

# EEMD-RobustICA 和 Prony 算法在电力系统 低频振荡模态辨识中的应用

赵峰<sup>1,2</sup>, 吴梦娣<sup>1</sup>

(1. 兰州交通大学自动化与电气工程学院, 兰州 730070; 2. 兰州交通大学 光电技术与智能控制教育部重点实验室, 兰州 730070)

**摘要:** 针对互联网低频振荡辨识过程中 Prony 算法对噪声敏感的问题, 该文将总体经验模态分解法、鲁棒性独立分量分析与 Prony 进行有机结合, 运用到关键振荡模式辨识中。将待处理信号进行总体经验模态分解后得到的本征模态函数作为鲁棒性独立分量分析算法的输入, 对得到的独立分量进行软阈值去噪后进行反变换得到重构后的本征模态函数, 接着将重构后的本征模态函数相加得到去噪信号, 用 Prony 算法对去噪信号进行辨识, 最终得到低频振荡的模态参数。仿真结果表明: 该方法综合利用了总体经验模态分解不依赖信号任何先验知识和完全由数据驱动的自适应性优点, 及鲁棒性独立分量分析提取独立分量并保持分量信号完整性的优势, 相比传统总体经验模态分解去噪算法, 该方法在没有损失信号的前提下可提高分量信号的信噪比, 克服 Prony 算法对噪声敏感的缺陷, 更大程度去除噪声, 有利于提高辨识精度和准确性, 更能满足实际应用需求。

**关键词:** 总体经验模态分解; 鲁棒性独立分量分析; Prony 算法; 低频振荡; 模式辨识

**中图分类号:** TM712

**文献标识码:** A

## 0 引言

随着电力工业规模不断扩大, 区域电力系统互联及长距离输电增多, 低频振荡时有发生, 严重威胁了电力系统的安全稳定运行<sup>[1,2]</sup>。为抑制系统低频振荡保证互联网安全稳定运行, 目前采用的措施有直流功率调制、安装 PSS 和 SVC 专用装置等<sup>[3]</sup>。为准确配备各项技术措施需要分析出系统具体的振荡特征, 及时准确地提取出低频振荡信号中的关键振荡模式已成为有效抑制电网低频振荡现象的重要基础之一。

研究人员近年来对于电力系统低频振荡信号的辨识提出许多方法, 常用的有傅里叶变换(FFT)<sup>[4]</sup>、小波分析法<sup>[5]</sup>、Prony 算法<sup>[6]</sup>、HHT 算法<sup>[7]</sup>。HHT 和 Prony 算法是目前国内外学者研究与应用较多的两种低频振荡算法<sup>[8]</sup>。其中 Prony 算法在低频振荡辨识、系统阻尼控制、暂态变量分析中发挥了重要作用。但单一的 Prony 算法在模式辨识过程中因其精度对噪声极为敏感, 导致辨识的效果不够

理想<sup>[9]</sup>。因此在运用 Prony 算法辨识低频振荡信号模态方面需要寻求一种更为准确的方法。总体经验模态分解(ensemble empirical mode decomposition, EEMD)算法在地震信号、水电机组振动信号、齿轮故障诊断<sup>[10-12]</sup>等众多领域已被广泛应用。传统的 EEMD 去噪算法是使用阈值去噪算法对本征模态函数(intrinsic mode functions, IMFs)直接进行去噪, 但该去噪算法的去噪效果不理想, 一方面是因为直接对 IMFs 阈值去噪没有考虑 EEMD 分解的固有特性, 去噪时破坏了模态单元的完整性, 对重构信号的连续性产生灾难性的后果; 另一方面是由于低信噪比条件下阈值去噪算法的去噪性能不佳<sup>[13]</sup>。针对这一问题, 本文利用鲁棒性独立分量分析(robust independent component analysis, RobustICA)算法提取独立分量的优势, 运用 EEMD-RobustICA 方法去除噪声。该方法能够在未损失信号的情况下保持 IMFs 的整体性并在去噪前提高分量信号的信噪比, 从而减小去噪后信号的失真度, 改善去噪效果; 将 EEMD-RobustICA 与 Prony 算法

收稿日期: 2017-05-08

基金项目: 甘肃省自然科学基金(1310RJZA038); 光电技术与智能控制教育部重点实验室(兰州交通大学)开放课题(KFKT2016-6)

通信作者: 赵峰(1966—), 男, 硕士、教授, 主要从事新能源方面的研究。zhaofeng818@163.com

有机结合可用于电网低频振荡模态分析。通过对比试验信号和 IEEE 四机系统低频振荡信号进行试验验证表明,该算法能够较为全面、准确地辨识出电力系统低频振荡信号中的振荡模式。

## 1 EEMD-RobustICA 和 Prony 算法分析

### 1.1 Prony 算法

在 Prony 分析<sup>[14-16]</sup>中,采用一组负指数项的线性组合来拟合离散采样数据,并能够直接提取离散数据中所含源信号的频率、幅值、衰减因子和阻尼比等关键参数。

假设输入信号为  $\hat{x}$ , 其拟合模型为:

$$\hat{x}(n) = \sum_{m=1}^p A_m e^{j\theta_m} e^{(\alpha_m + j2\pi f_m) \Delta t} \quad (1)$$

式中,  $\hat{x}(n)$  —— 采样点;  $A_m$ 、 $\theta_m$ 、 $f_m$ 、 $\alpha_m$  —— 幅值、初相角、频率和衰减因子;  $p$  —— 模型阶数;  $m$  —— 数函数,  $m$  可代表  $1, 2, 3, \dots, p$  中的任何一个, 共有  $p$  个指数函数。

设  $z_k$  是常系数线性差分方程式(2)的齐次解:

$$\phi(z) = \prod_{k=1}^p (z - z_k) = \sum_{i=0}^p a_i z^{p-i} = 0 \quad (2)$$

式中,  $\phi(z)$  —— 常系数线性差分方程;  $a_i$  —— 特征方程系数。

通过求解式(2)即可得到特征根  $z_k$ , 最后将特征根代入式(1)便可解得各振荡模态的振幅、初相位、振荡频率和衰减因子。

### 1.2 Prony 算法主要参数选择策略

1) 采样频率: 要获取正确的估计, 信号采样应满足 Nyquist 采样定理, 即采样频率大于信号最高频率的 2 倍, 以避免频谱发生混叠。在实际应用中, 采样频率刚刚大于 2 倍最高频率还不够, 而是应该有相当的裕度以保证结果精度。

2) 系统阶数: Prony 方法常用的定阶方法为选取初始阶数  $L$ , 使其远大于信号中实际包含的指数项个数, 得到  $L$  个指数项分量, 然后从这  $L$  个分量中选取  $K$  个分量的最优子集, 使这  $K$  个指数项分量最小平方意义上逼近观察数据, 此时的  $n$  就作为 Prony 分析使用的阶数。

在应用 Prony 算法进行参数辨识过程中, 为得到准确辨识结果, 保证采样频率和系统阶数处于最

优情况, 应遵循以上 2 个策略。

### 1.3 总体经验模态分解法

经验模态分解(EMD)方法的特点是能够对非平稳、非线性的信号进行平稳化和线性化处理, 并且在分解的过程中保留数据本身的特性。它最大的优点是基于信号本身的时间尺度特征, 无需选择基函数就可把复杂信号分解成若干个按频率高低排列的 IMFs 和一个余项<sup>[8]</sup>, 其缺点在于 EMD 存在模态混叠问题。模态混叠将导致 IMFs 成分中包含不同的时间尺度, 从而对各个模态分量的物理意义的判别造成困难。为解决模式混叠的问题, 中国台湾海洋学家 Norden E. Huang(黄锷)等<sup>[17]</sup>对 EMD 方法做出改进, 并提出 EEMD 方法, 该方法证明可消除模态混叠现象, 达到明显改善 EMD 方法分解效果的目的。其算法步骤为<sup>[18]</sup>:

1) 在原始信号  $x(t)$  中多次添加等长度随机正态分布的白噪声  $n_i(t)$ , 即:

$$x_i(t) = x(t) + n_i(t) \quad (3)$$

2) 对  $x_i(t)$  分别进行 EMD 分解, 得到各个 IMFs 分量记为  $c_{ij}(t)$ , 与一个余项记为  $r_{in}(t)$ , 则有:

$$x_i(t) = \sum_{j=1}^n c_{ij}(t) + r_{in}(t) \quad (4)$$

式中,  $x_i(t)$  —— 第  $i$  次加入高斯白噪声的合成信号。

3) 重复步骤 1) 和步骤 2) 共  $N$  次。

将上述 IMFs 进行总体平均运算, 得到最终的 IMFs 分量组:

$$c_j(t) = \frac{1}{N} \sum_{i=1}^N c_{ij} \quad (5)$$

式中,  $c_j(t)$  —— EEMD 分解后得到的最终的第  $j$  个 IMFs 分量;  $c_{ij}$  —— 第  $i$  次加入高斯白噪声时分解的第  $j$  个 IMFs 分量;  $N$  —— 加入高斯白噪声的总体个数。

### 1.4 独立分量分析法

独立分量分析(ICA)是一种新的基于统计分析的信号处理方法和盲源分离技术<sup>[11]</sup>, 广泛应用于含噪信号的盲源分离。该方法在分离信号方面不受强背景噪声的影响, 具有很好的应用前景。独立分量分析的基本原理为从观测信号出发, 利用信号的高阶统计特性, 对多个观测信号进行盲源分离, 从而获得互相独立的原始信号近似值。其中, 由 Zarzoso 等<sup>[19]</sup>于 2010 年提出的基于峭度和最优步长的 RobustICA 在盲源分离的算法中得到迅速发展。

但 ICA 算法要求观测信号的个数大于源信号的个数,这在一定程度上限制了 ICA 的应用<sup>[20]</sup>。

#### 1.4.1 ICA 模型

假设有  $n$  个独立源信号  $S=[S_1, S_2, \dots, S_n]^T$ , 观测信号  $X=AS$  为  $m \times n$  维信号, 其中  $A$  为  $m$  维混合信号矩阵。独立分量分析是在  $A$  和  $S$  均未知的条件下, 由式  $Y=WX$  得到输出估计信号  $Y=[Y_1, Y_2, \dots, Y_n]^T$ , 其中  $Y$  是源信号  $S$  的最优估计,  $W$  是通过优化算法求解到的分解矩阵。整个 ICA 过程框图如图 1 所示。

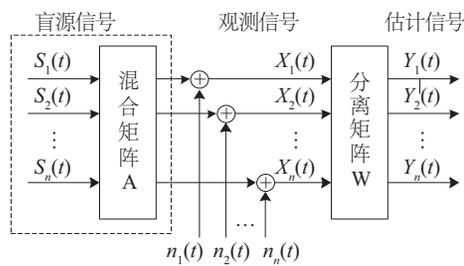


图1 独立分量分析框图

Fig. 1 Frame of independent component analysis

#### 1.4.2 RobustICA 算法

RobustICA 是通过峭度对照函数进行最佳步长的搜索, 找到解混矩阵  $W$ , 计算出源信号的近似值<sup>[20]</sup>。在统计学中, 峭度是表征一个随机变量非高斯性最简单的指标。ICA 的最终目的是得到分离矩阵  $W$ , 由公式  $Y=WX$  可知, 分离矩阵  $W$  中的每一个分离向量都对应着不同的输出估计信号。

因此可把峭度表示成一个分离向量  $\omega$  的函数:

$$\kappa(\omega) = \frac{E\{|y|^4\} - 2E^2\{|y|^2\} - |E\{y^2\}|^2}{E^2\{|y|^2\}} \quad (6)$$

最佳线性优化步长  $\mu_{opt}$  的计算公式为:

$$\mu_{opt} = \arg_{\mu} \max |\kappa(\omega + \mu g)| \quad (7)$$

典型的搜索方向为梯度  $g$  的方向, 其中:

$$g = \nabla_w \kappa(\omega) = \frac{4}{E^2\{|y|^2\}} \left\{ E\{|y|^2 y \cdot x\} - E\{yx\} E\{y^2\} - \left( E\{|y|^4\} - |E\{y^2\}|^2 \right) E\{y \cdot x\} / E\{|y|^2\} \right\} \quad (8)$$

式中,  $\kappa$  —— 峭度;  $E$  —— 数学期望;  $\mu$  —— 步长;  $\nabla_w$  —— 梯度;  $x, y$  —— 观测信号/估计信号。

峭度可表示成  $\mu$  的多项式或有理函数, 全局最优步长  $\mu_{opt}$  可通过寻找低级多项式的根来确定。所

以 RobustICA 基于这个思路, 在每一次迭代运算过程中采用以下步骤来执行全局最优步长的优化:

1) 计算最优步长多项式的系数

将峭度作为对照函数时, 最优步长多项式可表示为:

$$p(\mu) = \sum_{k=0}^4 a_k \mu^k \quad (9)$$

系数  $a_k (k=0, \dots, 4)$  可在每次迭代中通过观测信号和  $\omega$  与  $g$  的当前值获得。

2) 提取最优步长多项式的根  $\mu_k (k=1, \dots, 4)$ 。

3) 在搜索方向上选择使得峭度绝对值最大的根, 获取最优步长:

$$\mu_{opt} = \arg_{\mu} \max |\kappa(\omega + \mu g)| \quad (10)$$

4) 根据更新的步长  $\mu_{opt}$  值更新  $\omega^+$ :

$$\omega^+ = \omega + \mu_{opt} g \quad (11)$$

5) 对  $\omega^+$  进行标准化:  $\omega^+ \leftarrow \frac{\omega^+}{\|\omega^+\|}$

6) 判断迭代运算是否收敛, 若不满足则返回步骤 1)。

7) 进行下一个估计信号的提取。

算法细节参阅文献[19]。相比于 FastICA, RobustICA 减少了迭代次数, 加快了收敛速度, 极大地减少了运算量; RobustICA 提升了当信号存在坏点和伪局部极值时的鲁棒性; 在小样本空间下, 其均方误差 RMSE 也明显优于 FastICA 算法。

## 2 基于 EEMD-RobustICA 降噪的低频振荡 Prony 分析

EEMD 方法把复杂信号分解成有限个 IMF<sub>s</sub> 与一个残余信号之和, 即式(4)所示。其中 IMF<sub>s</sub> 需要满足 2 个条件: 1) 整个信号中的零点数目和极点数目相等或至多相差一个; 2) 由局部极大值点确定的极大值包络线和由局部极小值点确定的极小值包络线的均值为零, 及信号满足对时间轴的局部对称性。

EEMD 去噪方法的主要思想是对各个 IMF<sub>s</sub> 分量分别进行去噪处理, 然后累加处理后的所有 IMF<sub>s</sub> 以得到去噪后的信号。然而通过研究发现, 由于 IMF<sub>s</sub> 本身的特点, 如果直接使用小波阈值对 IMF<sub>s</sub> 进行去噪, 从原理上是错误的, 该方法忽略了 IMF<sub>s</sub> 的物理意义, 阈值处理后的分量不再满足 IMF<sub>s</sub> 定义, 破坏模态单元的完整性, 影响去噪效果<sup>[13]</sup>。

针对上述 EEMD 去噪方法的不足, 以及 EEMD

和 RobustICA 方法各自的优点, EEMD-RobustICA 结合 Prony 算法的思想: 本文利用 EEMD 自适应分解的优点, 将 EEMD 分解之后的 IMF<sub>s</sub> 作为 RobustICA 的输入, 利用 RobustICA 提取独立分量的优势, 进行盲源分离, 得到信噪比更高的独立分量, 这样不仅将噪声更加集中, 提高分量的信噪比, 而且此时再对独立分量进行软阈值去噪可避免直接对 IMF<sub>s</sub> 进行去噪, 改善去噪效果, 弥补经典 Prony 算法噪声抑制困难的缺点, 提高 Prony 算法的抗噪性能; 同时, 结合 Prony 算法直接提取信号特征参数的特点, 更加准确地辨识出观测信号中包含的关键振荡模式并计算其幅值、频率、衰减因子、阻尼比等参数。

具体实现步骤:

1) 利用 EEMD 自适应分解的特点对信号进行 EEMD 分解并提取得到 IMF<sub>s</sub>;

2) 将分解得到的 IMF<sub>s</sub> 整体作为 RobustICA 的输入进行盲源分离, 克服了 RobustICA 要求传感器数目大于等于源信号数目的限制, 利用 RobustICA 提取独立分量的优势得到独立分量和  $m$  维混合矩阵  $A$ , 在不损失信号的前提下, 提高分量的信噪比;

3) 利用软阈值法在信噪比较高条件下具有较好去噪效果的优点, 对各个独立分量自适应设置适当的阈值来消除噪声。根据公式  $X=AS$ , 将消噪后的独立分量与  $m$  维混合矩阵  $A$  相乘得到重构的 IMF<sub>s</sub>, 并将该 IMF<sub>s</sub> 相加得到去噪后信号波形, 弥补经典 Prony 算法对噪声敏感的缺点;

4) 对去噪后的信号从均方根误差 (RMSE)、信噪比 (SNR)、相关性系数 ( $R$ ) 这 3 个指标进行评价:

$$RMSE = \sqrt{\frac{1}{l} \sum_{i=1}^l (u'_i(i) - u_i(i))^2} \quad (12)$$

$$SNR = 10 \lg \left[ \frac{\sum_{j=1}^N u^2(j)}{\sum_{j=1}^N [u(j) - u'(j)]^2} \right] \quad (13)$$

$$R = \text{Cov}(u'_i, u_i) / (\delta_{u'_i} \delta_{u_i}) \quad (14)$$

式中,  $l$  —— 信号的总长度;  $u'_i$  —— 去噪后的信号;  $u_i$  —— 不含噪的原始参考信号;  $\text{Cov}(u'_i, u_i)$  ——  $u'_i$  与  $u_i$  的协方差;  $\delta_{u'_i}$ 、 $\delta_{u_i}$  ——  $u'_i$  与  $u_i$  的标准差。

5) 运用 Prony 算法辨识出低频振荡信号的幅值、频率、衰减因子、阻尼比。

### 3 算例分析

#### 3.1 算例 1

电力系统实际运行中, 低频振荡频率一般为

0.2~2.5 Hz。为验证本文所提方法的有效性, 首先构造一个不含噪声的振荡信号进行振荡模式提取的仿真分析。设置采样频率为 50 Hz, 采样点数为 1501。

构造理想振荡信号为:

$$S = 10e^{-0.2t} \cos(0.6\pi t) + 4e^{-0.1t} \cos(\pi t) + 1.5e^{-0.6t} \cos(2.6\pi t) + 0.5e^{-0.4t} \cos(5\pi t) \quad (15)$$

对理想振荡信号进行加噪处理, 得到加噪的信号  $S_1$ :

$$S_1 = 10e^{-0.2t} \cos(0.6\pi t) + 4e^{-0.1t} \cos(\pi t) + 1.5e^{-0.6t} \cos(2.6\pi t) + 0.5e^{-0.4t} \cos(5\pi t) + 0.5\text{rand}(1, 1501) \quad (16)$$

则得到理想振荡信号  $S$  波形和加噪后信号  $S_1$  的波形如图 2 所示。

直接对理想振荡信号  $S$  和含噪信号  $S_1$  进行 Prony 辨识, 得到的振荡模式如表 1 所示。将表 1 中的数据与模拟信号特征参数对比, 可看出 Prony 直接辨识理想振荡信号  $S$  能够准确得到关键振荡模式, 并能计算出相应的关键参数; 利用 Prony 算法直接对含噪信号  $S_1$  进行辨识, 频率基本准确, 但其他参数与实际值相比相差很大。所以 Prony 算法不能直接对含噪低频振荡信号进行辨识。

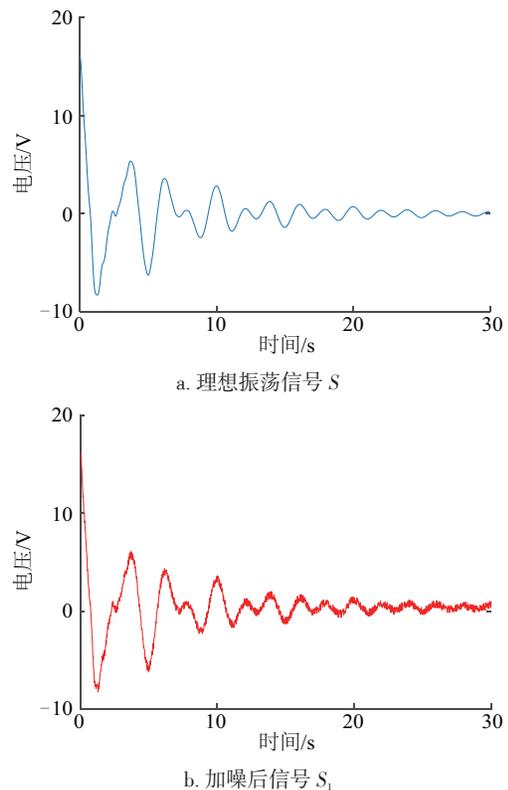


图 2 含理想信号  $S$  和噪信号  $S_1$  的振荡波形图  
Fig. 2 Oscillation waveform of ideal signal  $S$  & noisy signal  $S_1$

表1 Prony 法对理想信号  $S$  和含噪信号  $S_1$  辨识  
所得振荡模式

信号	模式	$f/\text{Hz}$	$R$	$\alpha_m$	$\zeta$
理想 信号 $S$	1 模式	0.3017	10.0 000	-0.2000	0.1049
	2 模式	0.5003	4.0000	-0.1000	0.0318
	3 模式	1.3035	1.5000	-0.6000	0.0731
	4 模式	2.5008	0.5000	-0.4000	0.0254
含噪 信号 $S_1$	1 模式	0.3151	15.7293	-0.4779	0.2347
	2 模式	0.5185	6.5200	-0.7034	0.2111
	3 模式	1.3382	3.5396	-1.0703	0.1263
	4 模式	2.5246	1.2207	-0.5680	0.0358

注:1)  $m$ —振荡模式编号; $f$ —频率; $R$ —幅值; $\alpha_m$ —衰减因子;  
 $\zeta$ —阻尼比;2)表3、表5同。

以下用本文所提的 EEMD-RobustICA 去噪算法与 Prony 算法相结合对低频振荡信号进行辨识。首先运用传统 EEMD 去噪算法对含噪信号  $S_1$  进行去噪,对去噪效果进行评价,再用 Prony 算法对去噪后信号进行辨识。对含噪信号  $S_1$  进行 EEMD 分解得到 IMF<sub>s</sub>,将得到的 IMF<sub>s</sub> 进行软阈值去噪得到新的 IMF<sub>s</sub>,如图3、图4所示。

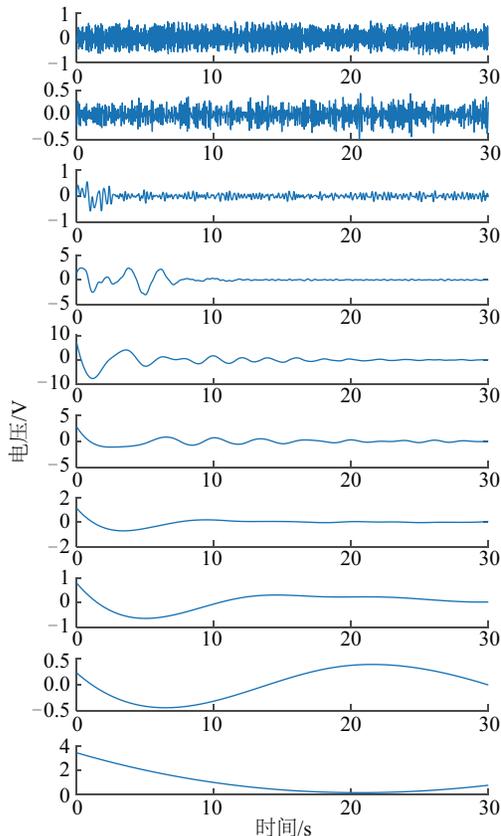


图3  $S_1$  经 EEMD 分解所得 IMF<sub>s</sub>

Fig. 3 IMF<sub>s</sub> obtained by EEMD of  $S_1$

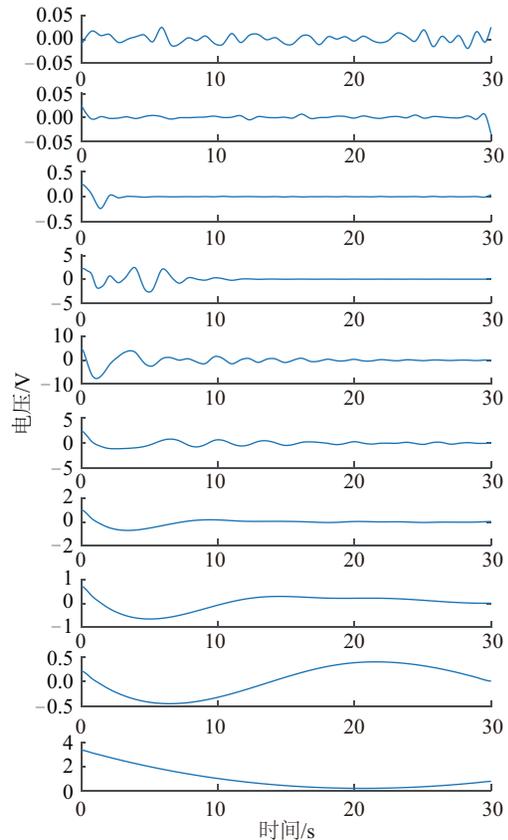


图4 IMF<sub>s</sub> 经软阈值去噪后的新的 IMF<sub>s</sub>

Fig. 4 New IMF<sub>s</sub> obtained by soft threshold denoising of IMF<sub>s</sub>

将去噪后的新的 IMF<sub>s</sub> 相加得到去噪后的信号,如图5所示。

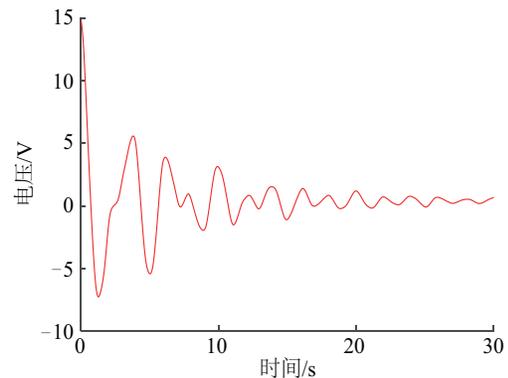


图5 传统 EEMD 法去噪后信号波形

Fig. 5 Signal after EEMD denoising

将去噪后的信号与原信号进行对比,如图6所示。

利用3种评价指标对传统 EEMD 算法的去噪效果进行评价,如表2所示。由表2可看出传统 EEMD 去噪后的信号与含噪信号  $S_1$  相比  $RMSE$  有

所减小,  $SNR$  有所增大,  $R$  有所增大, 即该方法有一定的去噪效果。

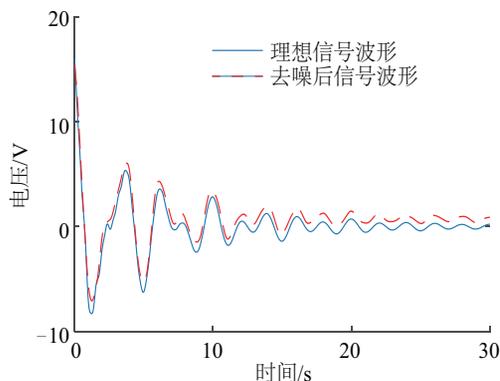


图6 理想信号  $S$  与去噪后信号对比图

Fig. 6 Comparison of the ideal signal  $S$  and denoising signal

表2 去噪效果对比

Table 2 Comparison of denoising effect

评价指标	含噪信号 $S_1$	传统 EEMD 去噪后信号
均方根误差 $RMSE$	0.2868	0.2539
信噪比 $SNR$	18.5862	19.6438
相关性系数 $R$	0.9982	0.9995

对传统 EEMD 法去噪后的信号进行 Prony 辨识, 所得振荡模式如表 3 所示。表 3 中 Prony 算法辨识所得的参数与表 1 中理想信号  $S$  的 Prony 辨识所得参数相比, 在幅值  $R$ 、衰减因子  $\alpha_m$ 、阻尼比  $\zeta$  等 3 个方面误差仍较大, 即传统 EEMD 去噪算法去噪效果不好。

表3 传统 EEMD 法去噪后信号的 Prony 辨识

Table 3 Prony identification of signal after denoising by traditional EEMD method

模式	$f/Hz$	$R$	$\alpha_m$	$\zeta$
1	0.3023	10.7850	-0.2395	0.1702
2	0.5055	5.7763	-0.2385	0.0339
3	1.3126	2.4188	-0.7399	0.0763
4	2.4807	0.7882	-0.4862	0.0504

下文用本文所提的 EEMD-RobustICA 算法与 Prony 算法相结合对含噪信号  $S_1$  进行辨识。对含噪信号  $S_1$  进行 EEMD 分解得到 IMFs, 将 IMFs 作为 RobustICA 的输入提取独立分量, 如图 7、图 8 所示。将独立分量进行软阈值去噪, 得到新的独立分量, 并将该组独立分量乘以混合矩阵  $A$ , 得到重构后的 IMFs, 如图 9、图 10 所示。

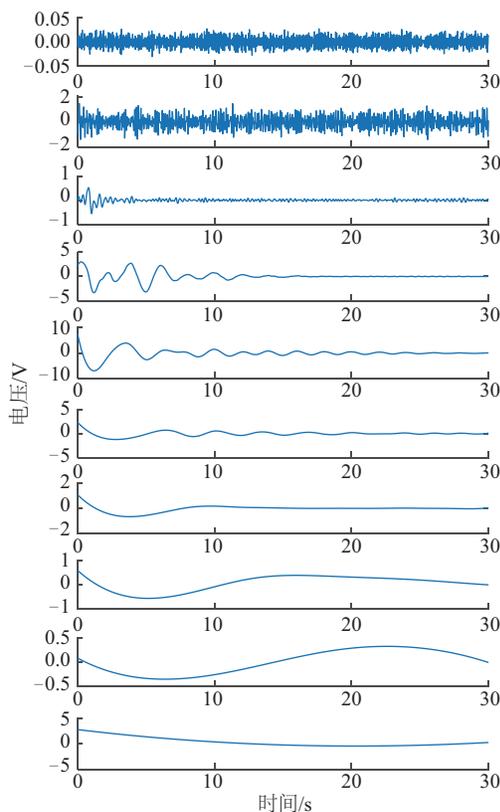


图7  $S_1$  经 EEMD 分解所得 IMFs

Fig. 7 IMFs obtained by EEMD of  $S_1$

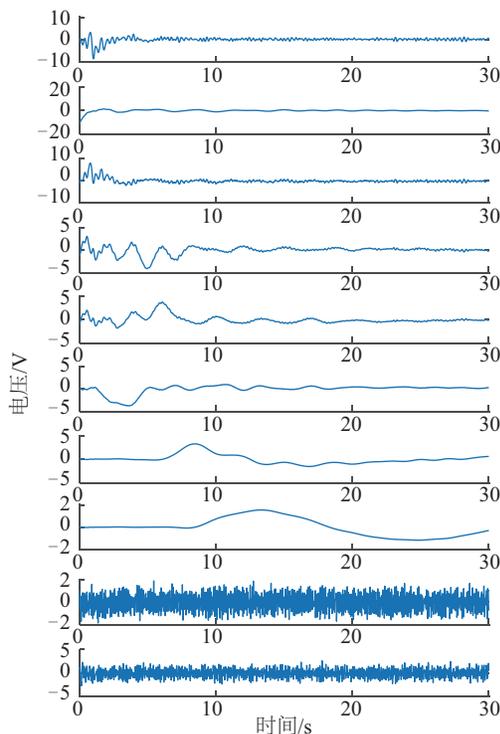


图8 RobustICA 分离出的独立分量

Fig. 8 Independent components separated by RobustICA

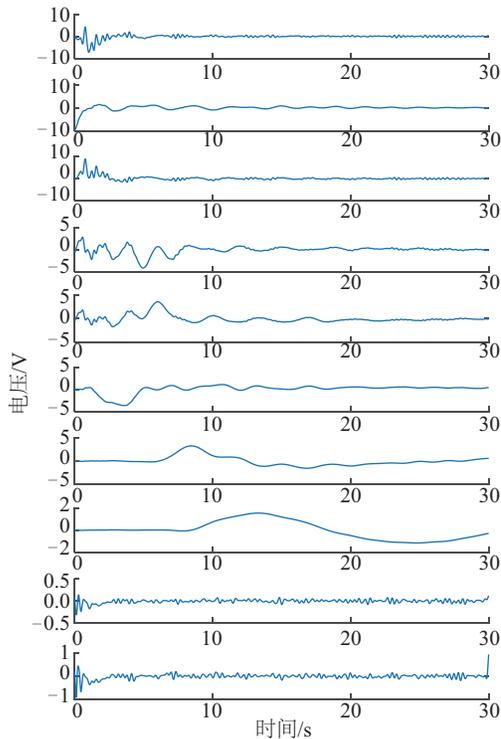


图9 软阈值去噪后的独立分量

Fig. 9 Independent components obtained by soft threshold denoising

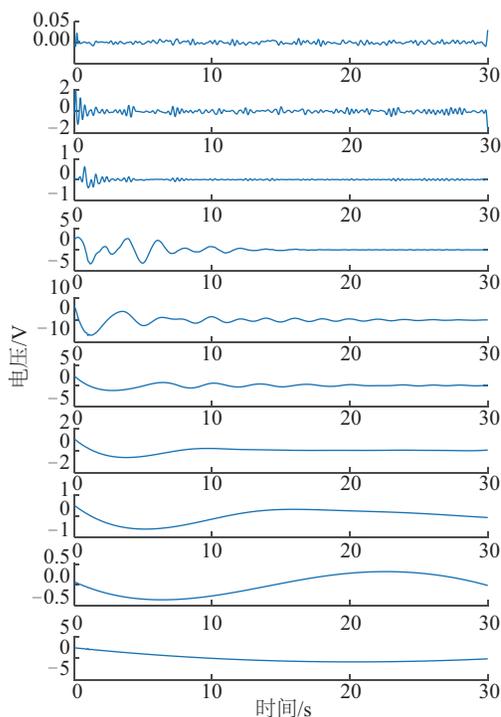


图10 重构后的IMFs

Fig. 10 Reconstructed IMFs

对比图7和图10可看重构后的各个IMFs与

图7中的各个IMFs相比曲线更加光滑,噪声更少,即重构后的IMFs中的噪声得到很好去除。

将重构后的IMFs相加得到去噪后的信号如图11所示,并与理想信号 $S$ 进行对比,如图12所示。

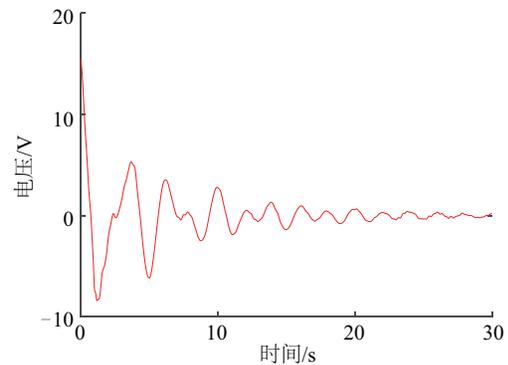


图11 EEMD-RobustICA法去噪后信号波形

Fig. 11 Signal after EEMD-RobustICA denoising

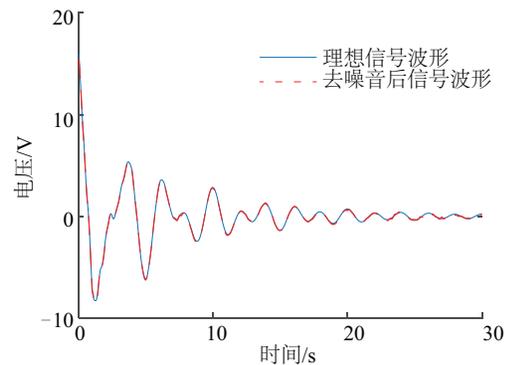


图12 理想原信号与去噪后信号对比

Fig. 12 Comparison of ideal signal and denoising signal

对EEMD-RobustICA算法的去噪效果利用3种评价指标进行评价,如表4所示。由表4看出,利用本文所提算法去噪后的信号与含噪信号 $S_1$ 相比 $RMSE$ 大幅度减小、 $SNR$ 大幅度增加、 $R$ 也有所增大,即本文提出的去噪算法去除了更多噪声。

表4 去噪效果对比

Table 4 Comparison of denoising effect

评价指标	含噪信号 $S_1$	EEMD-RobustICA去噪后信号
均方根误差 $RMSE$	0.2868	0.0674
信噪比 $SNR$	18.5862	31.1635
相关性系数 $R$	0.9982	0.9997

对 EEMD-RobustICA 法去噪后的信号进行 Prony 辨识, 所得振荡模式如表 5 所示。表 5 与表 1 参数对比可看出经 Prony 算法辨识后, 各低频振荡信号与模拟信号参数基本一致, 误差在允许范围内, 即 EEMD-RobustICA 算法去噪效果更好。

表 5 EEMD-RobustICA 法去噪后信号 Prony 辨识

Table 5 Identification of the traditional EEMD-RobustICA signal denoised by Prony algorithm

模式	$f/\text{Hz}$	$R$	$\alpha_m$	$\zeta$
1	0.3015	9.9211	-0.1995	0.1047
2	0.5014	4.1308	-0.1075	0.0341
3	1.3131	1.5463	-0.6145	0.0743
4	2.5051	0.4924	-0.4285	0.0272

对比以上仿真结果表明, 直接 Prony 辨识对噪声敏感, 所得参数误差较大; 传统 EEMD 去噪方法可在一定程度上去除部分噪声, 但 Prony 辨识后的参数仍有很大误差, 去噪效果不理想; 本文提出的 EEMD-RobustICA 与 Prony 结合方法, 在最大程度保留有用信号的同时有效去除大部分噪声且辨识精度较高, 去噪效果良好。综合以上分析, 证明该方法能够更好去除噪声且更加准确地辨识出低频振荡信号中的关键振荡模式。

### 3.2 算例 2

为了对低频振荡信号进行分析, 采用 IEEE 的四机两区域系统进行仿真, 该系统的电气接线图如图 13 所示, 具体参数见文献[1]。

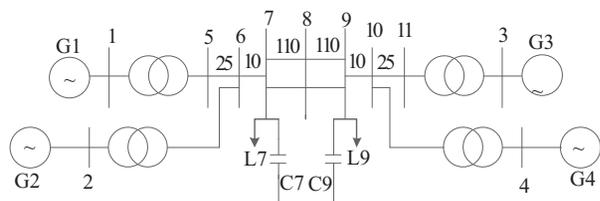


图 13 四机两区域电气接线图

Fig. 13 Four-machine two-area electrical wiring diagram

系统参数设置为在系统正常运行条件下, 模拟系统受到扰动, 在 2 s 时在节点 8 处发生三相短路故障, 在 2.5 s 时刻故障切除。采集区域二的发电机 G3 输出的有功功率的振荡曲线作为分析信号。采集 5~15 s 的数据作为分析数据。由于仿真环境比较理想, 实测信号在仿真过程中加入高斯白噪声进行模拟, 如图 14、图 15 所示。

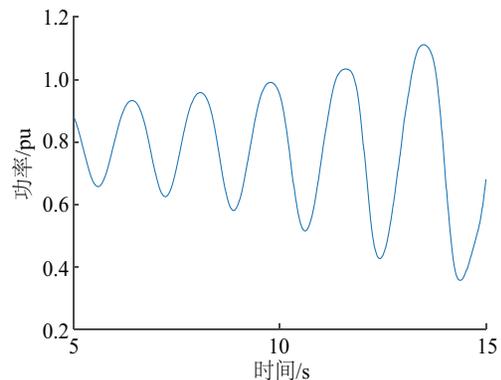


图 14 发电机 G3 的有功功率信号波形

Fig. 14 Active power signal waveform of generator G3

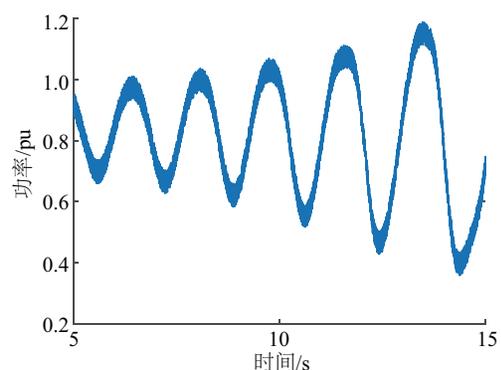


图 15 含白噪声的有功功率信号波形

Fig. 15 Active power signal waveform with white noise

然后用传统 EEMD 去噪法和 EEMD-RobustICA 法得到去噪后信号, 并与原信号的对比如图 16、图 17 所示。

对传统 EEMD 算法以及 EEMD-RobustICA 算法的去噪效果利用 3 种评价指标进行评价, 如表 6 所示。由表 6 可知 EEMD-RobustICA 法去噪后的信

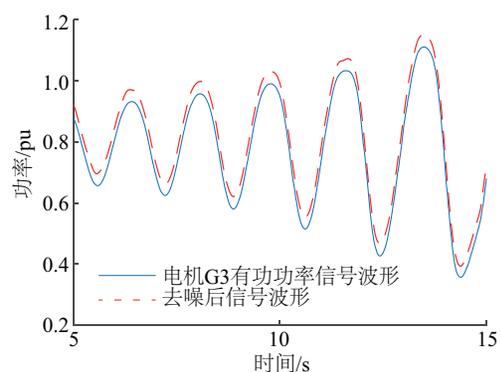


图 16 传统 EEMD 法去噪信号与有功功率信号波形

Fig. 16 Signal denoising by traditional EEMD and active power signal waveform

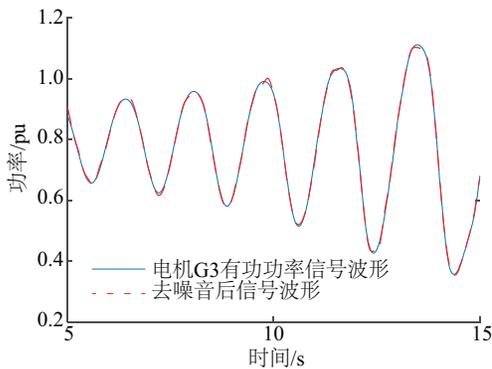


图 17 EEMD-RobustICA 法去噪信号与有功功率信号波形

Fig. 17 Signal denoising by EEMD-RobustICA and active power signal waveform

号与传统 EEMD 法去噪后的信号相比,均方根误差  $RMSE$  更小、信噪比  $SNR$  更大、相关性系数  $R$  也较大,效果优于传统 EEMD 去噪算法。

表 7 低频振荡辨识结果对比

Table 7 Comparison of low frequency oscillation identification results

原始 Prony 法		传统 EEMD 去噪法		EEMD-RobustICA 法		特征根分析法	
$f/\text{Hz}$	$\zeta$	$f/\text{Hz}$	$\zeta$	$f/\text{Hz}$	$\zeta$	$f/\text{Hz}$	$\zeta$
0.6865	0.2535	0.6164	-0.0070	0.6503	-0.0281	0.64	-0.026
—	—	—	—	1.1441	0.0846	1.12	0.080

综上所述,EEMD-RobustICA 与 Prony 有机结合的低频振荡辨识方法是正确有效的。

## 4 结论

1) 本文针对经典 Prony 法不能准确辨识噪声信号的缺点,提出了 EEMD-RobustICA 去噪法,该方法将 EEMD 法基于信号自身特征进行分解,不需要预先定义基函数,也无需信号先验知识,具有很好自适应性的优点和 RobustICA 具有良好抗噪性,能够提取独立分量的优势进行了融合,算法简单易实现,抗干扰能力强,去噪效果良好。

2) EEMD-RobustICA 去噪法避免了传统 EEMD 法中直接对 IMF<sub>s</sub> 进行阈值去噪,保持了 IMF<sub>s</sub> 的完整性,效果明显优于传统的 EEMD 法,为后续精确辨识提供了保证。

3) EEMD-RobustICA 和 Prony 结合,弥补了经典 Prony 算法对噪声敏感的缺点,能够准确提取出振荡信号中的关键模式,为低频振荡的抑制提供了数

表 6 传统 EEMD 法与 EEMD-RobustICA 法去噪果对比

Table 6 Comparison of denoising effect between traditional EEMD method and EEMD-RobustICA method

评价指标	含噪信号	传统 EEMD 法去噪后信号	EEMD-RobustICA 法去噪后信号
均方根误差 $RMSE$	0.115	0.0996	0.005
信噪比 $SNR$	16.765	18.0109	43.9317
相关性系数 $R$	0.9578	0.9995	0.9997

由表 7 可知,原始 Prony 法没有辨识出 0.54 Hz 振荡模式,并且辨识到的振荡模式在阻尼比上存在较大误差;传统 EEMD 与 Prony 结合的方法,也没有辨识出 0.54 Hz 的振荡模式,且辨识到的模式在阻尼比上仍旧存在着较大误差;本文的方法不但准确辨识出振荡模态,而且有效提升了各振荡模态的频率和阻尼比等参数的精度,进一步提高了辨识的精确度。

据依据。

因此本文提出的 EEMD-RobustICA 与 Prony 算法相结合的电网低频振荡模式分析方法是正确有效的,可用于辅助 PSS 配置和直流调制等电力系统低频振荡抑制工作。

## [参考文献]

- [1] Kundur P. Power system stability and control [M]. McGraw-Hill Education, 1994.
- [2] 倪以信. 动态电力系统的理论和分析[M]. 北京: 清华大学出版社, 2002.
- [2] Ni Yixin. The theory and analysis of dynamic power system [M]. Beijing: Tsinghua University Press, 2002.
- [3] Mao Xiaoming, Zhang Yao, Lin Guan, et al. Coordinated control of interarea oscillation in the China southern power grid[J]. IEEE Transactions on Power Systems, 2006, 21(2): 845—852.
- [4] Poon K K-P, Lee K-C. Analysis of transient stability swings in large interconnected power systems by Fourier

- transformation[J]. IEEE Transactions on Power Systems, 1988, 3(4): 1573—1581.
- [5] Rueda J L, Juarez C A, Erlich I. Wavelet- based analysis of power system low-frequency electromechanical oscillations [J]. IEEE Transactions on Power Systems, 2011, 26(3): 1733—1743.
- [6] Sanchez-Gasca J J, Chow J H. Performance comparison of three identification methods for the analysis of electromechanical oscillations[J]. IEEE Transactions on Power Systems, 1999, 14(3): 995—1002.
- [7] Han Song, Sun Bin, Wu Cheng, et al. Dynamic characteristic analysis of power system low frequency oscillation using Hilbert- Huang transform [A]. Power Systems Conference and Exposition (PSCE' 09). [C]. Seattle, WA, USA, 2009.
- [8] 胡昊明, 郑伟, 徐伟, 等. Prony和HHT算法在低频振荡在线辨识中的适用性比较[J]. 电力系统保护与控制, 2013, 41(14): 33—40.
- [8] Hu Haoming, Zheng Wei, Xu Wei, et al. Comparison of Prony and HHT algorithm for online identification of low frequency oscillation[J]. Power System Protection and Control, 2013, 41(14): 33—40.
- [9] 吴超, 曹广忠. 基于随机减量技术和Prony方法的低频振荡类噪声辨识[J]. 电力系统自动化, 2013, 37(8): 53—58.
- [9] Wu Chao, Cao Guangzhong. Identification of low frequency oscillation noise based on random decrement technique and Prony method[J]. Automation of Electric Power Systems, 2013, 37(8): 53—58.
- [10] 贾瑞生, 赵同彬, 孙红梅, 等. 基于经验模态分解及独立成分分析的微震信号降噪方法[J]. 地球物理学报, 2015, 58(3): 1013—1023.
- [10] Jia Ruisheng, Zhao Tongbin, Sun Hongmei, et al. Noise reduction method based on empirical mode decomposition and independent component analysis[J]. Chinese Journal of Geophysics, 2015, 58(3): 1013—1023.
- [11] 朱文龙, 周建中, 肖剑, 等. 独立分量分析-经验模态分解特征提取在水电机组振动信号中的应用[J]. 中国电机工程学报, 2013, 33(29): 95—101.
- [11] Zhu Wenlong, Zhou Jianzhong, Xiao Jian, et al. Application of independent component analysis empirical mode decomposition feature extraction in vibration signal of hydroelectric generating set[J]. Proceeding of the CSEE, 2013, 33(29): 95—101.
- [12] 侯高雁, 吕勇, 肖涵, 等. 基于EEMD自适应形态学在齿轮故障诊断中的应用[J]. 振动与冲击, 2014, 33(18): 145—148.
- [12] Hou Gaoyan, Lyu Yong, Xiao Han, et al. Application of EEMD adaptive morphology in gear fault diagnosis [J]. Journal of Vibration and Shock, 2014, 33(18): 145—148.
- [13] 吴微. 含噪盲源分离算法研究及其在水声信号中的应用[D]. 郑州: 解放军信息工程大学, 2014.
- [13] Wu Wei. Study on noise source blind source separation algorithm and its application in underwater acoustic signals[D]. Zhengzhou: PLA Information Engineering University, 2014.
- [14] Zhao F, Wang S J J, Si J. Analysis of power system low frequency oscillation mode based on improved fastica and prony algorithm[J]. International Journal of Electrical Engineering, 2015, DOI: 10.6329/CIEE.2015.5.03.
- [15] Trudnowski D J, Johnson J M, Hauer J F. Making Prony analysis more accurate using multiple signals[J]. IEEE Transactions on Power Systems, 1999, 14(1): 226—231.
- [16] 苟北, 陈陈. Prony算法在电力系统负荷动态模型辨识中的应用研究[J]. 电力系统自动化, 1997, 21(1): 21—24.
- [16] Gou Bei, Chen Chen. Application of prony algorithm in power system dynamic model identification [J]. Power System Automation, 1997, 21(1): 21—24.
- [17] 张超, 陈建军. EEMD方法和EMD方法抗模态混叠对比研究[J]. 振动与冲击, 2010, 29(sup1): 87—89.
- [17] Zhang Chao, Chen Jianjun. Comparison of anti- modal aliasing of EEMD method and EMD method[J]. Journal of Vibration and Shock, 2010, 29(sup1): 87—89.
- [18] 朱宁辉, 白晓民, 董伟杰. 基于EEMD的谐波检测方法[J]. 中国电机工程学报, 2013, 33(7): 92—98.
- [18] Zhu Ninghui, Bai Xiaomin, Dong Weijie. High harmonic detection method based on EEMD [J]. Proceeding of the CSEE, 2013, 33(7): 92—98.
- [19] Zarzoso V, Comon P. Robust independent component analysis by iterative maximization of the kurtosis contrast with algebraic optimal step size[J]. IEEE Transactions on Neural Networks, 2010, 21(2): 248—261.
- [20] 于宏志. 柴油机声源信号识别中的EMD-RobustICA融合方法及应用[D]. 昆明: 昆明理工大学, 2013.
- [20] Yu Hongzhi. EMD- RobustICA fusion method and its application in diesel engine sound source signal

- identification[D]. Kunming: Kunming University of Science and Technology, 2013.
- [21] 欧阳森, 宋政湘, 陈德桂, 等. 小波软阈值去噪技术在电能质量检测中的应用[J]. 电力系统自动化, 2002, 26(19): 56—60.
- [21] Ouyang Sen, Song Zhengxiang, Chen Degui, et al. Application of wavelet soft threshold denoising technology in power quality detection[J]. Power System Automation, 2002, 26 (19): 56—60.
- [22] Donoho D L. De-noising by soft-thresholding[J]. IEEE Transactions on Information Theory, 1995, 41 (3) : 613—627.

## APPLICATION OF EEMD-ROBUSTICA AND PRONY ALGORITHM IN MODES IDENTIFICATION OF POWER SYSTEM LOW FREQUENCY OSCILLATION

Zhao Feng<sup>1,2</sup>, Wu Mengdi<sup>1</sup>

(1. College of Electrical Engineering and Automation, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. Key Laboratory of Optoelectronic Technology and Intelligent Control, Ministry of Education, Lanzhou Jiaotong University, Lanzhou 730070, China)

**Abstract:** For the issue of Prony algorithm being sensitive to noise in low frequency oscillation identification of interconnected power grid, a method with the combination of Prony based on Ensemble Empirical Mode Decomposition (EEMD) and Robust Independent Component Analysis (RobustICA) is applied to the identification of oscillation mode. Intrinsic Mode Function (IMF) obtained by EEMD of the signal to be processed is taken as the input of RobustICA algorithm. Meanwhile the achieved independent components is processed by soft-threshold denoising method to attain reconstructed IMFs, which is added up to acquire denoised signal to be identified with Prony algorithm before getting mode parameters of low-frequency from the denoised signal. It is concluded from the simulation results that this method utilizes self-adaptive advantage of EEMD with non-rely on prior knowledge and complete data driving, and also takes the advantages of RobustICA of extracting independent component and keeping component signal integrity. Compared with traditional EEMD denoising algorithm, this method not only enhances signal-to-noise ratio of each component signal under the premise of no signal loss, overcomes the defect of Prony algorithm being sensitive to noise, but also eliminates noise to a large extent, helps to improve precision and accuracy of identification, and meet practical requirements of application as better as possible.

**Keywords:** ensemble empirical mode decomposition; robust independent component analysis; Prony algorithm; low-frequency oscillation; modes identification