

## 中值互补集合经验模态分解

刘淞华<sup>1</sup> 何冰冰<sup>1</sup> 郎恂<sup>1</sup> 陈启明<sup>2</sup> 张榆锋<sup>1</sup> 苏宏业<sup>2</sup>

**摘要** 针对经验模态分解 (Empirical mode decomposition, EMD) 系列方法存在的模态分裂 (Mode splitting, MS) 问题, 提出中值互补集合经验模态分解 (Median complementary ensemble EMD, MCEEMD) 算法. 通过概率模型量化互补集合经验模态分解 (Complementary ensemble EMD, CEEMD) 的 MS 问题, 证明了使用中值算子替代算术平均算子对抑制 MS 的有效性. 为了兼具抑制 MS 和残留噪声的性能, MCEEMD 算法首次在集合过程中结合了中值和平均算子. 具体地, 所提方法首先添加  $N$  对互补的白噪声至原信号中, 并经过 EMD 分解得到  $2N$  组固有模态函数 (Intrinsic mode functions, IMFs), 然后分别对其中互补相关的 IMFs 两两取平均得到  $N$  组 IMFs, 最后使用中值算子处理上述  $N$  组 IMFs 得到输出结果. 对仿真信号与两个真实案例的分析结果表明, 本文提出的 MCEEMD 方法不仅有效抑制了 CEEMD 的 MS 问题, 而且避免了单一使用中值算子的两个缺点: 分解完备性差和 IMFs 中存在的毛刺现象.

**关键词** 模态分裂, 中值算子, 互补白噪声, 互补集合经验模式分解

**引用格式** 刘淞华, 何冰冰, 郎恂, 陈启明, 张榆锋, 苏宏业. 中值互补集合经验模态分解. 自动化学报, 2023, 49(12): 2544–2556

**DOI** 10.16383/j.aas.c201031

### Median Complementary Ensemble Empirical Mode Decomposition

LIU Song-Hua<sup>1</sup> HE Bing-Bing<sup>1</sup> LANG Xun<sup>1</sup> CHEN Qi-Ming<sup>2</sup> ZHANG Yu-Feng<sup>1</sup> SU Hong-Ye<sup>2</sup>

**Abstract** In order to restrain the mode splitting (MS) problem of the empirical mode decomposition (EMD) series methods, a median complementary ensemble EMD (MCEEMD) algorithm is proposed in this paper. We first present novel probabilistic tools to quantify the MS phenomenon of complementary ensemble EMD (CEEMD), which aims at demonstrating the effectiveness of using the median operator to replace the mean operator during the ensemble process. To combine the advantages of suppressing MS and residual noise, the MCEEMD algorithm integrates both median and mean operators within the ensemble process for the first time. Specifically, the MCEEMD algorithm is enlightened and featured by following procedures: 1) Add  $N$  pairs of complementary white noise to the original signal to obtain  $2N$  groups of intrinsic mode functions (IMFs) by EMD decomposition; 2) By averaging each pair of the complementary IMFs, the  $2N$  groups of IMFs are computed into  $N$  IMF groups; 3) Assemble same-index components across the  $N$  groups of IMFs using the median operator to obtain the final IMFs within MCEEMD. Through typical simulations as well as two real-world cases, we show that the present work not only effectively alleviates the MS problem, but also avoids two shortcomings of using a single median operator, i.e., the poor decomposition completeness and the presence of burr in IMFs.

**Key words** Mode splitting (MS), median operator, complementary white noise, complementary ensemble empirical mode decomposition (CEEMD)

**Citation** Liu Song-Hua, He Bing-Bing, Lang Xun, Chen Qi-Ming, Zhang Yu-Feng, Su Hong-Ye. Median complementary ensemble empirical mode decomposition. *Acta Automatica Sinica*, 2023, 49(12): 2544–2556

收稿日期 2020-12-13 录用日期 2021-05-28

Manuscript received December 13, 2020; accepted May 28, 2021

国家自然科学基金 (81771928, 62003298), 云南省基础研究计划重点项目 (202101AS070031), 中国博士后科学基金资助项目 (2020M683389) 资助

Supported by National Natural Science Foundation of China (81771928, 62003298), Key Project of Fundamental Research of Yunnan Province (202101AS070031), and China Postdoctoral Science Foundation (2020M683389)

本文责任编辑 王鼎

Recommended by Associate Editor WANG Ding

1. 云南大学信息学院 昆明 650504 2. 浙江大学工业控制技术国家重点实验室 杭州 310027

1. School of Information, Yunnan University, Kunming 650504  
2. State Key Laboratory of Industrial Control Technology, Zhejiang University, Hangzhou 310027

经验模态分解 (Empirical mode decomposition, EMD) 算法是由 Huang 等<sup>[1]</sup> 提出的一种数据驱动分解的时-频分析方法<sup>[2]</sup>, 适用于分析处理非平稳非线性信号. 该方法能自适应地将原信号分解为一组固有模态函数 (Intrinsic mode functions, IMFs) 和一个残余量, 再对各个 IMF 进行希尔伯特变换 (Hilbert transform, HT), 得到具有实际意义的瞬时频率. EMD 方法自提出后在生物医学工程, 工业控制过程振荡监测, 机械设备故障诊断, 图像处理等众多工程领域得到了广泛的应用<sup>[3–5]</sup>. 目前, EMD 系列方法已与机器学习深度融合, 在预测、分类等

问题上实现了不小的突破<sup>[6-7]</sup>.

文献 [8] 指出 EMD 存在模态混叠和分解局限性等问题, 其中模态混叠将导致时频分布出现错位, 使 IMF 失去物理意义, 并对后续的信号分解产生影响. Wu 等<sup>[8]</sup> 基于白噪声的统计特性研究结果<sup>[9]</sup>, 提出了集合经验模态分解 (Ensemble EMD, EEMD). 通过将独立分布的高斯白噪声加入至原信号中进行 EMD 分解, 并对多次分解结果中相对应的 IMF 进行平均得到最终的 IMF 的. EEMD 利用高斯白噪声的频率均匀分布特性, 改变信号极值点的分布, 填充信号存在的间歇, 可以有效抑制 EMD 的模态混叠效应. 然而, 有限的集合平均次数不能完全消除添加白噪声的影响, 导致重构误差等问题. 针对该问题, Yeh 等<sup>[10]</sup> 提出 CEEMD (Complementary EEMD) 方法, 向待分解信号中加入若干对互补 (符号相反) 白噪声, 分别进行 EMD 分解, 通过集合平均时互补噪声相消, 有效减少了白噪声残留, 提高了分解的完备性. 类似地, 利用辅助噪声改进 EMD 的算法还有噪声完备集合经验模态分解 (Complete EEMD with adaptive noise, CEEM-DAN)<sup>[11]</sup>、噪声辅助多元经验模态分解 (Multivariate EMD, MEMD)<sup>[12]</sup> 和快速多元经验模态分解 (Fast MEMD, FEMD)<sup>[13]</sup> 等.

以上基于噪声辅助的 EMD 改进算法有效抑制了模态混叠, 但是它们在方法上共同存在模态分裂 (Mode splitting, MS) 问题. 其中模态混叠定义为一个 IMF 包含不同的尺度, MS 定义为一个尺度分裂到两个或更多的 IMF 上. 文献 [14] 提出中值集合经验模态分解 (Median EEMD, MEEMD), 利用中值算子替代算术平均算子, 有效抑制了 MS 问题. 然而实验发现, 中值取决于数据集中间位置的值, 这可能导致集合所得的 IMF 中存在毛刺, 降低信号光滑性. 其次, MEEMD 需要加入大量的噪声组数以降低重构误差, 并且达到与 EEMD 一致的重建效果理论上需要添加后者 1.25 倍的噪声组数, 致使 MEEMD 算法存在效率低、分解完备性差等问题. 因此, 该算法在实际工程应用中仍存在局限性.

事实上, CEEMD 方法提供了一种降低残留白噪声的思路, 即: 通过集合平均中和互补白噪声, 提升分解完备性. 基于此, 本文提出中值互补集合经验模态分解 (Median CEEMD, MCEEMD) 算法. 首先向原信号中添加  $N$  对互补白噪声, 通过 EMD 分解得到  $2N$  组 IMF; 然后, 分别对互补相关的两组 IMF (添加一对互补白噪声分解得到的两组 IMF) 进行平均运算得到  $N$  组 IMF; 最后, 对平均所得  $N$  组 IMF 进行中值运算, 输出最终的 IMF. 实验结果验证了 MCEEMD 方法的有效性.

本文的创新点归纳如下: 1) 在 EMD 系列方法的集合过程中, 首次将不同算子结合使用, 用以替代方法中的单一算子; 2) 所提方法结合了中值算子与平均算子的各自优点, 不但能够在一定程度上抑制 MS 问题, 而且克服了 MEEMD 分解完备性差、IMF 存在毛刺现象等缺陷; 3) 针对 CEEMD 的模态分裂问题, 提出了一系列概率统计模型量化分析该现象, 用以验证所提方法的合理性与有效性.

## 1 基础理论

### 1.1 EMD

经验模态分解根据原信号不同尺度的趋势和波动分解得到一组 IMF, 其中, IMF 为满足以下两个条件的函数: 1) 信号中极值点个数和过零点个数必须相等或仅相差一个; 2) 由信号局部极大值和极小值点分别拟合出上包络线和下包络线, 上、下包络线的局部均值必须为零.

对于待分解信号  $x(t)$ , 令  $i = 1$ , 则 EMD 分解过程如下:

- 1) 找到  $x(t)$  的所有局部极大值点和极小值点.
  - 2) 利用三次样条插值函数分别对信号  $x(t)$  的极大值和极小值进行拟合, 构成上、下包络线  $e^+(t)$ ,  $e^-(t)$ , 然后求取上、下包络均值  $m(t) = [e^+(t) + e^-(t)]/2$ , 并计算  $x(t)$  与包络线均值的差, 即  $h(t) = x(t) - m(t)$ .
  - 3) 若  $h(t)$  满足 IMF 的两个条件, 执行步骤 4); 不满足则将  $x(t)$  替换为  $h(t)$ , 然后执行步骤 1).
  - 4) 得到第  $i$  个 IMF:  $d_i(t) = h(t)$ , 以及剩余部分  $r_i(t) = x(t) - d_i(t)$ .
  - 5) 判断  $r_i(t)$  是否为常值或单调函数, 若是, 则分解结束; 否则, 令  $x(t) = r_i(t)$ ,  $i = i + 1$ , 返回步骤 1).
- 信号  $x(t)$  经 EMD 分解得到一组 IMF 和残余分量  $r_n(t)$ , 即

$$x(t) = \sum_{i=1}^n d_i(t) + r_n(t) \quad (1)$$

式 (1) 说明原信号可被分解为  $n$  个 IMF 分量  $\{d_i(t)\}_{i=1}^n$  和 1 个残余分量  $r_n(t)$ . 由于 EMD 方法具有完备性, 上述分量能精确重构出被分解信号  $x(t)$ .

### 1.2 EEMD 与 CEEMD

针对 EMD 方法存在的模态混叠问题, 文献 [8] 提出一种辅助噪声改进算法——EEMD. 该方法利用白噪声的频率分布特性, 使信号的极值点均匀分布, 填充了信号中的频率 (尺度) 间歇, 能够有效抑制 EMD 的模态混叠问题. 其详细算法流程参见文

献 [8], 简要步骤如下:

- 1) 添加一组白噪声信号至待分解信号中;
- 2) 对添加白噪声的信号进行 EMD 分解得到 IMFs;
- 3) 循环迭代步骤 1) 和步骤 2), 直至  $N$  组独立分布的白噪声全部加入;
- 4) 将上述分解得到的  $N$  组 IMFs 进行集合平均, 得到最终的分解结果.

该算法利用集合平均的中和作用, 可以一定程度上抑制由添加白噪声引起的重构误差. 但完全消除该问题需要大量的集合平均次数, 在实际工程应用中具有局限性. 文献 [9] 在 EEMD 算法基础上, 提出了 CEEMD 方法, 步骤如下:

- 1) 成对地添加互补 (符号相反) 白噪声至待分解信号;
- 2) ~ 4) 同 EEMD 算法中的步骤 2) ~ 4).

CEEMD 方法在向待分解信号中添加一组白噪声的同时添加一组符号相反的白噪声, 并通过对  $2N$  组 IMFs 进行平均运算, 使任意互补相关的两组 IMFs 中白噪声平均相消, 有效减少了由白噪声引起的重构误差, 提升了分解完备性. 然而, EEMD 与 CEEMD 均存在 MS 问题, 且无论改变集合尺寸还是改变添加白噪声的幅度都不能克服该问题.

## 2 CEEMD 的模式分裂

在文献 [14] 的基础上, 本文利用概率模型量化 CEEMD 的 MS 现象, 用于验证中值算子抑制 MS 问题的有效性.

根据 CEEMD 算法流程: 1) 向原信号中添加  $N$  对互补噪声, 分别经过 EMD 分解得到  $2N$  组 IMFs; 2) 分别对其中互补相关的两组 IMFs 进行平均, 可以得到  $N$  组相互独立的 IMFs; 3) 利用平均算子处理步骤 2) 中  $N$  组 IMFs, 得到最终的 IMF 集合. 为方便分析, 定义步骤 2) 中的任意一组 IMFs 为互补 IMFs. 由于  $N$  组互补 IMFs 之间相互独立, 所以仅对其中一组互补 IMFs 进行量化分析即可准确反映 CEEMD 算法的 MS 问题. 具体分析过程如下.

使用正弦信号  $x(t) = \sin(2\pi ft)$  作为原信号, 其中频率  $f = 2$  Hz, 并添加一对互补白噪声构成噪声辅助信号

$$\begin{cases} y^+(t) = x(t) + \varepsilon w(t) \\ y^-(t) = x(t) - \varepsilon w(t) \end{cases} \quad (2)$$

其中, 白噪声  $w(t) \sim N(0, 1)$ ,  $\varepsilon = 0.2\text{std}\{x(t)\}$  表示添加白噪声的幅度 (信号  $x(t)$  标准差的 0.2 倍) (若无特殊说明下同). 信号 (2) 经过 EMD 分解得到两组互补相关的 IMFs, 再进行平均运算可获得一组互补 IMFs, 如图 1 所示. 可以发现: 1)  $d_4$  分量与正




图 1 EMD 分解噪声辅助信号得到的前 5 个互补 IMFs  
Fig.1 The first five complementary IMFs obtained from the noise-assisted signal through EMD

弦信号  $x(t)$  相似程度最高, 视为主尺度. 2)  $d_3$  分量内包含少量与  $x(t)$  相关的半波, 这说明出现了 MS 现象. 3) EMD 算法由信号的极值点驱动分解, 并且信号  $x(t)$  中一个半波内仅存在一个极值点. 当某一半波的极值点附近存在噪声间歇时, 该极值点将参与到噪声分量的筛选过程中, 导致噪声分量中出现该极值点所对应的半波 (如  $d_3$  分量中虚线所圈部分). 因此, 分裂成分主要以半波的形式呈现. 4) 分裂成分 (虚线所圈部分) 与原信号的频率、波形相似, 进而以原信号的半波为单位可以量化 MS 现象.

基于以上结论, 对 MS 现象进行统计分析. 假设  $x(t)$  包含  $w_x(f)$  个半波, 根据半波的位置从整个观察区间中划分出  $w_x(f)$  个窗口, 如图 1 虚线划分所示. 如果某 IMF 的半波窗口内的信号绝对值之和大于噪声窗口阈值, 可以认为该窗口中的信号与原信号相关, 进而引出两个关键的概率参数.

1)  $p_i(f)$ : 互补 IMFs 中第  $i$  个分量内存在原信号的概率,  $i = 2, 3, 4$ . 对于每个频率  $f$ , 当互补 IMFs 中第  $i$  个分量内存在任意窗口的指标高于噪声阈值, 认为该分量包含原信号并计数. 进行 1000 次独立实验后, 设  $m_i$  为包含原信号的分量个数, 通过计算其所占百分比可以估计得到  $p_i(f)$ , 即:  $p_i(f) = m_i/1000$ . 其中, 互补 IMFs 中第  $i$  个分量的噪声阈值为

$$T_i = \frac{T_1}{\sqrt{\beta}} \rho^{-\frac{i}{2}} \quad (3)$$

式中,  $i = 2, 3, 4$ , 常数  $\rho, \beta$  分别为 2.01, 0.719.  $T_1$  通过计算第 1 个互补 IMF 中所有半波窗口内数据的绝对值之和, 然后取平均获得.

2)  $r_i(f)$ : 互补 IMFs 中第  $i$  个分量内存在原信号  $x(t)$  的时间占比, 即

$$r_i(f) = \frac{w_i(f)}{w_x(f)} \times 100\% \quad (4)$$

其中,  $w_i(f)$  为第  $i$  个互补 IMF 中与原信号  $x(t)$  相关的半波窗口个数,  $w_x(f)$  为  $x(t)$  全部半波窗口的数目.

上述互补 IMF 的  $p_i(f)$  和  $r_i(f)$  如图 2 所示, 可以发现: 1) 低频范围内 ( $1.5 \text{ Hz} \leq f \leq 2.1 \text{ Hz}$ ),  $d_4$  对应的  $p_4(f)$  和  $r_4(f)$  值最大, 因此可以将  $d_4$  分量视为主尺度; 2) 在频率增加至  $3.8 \text{ Hz}$  的过程中,  $p_3(f)$  和  $r_3(f)$  急剧增大, 逐渐接近  $100\%$ , 即主尺度逐渐由  $d_4$  分量转移至  $d_3$  分量; 3) 在高频范围内,  $d_2$  分量对应的  $p_2(f)$  和  $r_2(f)$  增幅趋势与之前  $d_3$  分量相似, 代表主尺度逐渐转移至  $d_2$  分量中. 基于上述分析可以发现, 原信号频率的改变使主尺度在不同分量之间进行转移, 从而不同程度地导致了发生 MS 现象.




图 2 互补 IMF 的 (由噪声辅助信号得到) 的  $p_i(f)$  和  $r_i(f)$  曲线

Fig.2 The curves  $p_i(f)$  and  $r_i(f)$  corresponding to the complementary IMF (obtained from the noise-assisted signal)

进一步定义  $P_i(f)$  为互补 IMF 中第  $i$  个分量内任意半波窗口中存在原信号  $x(t)$  的概率, 表达式为

$$P_i(f) = p_i(f) \times r_i(f) \quad (5)$$

通过  $p_i(f)$  和  $r_i(f)$  计算得到的  $P_i(f)$  如图 3 所示. 从图 3 中可以明显看出,  $P_i(f)$  与 EMD 的滤波器组特性<sup>[9]</sup> 相似.

在此基础上, 可以分析 CEEMD 分解结果中各个分量存在原信号的程度. 通过  $N$  次独立实验, 对得到的  $N$  组互补 IMF 进行平均运算, 即可得到 CEEMD 输出的 IMF. 其中, 对于第  $i$  个分量而言,  $N$  次独立实验中包含  $x(t)$  的互补 IMF 有  $P_i(f) \times N$  个, 然后取平均得到其出现的比率  $PR_i(f)$ , 表达式为




图 3 互补 IMF 的 (由噪声辅助信号得到) 的  $P_i(f)$  曲线  
Fig.3 The curves  $P_i(f)$  corresponding to the complementary IMF (obtained from the noise-assisted signal)

$$PR_i(f) = \frac{P_i(f)}{N} \times N \quad (6)$$

由于  $N$  组互补 IMF 之间相互独立, 所以通过平均运算得到的  $PR_i(f)$  与  $P_i(f)$  曲线一致. 这说明在  $N$  次独立实验中, 理论上  $PR_i(f)$  占比的分量将包含部分  $x(t)$ . 此外, 集合平均后得到的第  $i$  个 IMF 包含  $x(t)$  的程度与  $PR_i(f)$  成正比关系, 进而可以使用  $PR_i(f)$  量化 MS 现象.

通过上述分析发现, MS 现象主要出现在主尺度前、后两个分量中, 因此通过计算主尺度及其前、后两个分量的  $PR_i(f)$  即可量化 MS 程度. 针对本文研究的频率范围, 设计 MS 量化指标  $MSD(f)$ , 即

$$MSD(f) = \sum_{i=2}^4 PR_i(f) - \max\{PR_2(f), PR_3(f), PR_4(f)\} \quad (7)$$

其中,  $MSD(f)$  值越大,  $x(t)$  分裂的幅度和程度越大. CEEMD 算法使用平均算子处理  $N$  组互补 IMF, 得到最终 IMF, 其  $MSD(f)$  曲线如图 4 所示. 对照图 3 与图 4 容易发现: 首先, 在 EMD 滤波器组的重叠频带内 ( $1.6 \text{ Hz} \leq f \leq 1.8 \text{ Hz}$  或  $4.2 \text{ Hz} \leq f \leq 4.9 \text{ Hz}$ ), 使用平均算子获得的  $MSD(f)$  曲线出现明显的峰值, 即该频带内 MS 现象最为严重; 其次, 在重叠频带以外,  $MSD(f)$  曲线呈现明显的下降趋势, 尤其在  $2.9 \text{ Hz} \leq f \leq 3.1 \text{ Hz}$  频带内, 曲线接近于 0. 但是, 无论频率如何改变, 使用平均算子都将出现 MS 现象.

然而, 使用中值算子替换上述集合过程中的平均算子可以去除  $MSD(f)$  的故障点, 如图 4 所示. 其根本原因是: 对于第  $i$  个分量的任意半波窗口而言, 经过  $N$  次独立实验, 只要包含  $x(t)$  的分量数目不超过  $N/2$ , 集合过程使用中值算子即可有效剔除半波窗口中的  $x(t)$  成分. 所以, 当原始的  $MSD(f) <$




图 4 不同算子处理互补 IMF 集合得到的  $MSD(f)$  曲线

Fig.4 Curves of  $MSD(f)$  obtained by processing the complementary IMF s with different operators

50% 时, 使用中值算子得到的  $MSD(f)$  曲线将被置零, 可以有效抑制 MS 现象.

### 3 中值 CEEMD

#### 3.1 中值 CEEMD 算法

第 2 节论证了中值算子抑制 CEEMD 算法 MS 问题的有效性. 并且, 鉴于使用集合平均可以中和互补白噪声, 弥补单一使用中值算子的缺陷, 本文提出了中值 CEEMD (MCEEMD) 方法, 步骤如下:

- 1) 初始化, 令  $n = 1$ .
- 2) 添加成对互补白噪声至原始信号中

$$\begin{cases} y^{n+}(t) = x(t) + \varepsilon w_n(t) \\ y^{n-}(t) = x(t) - \varepsilon w_n(t) \end{cases} \quad (8)$$

其中,  $w(t) \sim N(0, 1)$ , 添加白噪声的幅度为  $\varepsilon = 0.2\text{std}\{x(t)\}$ .

3) 对  $y^{n+}(t)$  和  $y^{n-}(t)$  分别进行 EMD 分解, 得到两组 IMF s:  $\{d_i^{n+}(t)\}_{i=1}^M$ ,  $\{d_i^{n-}(t)\}_{i=1}^M$ , 然后对它们进行平均运算, 得到一组互补 IMF s, 即

$$d_i^n(t) = \frac{d_i^{n+}(t) + d_i^{n-}(t)}{2} \quad (9)$$

式中,  $i = 1, \dots, M$ ,  $M$  是 EMD 分解得到的 IMF 个数.

4) 令  $n = n + 1$ , 如果  $n \leq N$ , 重复步骤 2) 和步骤 3), 其中,  $N$  是添加的互补噪声组数.

5) 对步骤 4) 输出的  $N$  组互补 IMF s 进行中值运算, 得到最终的分解结果:  $\{d_i(t)\}_{i=1}^M$ . 其中, 第  $i$  个分量计算为

$$d_i(t) = \text{median}\{d_i^1(t), d_i^2(t), \dots, d_i^N(t)\} \quad (10)$$

图 5 为该算法框图.

#### 3.2 MCEEMD 模态分裂率

第 2 节利用概率模型从理论上分析了 CEEMD 的 MS 程度. 本节将基于仿真信号  $x(t)$  进一步对比 MCEEMD、MEEMD 和 CEEMD 的 MS 程度, 以验证中值算子抑制 MS 问题的有效性.

根据 MS 的定义, 主尺度所在 IMF 的前、后两个分量中可能存在原信号的分裂成分, 因此实际 MS 程度可由主尺度前、后两个分量与原信号之间的比值来反映, 定义模态分裂率<sup>[4]</sup>为

$$MSR(f) = \frac{\int_T [|d_{k-1}(t)| + |d_{k+1}(t)|] dt}{\int_T |x(t)| dt} \quad (11)$$

其中

$$k = \arg \max_i \left\{ \int |d_i(t)| dt \right\} \quad (12)$$

其中,  $i = 1, \dots, M - 1$ ,  $M$  是分解得到的 IMF 的个数.

使用 MCEEMD、MEEMD 和 CEEMD 分解仿真信号  $x(t) = \sin(2\pi ft)$ , 初始化条件相同: 辅助噪声幅度  $\varepsilon = 0.2\text{std}\{x(t)\}$ , 总采样点数 512 个, 采样频率  $f_s = 100$  Hz, 频率  $f = 1.1, 1.2, \dots, 5.5$  Hz, 其中间隔为 0.1 Hz. 为测试集合尺寸  $N$  对 MS 问题造成的影响, 采用  $N = 10, 20, 50, 100$  分别进行 1000 次独立实验并获得平均结果. 图 6 显示了 3 种方法在不同集合尺寸下的  $MSR(f)$  曲线, 可以看出: 1) MCEEMD 实际模态分裂率与理论分析中图 4 的结果高度一致; 2) MCEEMD 与 MEEMD 相比, 在滤波器组的重叠频带以外, MCEEMD 基本消除了噪声的影响, 使其  $MSR(f)$  曲线低于 MEEMD 且趋近于零. 但是在滤波器组的重叠频带内, MCEEMD 的  $MSR(f)$  曲线略高于后者. 其原因是, 方法中的平均过程  $d_i^n = [d_i^{n+}(t) + d_i^{n-}(t)]/2$  导致 MS 程度略有增加; 3) 与 CEEMD 方法相比, 本文提出的方法能够有效抑制不同集合尺寸下的 MS 问题. 并且, 本文方法的改善效果随集合尺寸的增加而更加明显. 尤其当  $N = 100$  时, 在滤波器组重叠频带以外, 本文方法的  $MSR(f)$  曲线以最快速率下降至零, 这说明 MS 问题得到了有效抑制.

#### 3.3 MCEEMD 分解完备性

文献 [10] 指出, 成对地添加互补噪声可以有效减小重建信号中的噪声残留, 保证分解完备性. 基于此, 进行数值实验对比分析 MCEEMD、MEEMD 和 CEEMD 的分解完备性, 验证本文方法融合两种算子 (平均、中值算子) 相对单一使用中值算子的有效性.

本次实验使用的仿真信号仍是  $x(t) = \sin(2\pi ft)$ , 其中,  $f = 3.5$  Hz, 总样本点数 512 个, 辅助噪声幅

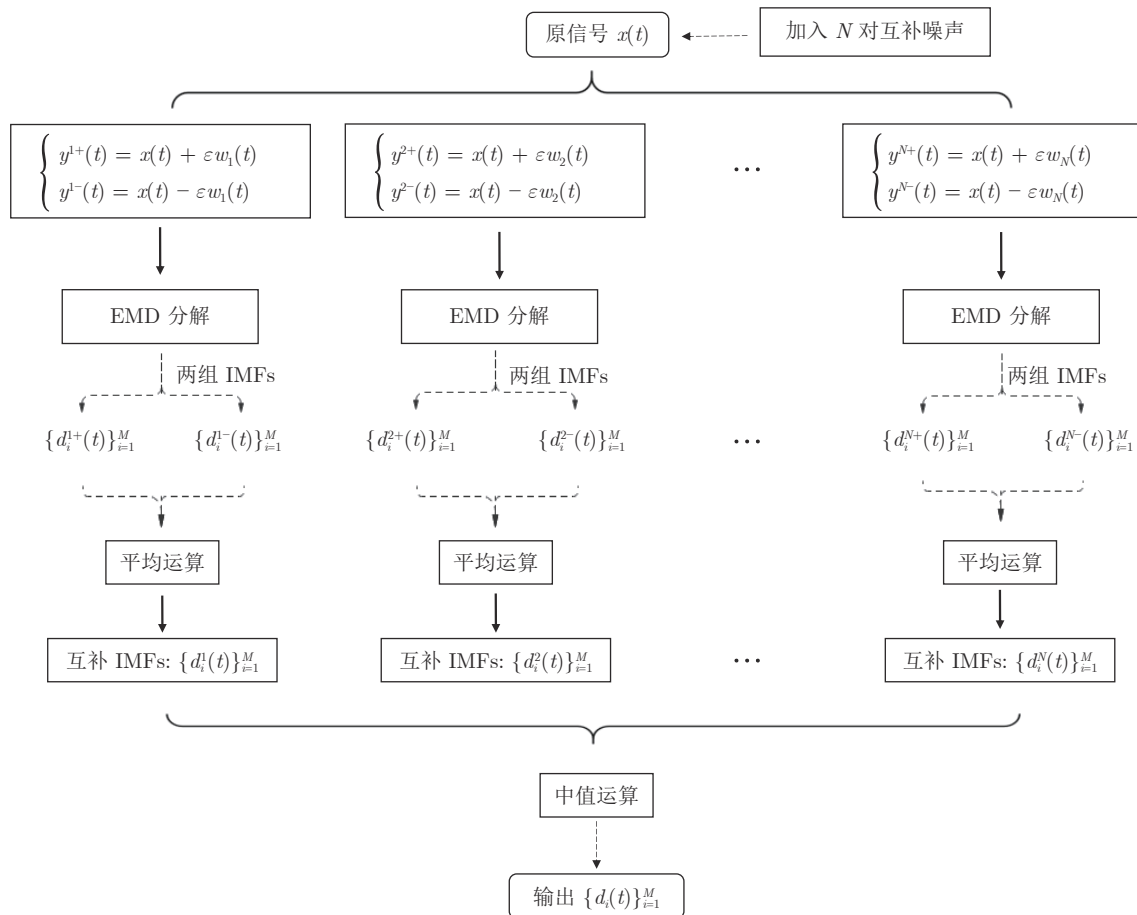


图 5 MCEEMD 算法框图

Fig.5 The block diagram of the MCEEMD algorithm

值为  $\varepsilon = 0.2\text{std}\{x(t)\}$ . 通过计算重建误差的标准差与辅助噪声幅值的比值, 可以反映噪声的残留量. 据此, 定义噪声残留率  $SDR(N)$  [14] 为

$$SDR(N) = \frac{\sigma_N}{\varepsilon} \quad (13)$$

其中,

$$\sigma_N = \text{std}\left\{x(t) - \sum_{i=1}^M d_i^N(t)\right\} \quad (14)$$

式 (14) 中,  $\{d_i^N(t)\}_{i=1}^M$  为上述 3 种方法在集合尺寸为  $N$  时分解得到的  $M$  个 IMF 分量,  $\sigma_N$  是重建误差的标准差.

本次数值实验使用不同数值的集合尺寸检验两种方法的分解完备性, 即  $N = 10, \dots, 100$ , 其中间隔为 5. 最终的  $SDR(N)$  结果由 1000 次独立的实验取平均获得, 如图 7 所示.

从图 7 中可以发现, 1) CEEMD 的  $SDR(N)$  曲线始终最低, 分解完备性最优; 2) MCEEMD 由于结合了平均算子, 相比 MEEMD 的  $SDR(N)$  曲线

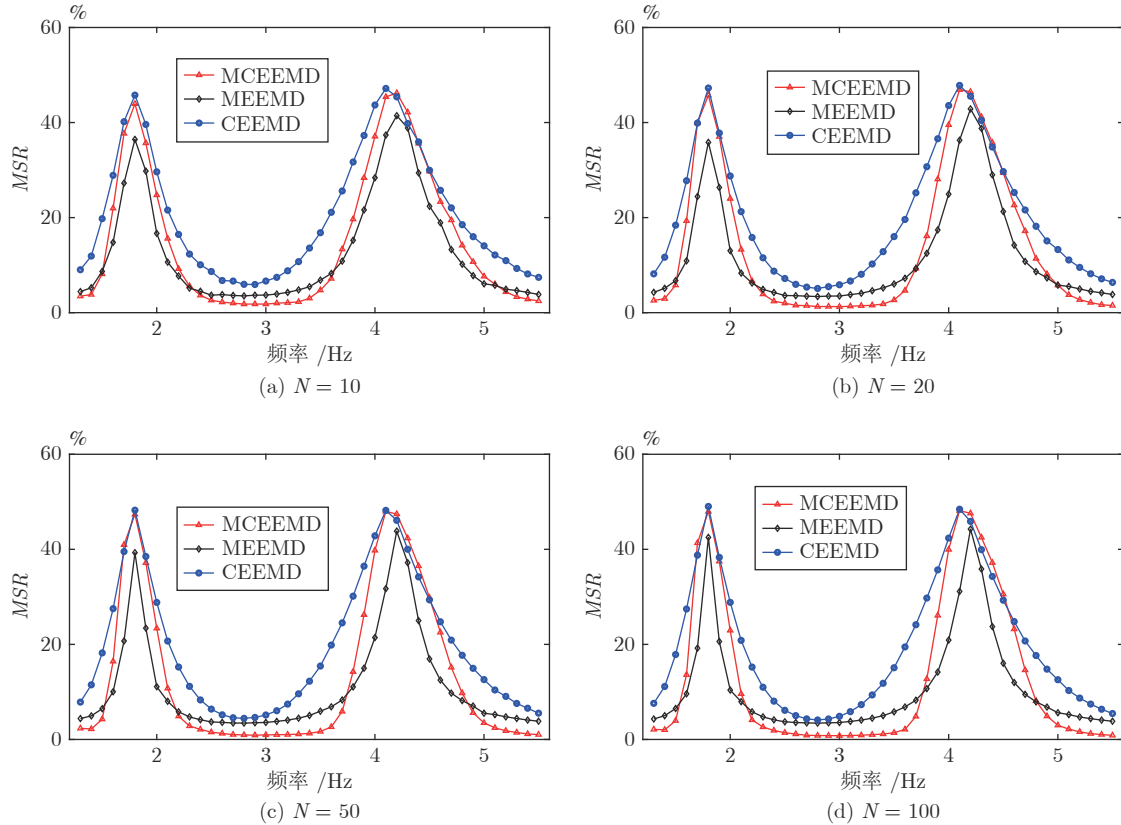

降低了约 75%, 分解完备性有明显的提升. 其根本原因是 MEEMD 方法单一使用中值算子, 导致噪声残留量较大, 而本文所提方法利用平均算子中和了互补白噪声, 所以重建信号与原信号吻合程度更高, 分解完备性优于 MEEMD.

### 3.4 仿真分析

本节使用式 (15) 所示仿真信号进一步验证本文方法的有效性.

$$Z(t) = x(t) + n(t) \quad (15)$$

其中, 设定原始信号为:  $x(t) = \cos(2\pi ft)$ ,  $f = 3.5$  Hz,  $n(t)$  是两段均值为 0 且幅值为 0.2 的高斯白噪声,  $w(t) \sim N(0, 0.2)$ ,  $t \in (100, 200) \cup (300, 400)$ . 信号总采样点 512 个, 采样频率  $f_s = 100$  Hz. 图 8(a) ~ 8(d) 依次对应 EEMD、CEEMD、MEEMD 和 MCEEMD 分解该仿真信号所得结果 (由于篇幅原因只显示到  $d_5$  分量). 由图 8 可以发现, 4 种方法的分解结果中  $d_3$  分量为主尺度. 然而, EEMD 和 CEEMD 单独使用平均算子, 导致  $d_2$  分量中存在部分原始信

图 6 不同集合尺寸下 CEEMD、MEEMD 和 MCEEMD 的  $MSR(f)$  曲线Fig. 6  $MSR(f)$  curves for different ensemble sizes within CEEMD, MEEMD and MCEEMD图 7 MCEEMD、MEEMD 和 CEEMD 在不同集合尺寸下的  $SDR(N)$  曲线Fig. 7  $SDR(N)$  curves for different ensemble sizes within MCEEMD, MEEMD and CEEMD

号  $x(t)$ , 表现出明显的 MS 问题. 而采用中值算子的 MEEMD 和 MCEEMD 两种方法, 所得到的  $d_3$  分量与原始信号  $x(t)$  高度吻合, 既精确地提取出周期信号, 又实现了周期信号与间歇信号的尺度分离.

进一步地, 上述方法的分解结果中,  $d_3$  分量与  $x(t)$  的皮尔逊相关系数分别为 0.9783, 0.9066, 0.9972, 0.9978. 显然, 采用中值算子的两种方法能

够更好地从间歇噪声中提取原始信号, 验证了中值算子抑制 MS 问题的有效性.

另外, 本案例还对比了使用中值算子的两种方法的性能. 图 9(a) 和图 9(b) 分别显示了 MEEMD 与 MCEEMD 分解得到的  $d_2$  分量. 从图 9 中可以明显发现, MEEMD 的  $d_2$  分量中存在大量毛刺, 导致分量的精确性差. 其根本原因是中值算子根据数据集内中间位置的值来确定代表值, 缺乏对数据集的概括能力, 从而降低了信号光滑性. 本文所提方法在中值算子的基础上融合了平均算子, 有效地改善了中值算子造成的毛刺现象. 并且, 两种方法分解仿真信号的  $SDR(N)$  曲线与图 7 一致, 即 MCEEMD 的分解完备性优于 MEEMD.

对上述仿真信号的分析初步表明, 本文提出的 MCEEMD 方法不仅可以有效抑制 MS 现象, 而且还能改善单一使用中值算子产生的毛刺现象和分解完备性差等问题. 此外, 本文所提方法对“纯净信号加瞬态振荡信号”的分解结果与上述结果高度一致.

#### 4 实际案例分析

鉴于 MCEEMD 在仿真实验中取得的良好性能, 因此可期待更多的实际应用. 为了验证所提出

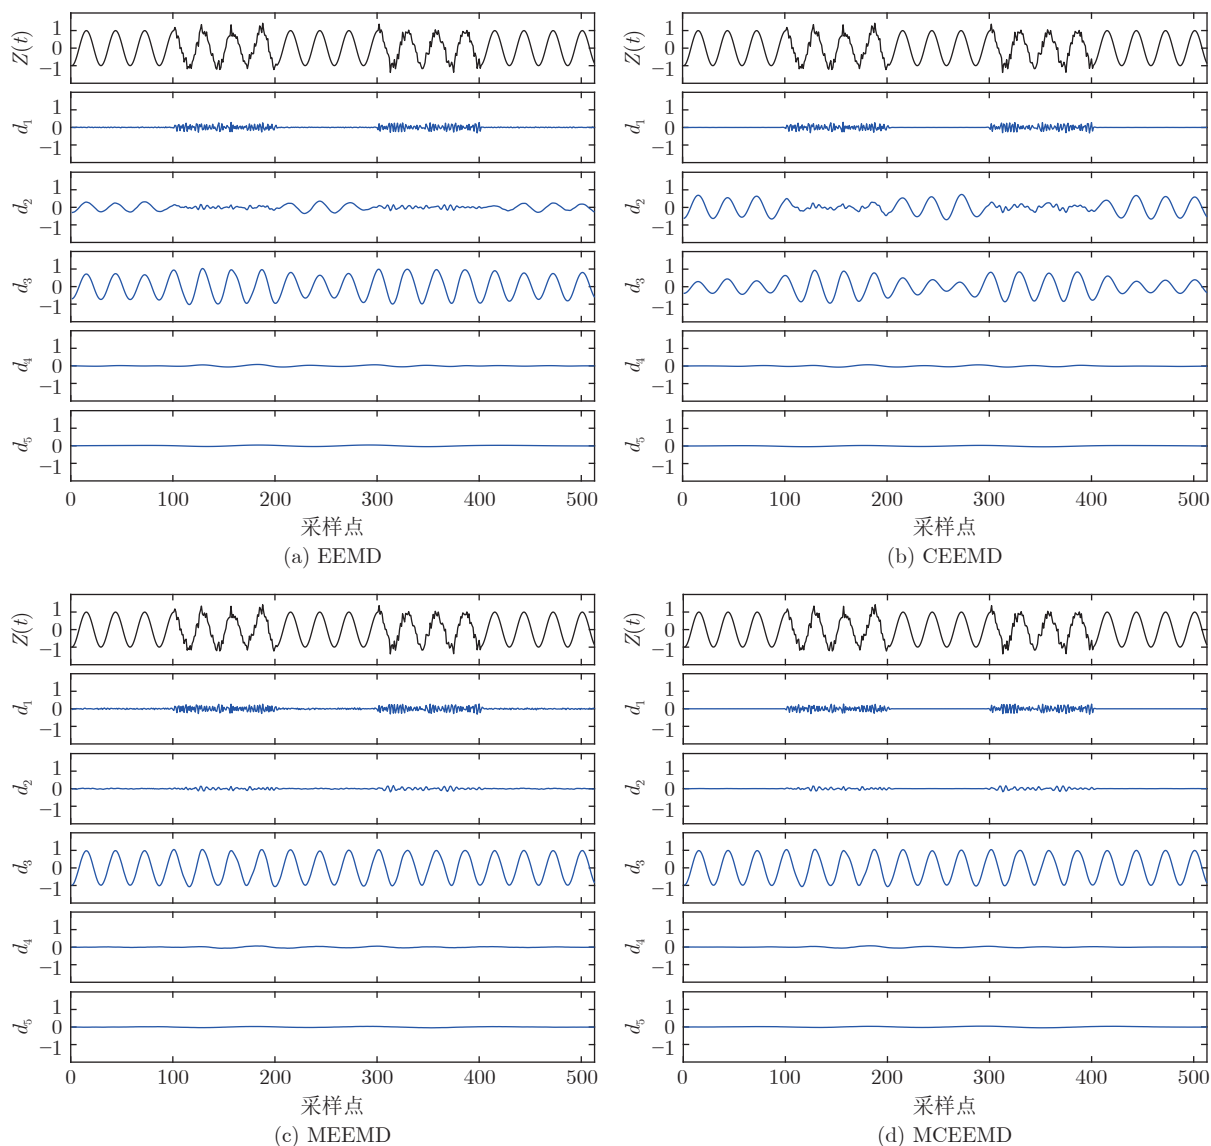


图 8 4 种方法分解仿真信号所得的前 5 个 IMF

Fig.8 The first five IMFs obtained by decomposing the simulated signal by four methods




图 9 MEEMD、MCEEMD 分解结果中的  $d_2$  模态  
 Fig.9 The  $d_2$  mode in the decomposition results of MEEMD and MCEEMD

方法在实际应用中的有效性, 本文研究了两个不同领域的典型应用, 即: 1) 机械故障信号特征提取; 2) 超声多普勒血流信号的干扰抑制. 由于机械系统中的故障涉及到部件的相对运动和磨损, 同时监测超声血流信号依赖于多普勒效应, 因此这两种信号均呈现显著的周期性, 可用于测试分解算法的实际性能.

本文算法实验硬件环境是笔记本电脑, 主要配置为 Intel i5-8300H, 2.3 GHz, 以及 8 GB 的内存; 软件环境是 32 位的 Windows10 系统, 仿真运行工具是 MATLAB2020a.

#### 4.1 机械故障信号

目前, 国内外对单向阀故障诊断研究的主要步骤包括: 信号预处理、特征提取和故障识别<sup>[14]</sup>. 其中,

信号预处理阶段通常使用 EMD 系列方法分解原始信号, 对 IMFs 进行处理后得到故障的特征向量; 然后, 利用特征提取方法提取故障特征信息进行训练; 最后建立故障诊断模型, 实现故障识别. 在处理 IMFs 过程中, 为提升故障特征提取的准确性, 通常将 EMD 系列方法分解结果中虚假分量、背景噪声进行分辨并去除<sup>[15-16]</sup>. 但是, EMD 系列方法存在 MS 问题, 可能导致部分故障特征分裂至被去除的分量中, 降低信号预处理的效果. 基于此, 对比分析现有的噪声辅助 EMD 方法与本文方法在信号预处理阶段的性能, 验证本文方法在实际应用中的有效性.

单向阀磨损击穿状态下的振动信号采样频率为 2560 Hz, 采样数据长度为 2048 个采样点<sup>[17]</sup>. 使用 EEMD、CEEMD、MEEMD 和 MCEEMD 四种方法处理该信号, 并设置集合尺寸  $N = 100$ , 添加白噪声幅度为振动信号标准差的 0.2 倍. 由于分解结果中的 MS 现象无法直观判断, 所以通过计算各个分量的功率谱密度 (Power spectral density, PSD) 来反映该现象.

图 10(a) ~ 10(d) 分别对应 EEMD、CEEMD、MEEMD 和 MCEEMD 分解结果中各个分量的 PSD 曲线. 从图 10 中可以看到: 1) EEMD 的 MS 问题

最为严重. 图 10(a) 中, IMF4 分量在 30 Hz 频率处出现 50% 左右的功率泄漏, IMF2 分量在 157 Hz 频率处出现约 37% 的功率泄漏; 2) CEEMD 在 30 Hz 频率处表现出的模态分裂程度与 EEMD 相同, 并且类似问题同样出现在 80 Hz、157 Hz 频率处; 3) MEEMD 在 30 Hz、80 Hz 频率处抑制了 MS 问题, 但在 157 Hz、194 Hz 频率处仍表现出约 23% 和 33% 的功率泄漏; 4) MCEEMD 在上述 4 个频率处均未出现明显的 MS 现象.

此外, 仅 MEEMD 将分解得到的主要信号功率 (20 ~ 40 Hz 频率成分) 集中在 IMF5. 这是由于该方法在 IMF2 分量出现了一定程度的模态分裂现象, 使得 160 ~ 200 Hz 的成分部分被分裂到 IMF3 分量中, 这将导致连锁反应, 使得之后所有的成分都分别往下一层 IMF 分裂. 图 10(a) 和图 10(b) 已经表明, IMF4 和 IMF5 包含了功率相当的成分. 当 IMF4 部分分裂至 IMF5 后, 将导致 20 ~ 40 Hz 频率的成分主要分布在 IMF5, 使 IMF5 占主导地位. 相应地, 使用中值算子将会在集合过程中把 IMF4 归于 IMF5 中. 该现象可能对后续的特征提取产生不利的影响.

文献 [18] 指出, 单向阀的故障特征主要出现在

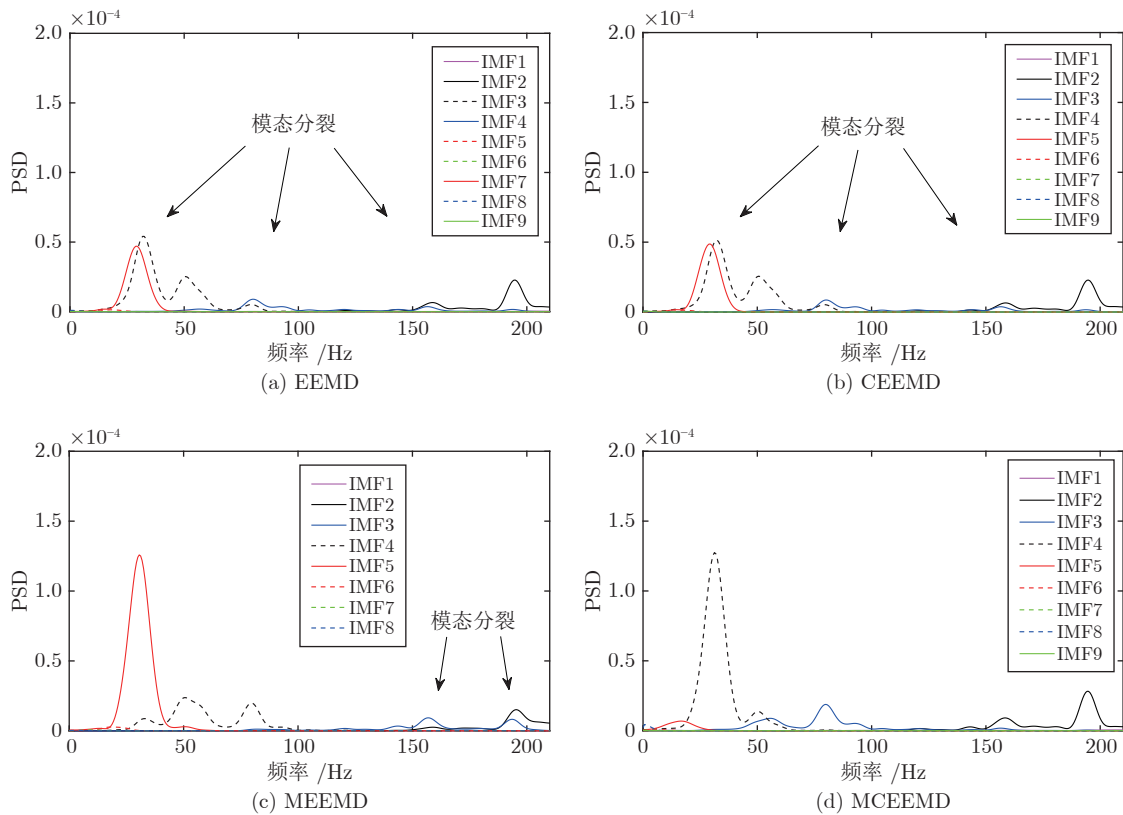


图 10 4 种方法分解结果的 PSD

Fig. 10 The PSD curves of the decomposition results from the four methods

10 ~ 200 Hz. 在该频带内, MCEEMD 方法有效抑制了 MS 问题, 分解得到的 IMFs 相对完整地保留了故障特征信息, 使提取到的特征更具代表性, 利于后续的故障识别研究.

## 4.2 超声多普勒血流信号

超声多普勒血流信号中经常存在管壁信号的干扰, 尤其在血流和管壁的临界处, 管壁信号会严重干扰血流信号中的低频成分. 因此, 有效抑制管壁干扰对提高血流流速检测的精度具有重要作用<sup>[19-20]</sup>.

EMD 系列方法常用于超声多普勒血流信号中血流成分的提取, 主要包含三大步骤<sup>[21]</sup>: 1) 使用 EMD 系列方法分解超声多普勒血流信号, 得到一组 IMFs. 2) 由于管壁信号功率通常比血流信号功率大约 20 dB, 所以通过管壁与血流功率比 (Wall blood signal ratio, WBSR)<sup>[22]</sup> 突变的位置, 即可确定血流与管壁的 IMF 分界点. 其中, 分界点以前的高频、低幅值 IMFs 属于血流信号, 而分界点以后的低频、高幅值 IMFs 属于管壁信号. 3) 将分界点以前的 IMFs 相加构成血流成分, 并且, 使用软阈值降噪法对提取到的血流成分进一步细分. 然而, 在步骤 2) 中, 传统 EMD 方法的 MS 现象可能导致分界点附近的 IMF 中包含不同尺度的信息, 即: 血流成分分裂至管壁成分中, 或者, 管壁成分分裂至血流成分中. 这将影响提取血流成分的精度. 基于此, 对比分析现有噪声辅助 EMD 方法与本文方法提取血流成分的性能, 验证本文方法提取血流成分的有效性. 步骤详述如下.

所分析的超声多普勒人体颈动脉血流信号从管壁和血流临界点处测得, 其中, 采样频率为 6666 Hz, 数据长度为 4048 个样本点. 使用 MCEEMD 方法分解血流信号结果如图 11 所示. 通过 WBSR 方法判断出  $d_3$  分量为临界点, 因此, 将前三个 IMFs 分量相加构成血流成分. 按上述步骤, 分别获得 EEMD、CEEMD 和 MEEMD 提取到的血流成分.

由于血流成分与管壁干扰之间存在频率分界点, 采用高通滤波器提取血流成分时的归一化截止频率通常设为  $f = 0.09$  Hz<sup>[23]</sup>. 因此, 计算出原信号与各方法提取血流成分的归一化 PSD, 如图 12 和图 13 所示. 在此基础上, 可以通过两个方面来评价方法的性能: 1) 图 13 中  $f = 0.09$  Hz 左侧部分为管壁干扰, 所以该部分的面积大小可以反映方法抑制干扰的性能; 2) 右侧部分可认为是较为纯净的血流, 通过与原信号该部分的 PSD 曲线进行互相关分析, 可以评估方法提取血流的精度.

对照图 12 与图 13 容易发现: 1) 在截止频率  $f = 0.09$  Hz 左侧, MCEEMD、MEEMD 的功率谱




图 11 MCEEMD 分解血流信号所得的前 8 个分量  
Fig. 11 The first eight components of the blood flow signal decomposed by MCEEMD




图 12 原始信号的频率归一化功率谱  
Fig. 12 The frequency normalized PSD of the original signal

面积较小, 有效抑制了管壁干扰; 2) 在其右侧, MEEMD 的功率谱与原信号相差较大, 说明该方法提取的血流成分严重失真.

进一步地, 使用皮尔逊相关系数 (Pearson correlation coefficient, PCC)、均方根误差 (Root mean square error, RMSE) 以及 PSD 面积比 (PSD area ratio) 来定量分析方法性能. 首先, 对于 PSD 中  $f = 0.09$  Hz 右侧部分, 分别计算 4 种方法提取的血流成分与原信号之间的 PCC、RMSE. 其次, 对于  $f = 0.09$  Hz 左侧部分, 分别计算 4 种方法提取的血流成分与原信号之间的面积比, 得到 PSD 面积比. 以上计算结果如表 1 所示.




图 13 EEMD、CEEMD、MEEMD 和 MCEEMD 提取的血流成分频率归一化功率谱

Fig.13 Frequency normalized PSD of the blood flow component extracted by EEMD, CEEMD, MEEMD, and MCEEMD, respectively

表 1 4 种方法的性能指标

Table 1 Performance indicators of the four methods

方法	PCC	RMSE	PSD 面积比 (%)
EEMD	0.9568	0.3087	0.28
CEEMD	0.9986	0.0031	0.21
MEEMD	0.7293	1.2938	0.24
MCEEMD	0.9980	0.1614	0.14

表 2 4 种方法的计算时间

Table 2 Calculation time of the four methods

方法	计算时间 (s)
EEMD	14.32
CEEMD	28.95
MEEMD	14.58
MCEEMD	29.01

从表 1 中可以看出, MCEEMD 和 CEEMD 方法的 PCC 接近于 1, 说明提取的血流成分与原信号吻合程度较高, 并且两种方法之间的差仅为万分位级, 可以忽略不计. 相比之下, MEEMD 由于单独使用中值算子导致其相关系数最低. 其次, MCEEMD 方法的 RMSE 相比 MEEMD 降低了 87% 左右, 方法的分解完备性得到大幅度提升, 仅次于 CEEMD. 更重要的是, MCEEMD 的 PSD 面积比在 4 种方法中最小, 分别比 EEMD、CEEMD、MEEMD 减小了约 50%, 33%, 42%, 说明该方法有效抑制了管壁干扰.

此外, 表 2 给出了 4 种方法的计算时间. 可以发现, 在方法初始参数 (噪声幅值、集合次数、筛选停止指标) 相同的情况下, CEEMD 和 MCEEMD

的计算时间基本相同, 约为 EEMD 和 MEEMD 的两倍, 其原因是: 前两种方法之间的区别仅在于处理 IMFs 集合的算子差异, 调用 EMD 子算法的次数相同, 所以两种方法计算时间高度相似; 然而, 由于它们加入了互补噪声, 使得调用 EMD 子算法的次数是 EEMD、MEEMD 的两倍, 计算时间也约为两倍. 但是, 本文所提方法与 MEEMD 相比, 分解完备性有 75% 的提升, 设置较少的集合次数即可获得优于 MEEMD 的分解结果. 当要求两种方法在达到相同的完备性标准时, 本文所提方法要求的独立分解次数更少, 运行时间更短.

综上所述, 本文方法既能精确地提取血流成分, 又抑制了管壁干扰, 对后续的噪声细分、平均血流估计 (血流测速) 研究起到积极作用.

基于上述两个实际案例可以看出, 在实际应用中 EMD 系列方法常出现模态混叠、模态分裂现象, 而 MEEMD 又存在分解完备性差、IMFs 中出现毛刺等固有问题. 本文提出的 MCEEMD 可以有效地抑制上述问题, 该方法对大部分存在模态分裂的应用场合有效.

此外, 我们还针对不同采样频率的仿真信号、工业控制过程振荡信号 (振荡检测)<sup>[24]</sup> 和心电信号 (信号消噪)<sup>[25]</sup> 进行实验, 结果与本文结论高度一致, 说明本文所提方法对采样频率并不敏感, 并且在多种领域中均具备实践性, 验证了方法的可推广性及应用价值.

## 5 结束语

针对 MEEMD 单一使用中值算子造成的分解完备性差、IMFs 存在毛刺等问题, 本文提出 MCEEMD 方法. 该方法在使用中值算子的基础上, 利用集合平均中和了互补白噪声. 仿真实验结果表明, 该方法既抑制了 MS 问题, 又克服了单一使用中值算子造成的缺陷, 提升了方法的分解完备性, 使分解得到的 IMF 更具物理意义. 最后, 使用两个不同工程领域的案例, 验证了本文所提方法相对 EMD、CEEMD 和 MEEMD 的优越性. 因此, 本文建议将 MCEEMD 作为 MEEMD 的标准形式. 此外, 针对特殊的实际信号, 可以尝试更先进的平均算子, 例如: 模式平均、几何平均和加权平均等. 下一步的主要工作是研究其他平均算子的优点, 以及如何完全抑制 MS 问题.

## References

- Huang N E, Shen Z, Long S R, Wu M C, Shih H H, Zheng Q, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings Mathematical Physical and Engineering Sciences*, 1998, **454**(1971): 903–995
- Mandic D P, Rehman N U, Wu Z H, Huang N E. Empirical mode decomposition-based time-frequency analysis of multivariate signals: The power of adaptive data analysis. *Signal Processing Magazine IEEE*, 2013, **30**(6): 74–86
- Yang Mo-Han, Chen Wan-Zhong, Li Ming-Yang. Multiple feature extraction based on ensemble empirical mode decomposition for motor imagery EEG recognition tasks. *Acta Automatica Sinica*, 2017, **43**(5): 743–752  
(杨默涵, 陈万忠, 李明阳. 基于总体经验模态分解的多类特征的运动想象脑电识别方法研究. *自动化学报*, 2017, **43**(5): 743–752)
- Lang X, Lu S, Xie L, Zakharov A, Zhong D, Jämsä-Jounela S L. Bihocurrence based industrial control loop nonlinearity detection and diagnosis in short nonstationary time series. *Journal of Process Control*, 2018, **63**: 15–28
- Lang X, Zhang Y F, Xie L, Jin X, Horch A, Su H Y. Use of fast multivariate empirical mode decomposition for oscillation monitoring in noisy process plant. *Industrial and Engineering Chemistry Research*, 2020, **59**(25): 11537–11551
- Devi A S, Maragatham G, Boopathi K, Rangaraj A G. Hourly day-ahead wind power forecasting with the EEMD-CSO-LSTM-EFG deep learning technique. *Soft Computing*, 2020, **24**(16): 12391–12411
- Li Xia, Lu Guan-Ming, Yan Jing-Jie, Zhang Zheng-Yan. A survey of dimensional emotion prediction by multimodal cues. *Acta Automatica Sinica*, 2018, **44**(12): 2142–2159  
(李霞, 卢官明, 闫静杰, 张正言. 多模态维度情感预测综述. *自动化学报*, 2018, **44**(12): 2142–2159)
- Wu Z H, Huang N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method. *Advances in Adaptive Data Analysis*, 2009, **1**(1): 1–41
- Flandrin P, Rilling G, Goncalves P. Empirical mode decomposition as a filter bank. *IEEE Signal Processing Letters*, 2004, **11**(2): 112–114
- Yeh J R, Shieh J S, Huang N E. Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method. *Advances in Adaptive Data Analysis*, 2010, **2**(2): 135–156
- Torres M E, Colominas M A, Schlotthauer G, Flandrin P. A complete ensemble empirical mode decomposition with adaptive noise. In: *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Prague, Czech Republic: IEEE, 2011. 4144–4147
- Rehman N, Mandic D P. Multivariate empirical mode decomposition. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2010, **466**(2117): 1291–1302
- Lang X, Zheng Q, Zhang Z M, Lu S, Xie L. Fast multivariate empirical mode decomposition. *IEEE Access*, 2018, **6**: 65521–65538
- Lang X, ur Rehman N, Zhang Y F, Xie L, Su H Y. Median ensemble empirical mode decomposition. *Signal Processing*, 2020, **176**: Article No. 107686
- Cheng J S, Yu D J, Tang J S, Yang Y. Application of SVM and SVD technique based on EMD to the fault diagnosis of the rotating machinery. *Shock and Vibration*, 2009, **16**(1): 89–98
- Zhao Chun-Hui, Yu Wan-Ke, Gao Fu-Rong. Data analytics and condition monitoring methods for nonstationary batch processes—Current status and future. *Acta Automatica Sinica*, 2020, **46**(10): 2072–2091  
(赵春晖, 余万科, 高福荣. 非平稳间歇过程数据解析与状态监控——回顾与展望. *自动化学报*, 2020, **46**(10): 2072–2091)
- Zhou Cheng-Jiang, Wu Jian-De, Yang Jing-Zong. Fault diagnosis of core equipment of slurry pipeline based on CEEMD-SVD-LSSVM. *Journal of Yunnan University Natural Sciences Edition*, 2018, **40**(5): 886–896  
(周成江, 吴建德, 杨静宗. 基于 CEEMD-SVD-LSSVM 的矿浆管线核心设备故障诊断. *云南大学学报自然科学版*, 2018, **40**(5): 886–896)
- Luo Ji-Hui, Huang Guo-Yong. Check valve fault diagnosis based on generalized S-transform and deep belief network. *Journal of Electronic Measurement and Instrumentation*, 2019, **33**(9): 197–203  
(罗继辉, 黄国勇. 基于广义 S 变换和深度置信网络的单向阀故障诊断. *电子测量与仪器学报*, 2019, **33**(9): 197–203)
- He B B, Zhang Y F, Zhang K X, Chen J H, Zhang J H, Liang H. Optimum speckle tracking based on ultrafast ultrasound for improving blood flow velocimetry. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 2020, **68**(3): 494–509
- Xia Ping, Shi Yu, Lei Bang-Jun, Gong Guo-Qiang, Hu Rong, Shi Dong-Xia. Ultrasound medical image segmentation based on hybrid probabilistic graphical model in complex-wavelet domain. *Acta Automatica Sinica*, 2021, **47**(1): 185–196

(夏平, 施宇, 雷帮军, 龚国强, 胡蓉, 师冬霞. 复小波域混合概率图模型的超声医学图像分割. 自动化学报, 2021, 47(1): 185-196)

- 21 Lin Wen-Jing, Zhang Yu-Feng, Zhang Ke-Xin, Li Zhi-Yao, Li Hai-Yan, Gao Lian, et al. Extraction of doppler ultrasound blood signals using the delicate separation method based on the EEMD algorithm. *Acta Electronica Sinica*, 2014, 42(7): 1424-1428  
(林文晶, 张榆锋, 章克信, 李支尧, 李海燕, 高莲, 等. 总体经验模态细分法提取血流超声多普勒信号的研究. 电子学报, 2014, 42(7): 1424-1428)
- 22 Zhang Y F, Gao Y L, Wang L, Chen J H, Shi X L. The removal of wall components in Doppler ultrasound signals by using the empirical mode decomposition algorithm. *IEEE Transactions on Biomedical Engineering*, 2007, 54(9): 1631-1642
- 23 Majd S M M T, Asl B M. Adaptive spectral doppler estimation based on the modified amplitude spectrum capon. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 2021, 68(5): 1664-1675
- 24 Lang X, Zheng Q, Xie L, Horch A, Su H Y. Direct multivariate intrinsic time-scale decomposition for oscillation monitoring. *IEEE Transactions on Control Systems Technology*, 2020, 28(6): 2608-2615
- 25 Xie X Y, Liu H, Shu M L, Zhu Q, Huang A P, Kong X Q, et al. A multi-stage denoising framework for ambulatory ECG signal based on domain knowledge and motion artifact detection. *Future Generation Computer Systems*, 2021, 116: 103-116



**刘淞华** 云南大学信息学院博士研究生. 主要研究方向为数据驱动故障检测与诊断, 微弱信号检测与处理.

E-mail: liusonghuayn@126.com

(**LIU Song-Hua** Ph.D. candidate at the School of Information, Yunnan University. His research interest

covers data-driven fault detection and diagnosis, and weak signal detection and processing.)



**何冰冰** 云南大学信息学院讲师. 主要研究方向为超声平面波血流信号处理.

E-mail: he\_bing\_bing123@126.com

(**HE Bing-Bing** Lecturer at the School of Information, Yunnan University. Her main research interest

is ultrasonic plane wave blood flow signal processing.)



**郎 恂** 云南大学信息学院副教授. 主要研究方向为数据驱动故障检测与诊断, 时频分析和医学信号处理. 本文通信作者.

E-mail: langxun@ynu.edu.cn

(**LANG Xu** Associate professor at the School of Information, Yunnan

University. His research interest covers data-driven fault detection and diagnosis, time-frequency analysis, and medical signal processing. Corresponding author of this paper.)



**陈启明** 浙江大学工业控制技术国家重点实验室博士研究生. 主要研究方向为信号分解, 时频分析和故障诊断.

E-mail: chenqiming@zju.edu.cn

(**CHEN Qi-Ming** Ph.D. candidate at the State Key Laboratory of Industrial Control Technology, Zhejiang

University. His research interest covers signal decomposition, time-frequency analysis, and fault diagnosis.)



**张榆锋** 云南大学信息学院教授. 主要研究方向为数字信号处理理论, 微弱信号检测和医学超声工程.

E-mail: zhangyf@ynu.edu.cn

(**ZHANG Yu-Feng** Professor at the School of Information, Yunnan University. His research interest

covers digital signal processing theory, weak signal detection, and medical ultrasound engineering.)



**苏宏业** 浙江大学工业控制技术国家重点实验室教授. 主要研究方向为控制理论与应用, 复杂过程先进控制和优化技术, 先进控制软件开发及应用.

E-mail: hysu69@zju.edu.cn

(**SU Hong-Ye** Professor at the State Key Laboratory of Industrial

Control Technology, Zhejiang University. His research interest covers control theory and application, complex process advanced control and optimization technology, and the software development and application of advanced control.)