

基于类噪声数据的电力系统低频振荡模态参数辨识

闫红艳^{1,2}, Hwang Jin Kwon², 高艳丰^{1*}

(1. 河北工程大学水利水电学院, 河北省 邯郸市 056038;

2. 韩国又石大学能源工程系, 韩国 镇川 365-803)

Modal Parameter Identification of Low Frequency Oscillation in Power System Based on Ambient Data

YAN Hongyan^{1,2}, HWANG Jin Kwon², GAO Yanfeng^{1*}

(1. School of Water Conservancy and Hydroelectric Power, Hebei University of Engineering, Handan 056038, Hebei Province, China; 2. Department of Energy Engineering, Woosuk University, Jinchon-gun 365-803, Republic of Korea)

摘要: 低频振荡是影响互联电力系统安全稳定运行的关键问题之一, 提出采用变分模态分解(variational mode decomposition, VMD)提取类噪声数据的低频振荡信号, 基于离散傅里叶变换(discrete Fourier transform, DFT)曲线拟合的电力系统低频振荡模态辨识方法。首先, 采用VMD分解滤除类噪声数据信号中的直流分量, 提取出低频振荡信号, 利用模态相关系数确定VMD分解个数, 提高了信号分解的时效性; 其次, 建立类噪声数据自回归滑动平均(auto regressive moving average, ARMA)数学模型, 模拟产生数据信号, 利用低频振荡信号自相关函数的DFT曲线拟合估计拉普拉斯变换系数, 提取机电振荡特征参数; 最后, 采用模拟数据和某实测相量测量单元数据验证了该方法的可行性和有效性。试验表明, 采用VMD算法和基于DFT的曲线拟合法提取低频振荡特征参数, 有效提高了机电小干扰稳定评估的实时性。

关键词: 低频振荡; 类噪声数据; 自回归滑动平均(ARMA)模型; 变分模态分解(VMD); 离散傅里叶变换(DFT)曲线拟合

ABSTRACT: Low frequency oscillation is one of the key problem affecting the safe and stable operation of interconnected power system, variational modal decomposition (VMD) was used to extract low-frequency oscillation signals from ambient data, and a method of low-frequency oscillation modal identification for power systems discrete Fourier transform (DFT)-based curve fitting was proposed in this paper. Firstly, the

DC component of ambient data signals was filtered by VMD decomposition to extract low-frequency oscillation signals. The number of VMD decomposition was determined by modal correlation coefficient, which improved the timeliness of signal decomposition. Secondly, the auto regressive moving average (ARMA) model of ambient data was established to simulate the generation of data signals. The DFT curve fitting of low-frequency oscillation signal autocorrelation function was used to estimate the Laplace transform coefficient and extract characteristic parameters of electromechanical oscillation. Finally, Simulation data and some measured phasor measurement unit (PMU) data are used to verify the feasibility and effectiveness of the method. The experiment shows that the sampling VMD algorithm and the curve fitting method based on DFT can extract the characteristic parameters of low-frequency oscillation, which effectively improves the real-time performance of electromechanical small interference stability.

KEY WORDS: low frequency oscillation; ambient data; auto regressive moving average (ARMA) model; variational modal decomposition (VMD); discrete Fourier transform (DFT) curve-fitting

0 引言

随着电网远距离、大容量输电的实施, 高放大倍数励磁装置的使用以及大规模新能源的接入, 低频振荡时有发生, 频率范围一般为0.1~2.5 Hz^[1], 严重危害到系统正常运行。低频振荡模态识别是分析低频振荡产生原因的基础, 也是实现电力系统实时高效控制和风险预警的关键

基金项目: 河北省社会科学发展研究课题(20210201316); 河北省高等学校科学技术研究项目(ZD2021021)。

Project Supported by Social Science Development Research Project of Hebei Province (20210201316); Science and Technology Research Project of Higher Education of Hebei Province (ZD2021021).

之一^[2-5]。

基于相量测量单元(phasor measurement unit, PMU)的电力系统广域测量系统(wide area monitoring systems, WAMS)能够实时地记录电力系统的动态行为,按照量测信号的辨识方法可分为基于大扰动后自由振荡响应信号的方法和基于环境激励下随机响应信号的方法^[6-10]。大扰动数据包含强低频振荡分量,能够准确识别区域间模式,但这类事件很少发生,很难进行连续的模态识别。相反,负荷随机波动引起的小扰动激励(又称类噪声数据)时刻存在、易于采集、数据丰富,可及时准确地反映当前系统的运行特性^[11]。Prony算法及其改进算法在分析大扰动激励下的响应信号应用较广泛,但Prony算法在处理噪声信号和具有时变特性非平稳信号的能力不理想^[12-13]。基于环境激励下随机响应信号的方法大多在信号的自回归(auto regressive, AR)模型^[10]或自回归滑动平均(auto regressive moving average, ARMA)模型上发展起来的^[14-16]。文献[17-18]采用最小二乘法求取电力系统随机响应信号AR模型的最优参数,进而获得低频振荡的频率和阻尼比信息,但是该算法存在数值不稳定的问题。文献[19]提出了用Yule-Walker方程解AR模型的功率谱分析方法;文献[20]提出了一种基于数学形态学自回归移动平均(mathematical morphology, MM-ARMA)算法的辨识方法。文献[21]采用Bootstrap法确定YW法辨识结果的置信区间。改进扩展的Yule-Walker(modified extended Yule-Walker, MEYW)方法^[22]广泛用于基于环境数据自相关函数的AR模型中,但AR模型的阶数较难确定,存在2个频率相近的振荡模式无法区分辨识的现象。

随机子空间方法(stochastic subspace identification, SSI)从原理上既适用于自由振荡信号分析,也适用于由环境激励引起的系统随机响应信号分析,抗噪性强,模态识别结果较准确,但计算速度较慢,很难反映信号的时变特性^[7,23]。低频振荡产生的直流分量会降低模态识别的准确性,上述方法在使用过程中数据均需进行去除直流预处理。希尔伯特-黄变换(Hilbert-Huang

transform, HHT)算法是分析非线性、非平稳功率振荡的常用工具,虽然能分解出直流分量,但存在端点效应现象^[24]和本征模函数筛选效果不理想等固有缺点,辨识结果误差率较大。文献[25]提出集合经验模态分解(ensemble empirical mode decomposition, EEMD)算法,但该算法存在计算复杂、耗时长等问题。

变分模态分解(variational mode decomposition, VMD)是一种新的非递归的信号分解方法,除了能滤除直流外,还能克服经验模态分解(empirical mode decomposition, EMD)和EEMD方法的缺陷,噪声鲁棒性较好。本文采用基于模态相关系数的VMD进行类噪声数据处理,直接去除中心频率为0的直流部分并分离出低频振荡信号;低频振荡信号模态参数辨识利用信号频率差序列的自相关函数表示为与低频振荡函数形式一样的指数衰减正弦函数的线性组合,该函数的固有频率和阻尼比等于振荡模态的固有频率和阻尼比,用不同时间频率数据之间的差序列减少测量噪声的影响。通过在频域中峰值频率附近的离散傅里叶变换(discrete Fourier transform, DFT)进行曲线拟合来估计其拉普拉斯变换系数,然后计算得出模态分量的参数。通过与MEYW方法的识别结果相比较,验证了所提识别方法的准确性。最后,采用基于ARMA模型产生PMU频率数据和某实际系统的实测频率数据验证方法的可行性和有效性。

1 改进的变分模态分解方法

1.1 VMD原理

VMD是Dragomiretskiy提出的非递归信号分解方法,实质是变分问题,根据预设模态分量个数对信号进行分解^[26]。该方法通过一个自适应维纳滤波器组将原始信号 $f(x)$ 分解为 K 个中心频率为 ω_k 的模态函数 u_k ,其中 K 为预设模态分量个数。VMD算法在抗噪声和非平稳信号处理方面具有较好的性能和较高的运算效率,可以分解出直流分量。

为了得到具有一定带宽频率的 K 个模态分量,通常对每个模态函数 u_k 进行Hilbert变换得到边

际谱:

$$[\delta(t) + \frac{j}{\pi t}] * u_k(t) \quad (1)$$

式中: $\delta(t)$ 为狄利克雷函数; $j^2=-1$; *为卷积符号。预估各模态解析信号中心频率,将每个模态的频谱调制到相应的基频带:

$$[\delta(t) + \frac{j}{\pi t}] u_k(t) * e^{-j\omega_k t} \quad (2)$$

计算解析信号梯度的平方(L^2)范数,估计出各模态的信号带宽,受约束的变分问题可以表示如下:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_k u_k = f(t) \end{cases} \quad (3)$$

式中: $\{u_k\} = \{u_1, \dots, u_K\}$ 为分解得到的 K 个模态分量; $\{\omega_k\} = \{\omega_1, \dots, \omega_K\}$ 为各分量的频率中心。

受约束的变分问题求解,可引入二次惩罚因子 α 和拉格朗日乘法算子 $\lambda(t)$,得到增广拉格朗日公式:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + [\lambda(t), f(t) - \sum_k u_k(t)] \quad (4)$$

求解得:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (5)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (6)$$

拉格朗日乘法算子 λ :

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau [\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}] \quad (7)$$

利用乘法算子交替方向法求取式(6)变分问题,通过交替更新 u_k^{n+1} 、 ω_k^{n+1} 和 λ^{n+1} 寻求增广拉格朗日表达式的鞍点。式(5)为约束变分模型的最优解,从而将 f 分解为 K 个窄带IMF分量。VMD算法的具体过程如下:

- 1) 初始化 $\{u_k^1\}$, $\{\omega_k^1\}$, $\hat{\lambda}_1$, $n=0$;
- 2) $n=n+1$, 执行迭代循环;

3) 使 $k=k+1$,按照式(5)与式(6)更新 \hat{u}_k^{n+1} 与 ω_k^{n+1} ,直至 $k=K$;

4) 按照式(7)更新 $\hat{\lambda}^{n+1}$;

5) 当满足给定的判别精度 $\varepsilon > 0$, $\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \varepsilon$ 时,则停止迭代,否则重复步骤2) — 5)。

1.2 基于相关系数的模态个数设定

VMD本身不具有自适应性,模态分解数 K 值的设置是信号VMD分解的关键环节,对分解效果影响较大。 K 设定值大于待分解信号所含的固有模态(intrinsic mode function, IMF)分量个数,则会在最终结果中引入虚假模态分量,影响对原始低频振荡信号的分析;相反, K 设定值过小,则将导致信号分解不完全,即振荡信号中含有的重要模态没有被完全分解出来。

本文利用模态分量的相关系数来确定VMD分解个数的方法。首先取 K 值为2,计算各个分量之间的相关系数,判断各分量之间是否存在频率混叠现象,自适应确定模态个数。分量 $x_1(n)$ 和分量 $x_2(n)$ 的相关系数定义为

$$\rho_{x_1, x_2} = \frac{\sum_{n=0}^{\infty} x_1(n)x_2(n)}{[\sum_{n=0}^{\infty} x_1^2(n) \sum_{n=0}^{\infty} x_2^2(n)]^{1/2}} \quad (8)$$

基于模态相关系数的VMD算法具体步骤如下:

- 1) 初始化 $K=2$,并用VMD算法处理原始信号;
- 2) 计算各个模态分量之间的相关系数,提取其中最大的相关系数;
- 3) $K \rightarrow K+1$,并根据步骤2)更新模态之间的最大相关系数;
- 4) 重复步骤3),直到最大相关系数超过阈值。经过大量实验分析,最大相关系数的阈值选取0.1较为合适^[27]。

根据文献[26],当惩罚参数 $\alpha=2000$ 时,它可以满足大多数工作条件的实际需求。试验表明,改变 α 时影响很小,因此取默认值,当存在直流分量时,DC=1,这意味着可以分解出中心频率为0的分量。本文首要任务是要滤除直流分量,所以DC取1,其余参数取默认值。

2 电网区域间低频振荡模态辨识

2.1 类噪声数据的ARMA模型

负荷的随机变化即使很小也会影响到供需之间的不平衡,通常将这种干扰看作高斯白噪声^[28],在电力系统类噪声数据中用直流分量 $d(t)$ 和低频振荡模式 $s(t)$ 表示。同时,考虑到WAMS数据中含有各种测量噪声 $w(t)$,因此,电力系统正常运行时,PMU数据的信号模型可表示为

$$y(t)=d(t)+s(t)+w(t) \quad (9)$$

随机激励数据需要考虑电力系统的等效惯量和负荷对频率的影响。在不考虑调节器或频率控制的情况下,产生直流分量 $d(t)$ 的行为近似为^[29]:

$$\frac{2J}{f_0} \dot{d}(t)+K_s d(t)=-u(t) \quad (10)$$

式中: J 为系统的惯性常数; f_0 为标称频率; K_s 为系统的功率/频率特性; $u(t)$ 为系统负载功率缺额的标么值。 $\dot{d}(t)$ 是频率波动引起的直流分量,即每日负荷波动时的功率缺额; $u(t)$ 是阶跃函数的总和,是负荷切换时间的函数^[30]。日常负荷随机变化被建模为环境频率数据中的白噪声,所以 $d(t)$ 以白噪声 $v(t)$ 为输入时表示为

$$\frac{2J}{f_0} \dot{d}(t)+K_s d(t)=v(t) \quad (11)$$

式中 $v(t)=-\dot{u}(t)$,随着 $v(t)$ 的强度变强,由于电力系统中的调速器或频率控制,随着时间的推移, $v(t)$ 的强度可能会逐渐不同于其实际值。

扰动 $v(t)$ 引起电力系统频率中的低频振荡 $s(t)$ 。振荡模式被表示为二阶微分方程^[31]。 K 个振荡信号可表示为

$$s(t)=\sum_{k=1}^K q_k(t) \quad (12)$$

$$\ddot{q}_k(t)+2\zeta_k\omega_k\dot{q}_k(t)+\omega_k^2q_k(t)=\gamma_k v(t) \quad (13)$$

式中: $q_k(t)$ 是第 k 个模态,其阻尼比为 ζ_k ;固有角频率 $\omega_k=2\pi f_k$ ($f_1 < f_2 < \dots < f_k$); γ_k 是第 k 个模态的输入参数。

则考虑测量噪声时,PMU的环境频率数据式(9)用离散数据可以表示为

$$y[n]=d[n]+s[n]+w[n] \quad (14)$$

式中: $w[n]$ 是测量噪声; $d[n]=d(nT_s)$; $s[n]=s(nT_s)$, T_s 是PMU的采样周期。测量噪声 $w[n]$ 可以看成白色高斯信号,其均值和方差分别是0和 σ^2 。 $y[n]$ 的

信噪比(signal noise ratio, SNR)定义为 $s[n]$ 与 $w[n]$ 的功率比。在模拟产生数据和模态识别时,可将式(11)和式(13)的连续时间方程转换为离散时间方程,用脉冲响应不变法^[32]进行转换,表示成ARMA模型为:

$$d[n]+\eta_1 d[n-1]+\eta_2 d[n-2]=\eta_3 v[n-1] \quad (15)$$

$$q_k[n]+\mu_{k,1} q_k[n-1]+\mu_{k,2} q_k[n-2]=\mu_{k,3} v[n-1] \quad (16)$$

式中: $v[n]=v(nT_s)$; $q_k[n]=q_k(nT_s)$ 。式(15)和(16)的系数分别为: $\eta_1=-(1+e^{-T_s/\tau_D})$, $\eta_2=e^{-T_s/\tau_D}$, $\eta_3=(1-e^{-T_s/\tau_D})/K_s$, $\mu_{k,1}=-2 \times e^{-\zeta_k \omega_k T_s} \cos(\bar{\omega}_k T_s)$, $\mu_{k,2}=e^{-2\zeta_k \omega_k T_s}$,

$$\mu_{k,3}=\frac{\gamma_k}{\bar{\omega}_k} \times e^{-\zeta_k \omega_k T_s} \sin(\bar{\omega}_k T_s), \quad \text{其中 } \tau_D=2J/(K_s f_0),$$

$\bar{\omega}_k=\omega_k \sqrt{1-\zeta_k^2}$, ARMA模型即可用程序模拟生成类似真实PMU的频率数据。

2.2 模态参数辨识

将原始频率信号 $y[n]$ 进行VMD分解,分离出中心频率为零的直流分量 $d[n]$,同时得到 $K-1$ 个有限带宽的固有本征模分量,根据其频率值可直接提取出含噪声的低频振荡分量 $s_w[n]$,再对该模态分量进行参数辨识即可得系统的振荡参数。含噪的低频振荡信号 $s_w[n]$ 的ARMA模型可以表示为

$$s_w[n]=s[n]+w[n]=-\sum_{k=1}^{2K} c_k s_w[n-k]+\sum_{k=1}^{2K-1} e_k u[n-k] \quad (17)$$

式中 c_k 和 e_k 分别为自回归部分和滑动平均部分模型参数。

由信号的自相关特性可知,自相关分析能有效消除信号中的噪声,且能保留原信号函数的频率特征^[33-34],随着时间的延长,噪声信号自相关函数值将很快衰减至0,因此,可以采用自相关函数代替原函数进行模态辨识。

故 $s_w[n]$ 的自相关函数可以表示为

$$r_w[m]=E\{s_w[n]s_w[n-m]\}=\frac{1}{N} \sum_{n=m}^{N-1} s_w[n]s_w[n-m], 0 \leq m < N \quad (18)$$

式中: m 为模态辨识时的时间窗; $E\{\cdot\}$ 是数学期望。由式(17)和式(18)可以得到 $r_w[m]$ 的ARMA模型为

$$r_w[m]=-\sum_{k=1}^{2K} c_k r_w[m-k], m \geq 2K \quad (19)$$

$r_w[m]$ 是与式(17)中的AR模型具有相同特征多

项式的线性预测模型^[34]。因此, $r_w[m]$ 的连续信号也可以表示为 K 个指数衰减正弦分量的线性组合, 表达式为

$$r(t) = \sum_{k=1}^K q_k(t) \quad (20)$$

$$q_k(t) = A_k e^{-\zeta_k \omega_k t} \cos(\omega_k \sqrt{1 - \zeta_k^2} t + \varphi_k), t \geq 0 \quad (21)$$

式中: A_k 和 φ_k 分别为第 k 个振荡模态的幅值和相角; $\omega_k = 2\pi f_k$ 为固有角频率。基于控制理论, 式(20)和式(21)通过拉普拉斯变换为

$$R(s) = \sum_{k=1}^K Q_k(s) \quad (22)$$

$$Q_k(s) = A_k \frac{(s + \zeta_k \omega_k) \sin \varphi_k - \omega_k \sqrt{1 - \zeta_k^2} \cos \varphi_k}{s^2 + 2\zeta_k \omega_k s + \omega_k^2} \quad (23)$$

$R(s)$ 可用系数 a_k 和 b_k 来表示, $k=1, 2, \dots, 2K$ 。

$$R(s) = \frac{b_1 s^{2K-1} + \dots + b_{2K-1} s + b_{2K}}{s^{2K} + a_1 s^{2K-1} + \dots + a_{2K-1} s + a_{2K}} \quad (24)$$

如果所有的系数 a_k 和 b_k 都已知, 那么 $R(s)$ 可以通过其极点因式分解。这样 $Q_k(s)$ 可以写成:

$$Q_k(s) = \frac{\beta_k}{s - \alpha_k} + \frac{\beta_k^*}{s - \alpha_k^*} \quad (25)$$

式中: α_k 和 α_k^* 是第 k 个模态的极点; *代表复数的共轭。这样式(23)中的第 k 个模态参数 $f_k = \omega_k / (2\pi)$, ζ_k , A_k 和 φ_k 可由 α_k 和 β_k 计算得到:

$$\begin{cases} f_k = |\alpha_k| / 2\pi \\ \zeta_k = -\text{Re}\{\alpha_k\} / \omega_k \\ A_k = \frac{2\text{Re}\{\beta_k\}}{\sin(\varphi_k)} \end{cases} \quad (26)$$

$$\varphi_k = \cot^{-1} \left[\frac{1}{\omega_k \sqrt{1 - \zeta_k^2}} \left(\frac{-\text{Re}\{\beta_k \alpha_k^*\}}{\text{Re}\{\alpha_k\}} - \zeta_k \omega_k \right) \right] \quad (27)$$

式中 $\text{Re}\{\cdot\}$ 代表复数的实数部分。

2.3 频域的曲线拟合过程

公式(19)自相关函数 $r_w[m]$ 进行DFT的结果为

$$R_w[m] = \sum_{n=0}^{M-1} r_w[n] e^{-j2\pi nm/M}, m=0, 1, \dots, M-1 \quad (28)$$

为了减少曲线拟合中的噪声影响和缩短计算时间, 希望在 f_k 附近使用 $R_w[m]$, f_k 是低频振荡模态功率最集中的地方。最好在以下频率范围上进行曲线拟合: $|\hat{f}_k - f| \leq f_c, k=1, 2, \dots, K$ 。

本文将 f_c 设为0.05 Hz, 其宽度足以包含每个峰值的频率范围。每一个峰值曲线拟合采样的最大整数小于 $2f_c / \Delta f$ 。角频率采样点表示为 $\omega_{k,m}$ 和

$\omega_{k,(m+1)} = \omega_{k,m} + 2\pi \Delta f$ 。 $m=1, 2, \dots, M$ 是第 K 个模态峰值的曲线拟合。

信号VMD分解后, 取低频振荡频率范围内IMF分量, 并对此分量做自相关计算, 按式(24)中 $R(s)$ 的系数 a_k 和 b_k 来辨识模式信号各参数的值。整个过程通过将 $R(s)$ 拟合到频域中的 $R[m]$ 中来实现。 $R(s)$ 在频域中可以表示为

$$R(j\omega) = \frac{b_1 (j\omega)^{2K-1} + \dots + b_{2K-1} (j\omega) + b_{2K}}{(j\omega)^{2K} + a_1 (j\omega)^{2K-1} + \dots + a_{2K-1} (j\omega) + a_{2K}} \quad (29)$$

为了用最小二乘法估计 a_k 和 b_k , 上述方程可以改写为

$$\begin{aligned} (j\omega)^{2K} &= -(j\omega)^{2K-1} a_1 - \dots - (j\omega) a_{2K-1} - a_{2K} + \\ &\frac{(j\omega)^{2K-1}}{Y(j\omega)} b_1 + \dots + \frac{(j\omega)}{Y(j\omega)} b_{2K-1} + \\ &\frac{b_{2K}}{Y(j\omega)} \end{aligned} \quad (30)$$

式(30)可以按等式两边实部和虚部分别相等表示为:

$$\begin{aligned} (-\omega^2)^K &= (-1)^{K-1} \omega^{2K-2} a_2 + \dots + (-1) a_{2K} + \\ &\text{Re} \left\{ \frac{(j\omega)^{2K-1}}{Y(j\omega)} \right\} b_1 + \dots + \end{aligned} \quad (31)$$

$$\text{Re} \left\{ \frac{(j\omega)}{Y(j\omega)} \right\} b_{2K-1} + \text{Re} \left\{ \frac{1}{Y(j\omega)} \right\} b_{2K}$$

$$0 = (-1)^K \omega^{2K-1} a_1 + \dots + (-1) \omega a_{2K-1} +$$

$$\text{Im} \left\{ \frac{(j\omega)^{2K-1}}{Y(j\omega)} \right\} b_1 + \dots + \quad (32)$$

$$\text{Im} \left\{ \frac{(j\omega)}{Y(j\omega)} \right\} b_{2K-1} + \text{Im} \left\{ \frac{1}{Y(j\omega)} \right\} b_{2K}$$

式中 $\text{Im}\{\cdot\}$ 代表复数的虚部。

$R(j\omega)$ 在 $\omega_{k,m}$ 处的曲线拟合可以用以下的矩阵形式来表示:

$$CX = D \quad (33)$$

$$\begin{cases} X = (a_1, a_2, \dots, a_{2K-1}, a_{2K}, b_1, b_2, \dots, b_{2K-1}, b_{2K})^T \\ C = (C_a, C_b) \end{cases} \quad (34)$$

式中:

$$C_a = \begin{bmatrix} 0 & (-1)^{K-1} \omega_{1,1}^{2K-2} & \dots & 0 & -1 \\ (-1)^{K-1} \omega_{1,2}^{2K-2} & 0 & \dots & -\omega_{1,1}^2 & 0 \\ 0 & (-1)^{K-1} \omega_{1,2}^{2K-2} & \dots & 0 & -1 \\ (-1)^K \omega_{1,2}^{2K-1} & 0 & \dots & -\omega_{1,2}^2 & 0 \\ \vdots & \vdots & & \vdots & \vdots \\ 0 & (-1)^{K-1} \omega_{K,M}^{2K-2} & \dots & 0 & -1 \\ (-1)^K \omega_{K,M}^{2K-1} & 0 & \dots & -\omega_{K,M}^2 & 0 \end{bmatrix}$$

$$C_b = \begin{bmatrix} \operatorname{Re}\left\{\frac{(j\omega_{1,1})^{2K-1}}{Y(j\omega_{1,1})}\right\} & \operatorname{Re}\left\{\frac{(j\omega_{1,1})^{2K-2}}{Y(j\omega_{1,1})}\right\} & \cdots & \operatorname{Re}\left\{\frac{1}{Y(j\omega_{1,1})}\right\} \\ \operatorname{Im}\left\{\frac{(j\omega_{1,1})^{2K-1}}{Y(j\omega_{1,1})}\right\} & \operatorname{Im}\left\{\frac{(j\omega_{1,1})^{2K-2}}{Y(j\omega_{1,1})}\right\} & \cdots & \operatorname{Im}\left\{\frac{1}{Y(j\omega_{1,1})}\right\} \\ \operatorname{Re}\left\{\frac{(j\omega_{1,2})^{2K-1}}{Y(j\omega_{1,2})}\right\} & \operatorname{Re}\left\{\frac{(j\omega_{1,2})^{2K-2}}{Y(j\omega_{1,2})}\right\} & \cdots & \operatorname{Re}\left\{\frac{1}{Y(j\omega_{1,2})}\right\} \\ \operatorname{Im}\left\{\frac{(j\omega_{1,2})^{2K-1}}{Y(j\omega_{1,2})}\right\} & \operatorname{Im}\left\{\frac{(j\omega_{1,2})^{2K-2}}{Y(j\omega_{1,2})}\right\} & \cdots & \operatorname{Im}\left\{\frac{1}{Y(j\omega_{1,2})}\right\} \\ \vdots & \vdots & \vdots & \vdots \\ \operatorname{Re}\left\{\frac{(j\omega_{K,M})^{2K-1}}{Y(j\omega_{K,M})}\right\} & \operatorname{Re}\left\{\frac{(j\omega_{K,M})^{2K-2}}{Y(j\omega_{K,M})}\right\} & \cdots & \operatorname{Re}\left\{\frac{1}{Y(j\omega_{K,M})}\right\} \\ \operatorname{Im}\left\{\frac{(j\omega_{K,M})^{2K-1}}{Y(j\omega_{K,M})}\right\} & \operatorname{Im}\left\{\frac{(j\omega_{K,M})^{2K-2}}{Y(j\omega_{K,M})}\right\} & \cdots & \operatorname{Im}\left\{\frac{1}{Y(j\omega_{K,M})}\right\} \end{bmatrix}$$

$$D = [(-\omega_{1,1}^2)^K \ 0 \ (-\omega_{1,2}^2)^K \ 0 \ \cdots \ (-\omega_{K,M}^2)^K \ 0]^T$$

曲线拟合需将 C_b 矩阵中 $\operatorname{Re}(j\omega_{k,m})$ 替换为 $R[m]$, m 对应于 $\omega_{k,m}$, 然后, 运用最小二乘法可估计 X 。

$$X = C^\dagger D \quad (35)$$

式中 \dagger 表示伪逆, X 的解即式(24)的系数 a_k 和 b_k 。则第 k 个模态参数 \hat{f}_k , $\hat{\zeta}_k$, \hat{A}_k 和 $\hat{\phi}_k$ 即可通过式(24)和式(25)计算得出。再由式(20)可得 $r[n]$ 的拟合值 $\hat{r}[n]$:

$$\hat{r}[n] = \sum_{k=1}^K \hat{A}_k e^{-\hat{\zeta}_k \hat{\omega}_k n T_s} \cos(\hat{\omega}_k \sqrt{1 - \hat{\zeta}_k^2} n T_s + \hat{\phi}_k) \quad (36)$$

2.4 结果评价

信号拟合曲线与原信号越接近, 辨识结果精确度也越高。拟合精度采用信噪比 S_{NRe} 为指标, 单位为 dB。

$$S_{\text{NRe}} = 10 \lg \frac{\sum_{n=0}^{N-1} r^2[n]}{\sum_{n=0}^{N-1} (r^2[n] - \hat{r}[n])^2} \quad (37)$$

式中: $r[n]$ 为测量信号; $\hat{r}[n]$ 为曲线拟合重构信号; S_{NRe} 的结果越大, 表示拟合信号与原始信号拟合的效果越好。

本文采用 VMD 分解滤除原始数据中的直流分量, 并提取出系统低频振荡信号, 然后做自相关计算消除噪声, 低频振荡参数由自相关函数的拉普拉斯变换计算得到, 而拉普拉斯变换式(22)的系数通过信号自相关函数 DFT 的曲线拟合来估计, 最后由 ARMA 模型产生的类似真实 PMU 的频率数据和实测 PMU 频率数据验证方法的有效性和准确性。

3 实例分析

3.1 模拟数据算例分析

由式(9)可知, PMU 数据由 3 部分组成, 为了验证所提方法的可行性和有效性, 利用式(15)和

式(16)的 ARMA 模型模拟产生 PMU 频率数据进行验证。由 ARMA 模型可通过程序模拟产生离散的 PMU 数据, 直流分量^[27]取值如表 1 所示, 2 个低频振荡分量取值如表 2 所示。模拟采样时间间隔为 0.02 s, 加入不同信噪比的高斯白噪声来模拟测量噪声。

表 1 模拟直流分量的参数

Tab. 1 Parameters of the analog DC component

DC 趋势项	数值
$1/K_s$ (幅值)	0.3
$Kf_0/(2J)$	0.2

表 2 低频振荡分量的参数

Tab. 2 Parameters of low-frequency oscillation components

k	f_k/Hz	ζ_k	γ_k
1	0.3	0.07	0.4
2	0.5	0.05	0.5

模拟数据测量噪声信噪比取 30 dB 高斯白噪声时, 对模拟数据先经过低通滤波处理, 低通滤波是基于高速采样频率 50 Hz 设计的 2 阶巴特沃兹低通滤波器, 截止频率为 5 Hz, 滤除高频分量可减少 VMD 分解个数, 增加运行速度。采用相关系数的 VMD 算法确定分量个数 K , 分量之间的最大相关系数如表 3 所示。由表 3 可知, 当 K 取 4、5 时, 信号经 VMD 算法分解之后分量之间的最大相关系数均大于阈值 0.1; 而当 k 取 2、3 时, 最大相关系数皆小于阈值 0.1。故取 K 值为 3, VMD 分解结果如图 1 所示。

表 3 不同 K 值的最大相关系数

Tab. 3 Maximum correlation coefficients of K different values

模态个数	2	3	4	5
最大相关系数	0.003 0	0.061 2	0.124 1	0.147 6

由图 1 可知, 信号经 VMD 分解后的各个 IMF 呈现比较规范, 彼此间没有模态混叠现象, 各个频段分离效果较好。其中 IMF0 是中心频率为 0 的直流分量, 其余的是不同频率范围的主导振荡频率, 为后续准确辨识出低频振荡特征参数提取提供了理想的模态分量。

与 EEMD 算法相比, VMD 算法具有较好的优越性, EEMD 分解结果如图 2 所示。从图中可以

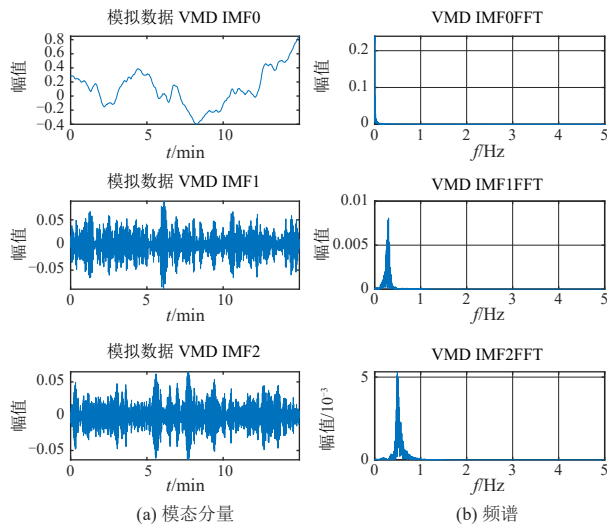


图 1 VMD 模态分量及频谱

Fig. 1 The spectrum and VMD modal component

看出，经过 EEMD 分解后得到 13 个 IMF，右侧为对应频谱。分解得到的模态个数远远多于原始信号含有的振荡分量个数，且耗时很长，同时出现了模态混叠，无法准确反映原始信号的低频振荡分量，严重影响参数提取的准确度。

以图 1 中 IMF1 和 IMF2 信号为例进行分析，对 IMF1 分别利用频差序列 DFT 的曲线拟合法和 MEYW 法进行振荡分量模态辨识，辨识算法采样频率为 50 Hz，自相关函数的有效持续时间设置为 20 s，数据窗长为 5 min，相邻数据窗间隔为 1 min，数据总长为 15 min。得到 3~8 min 的频率偏差波形和 20 s 频率偏差的自相关拟合曲线如图 3 所示，拟合 DFT 幅值和角度如图 4 所示。可以看出拟合曲线非常接近辨识信号的曲线，辨识结果

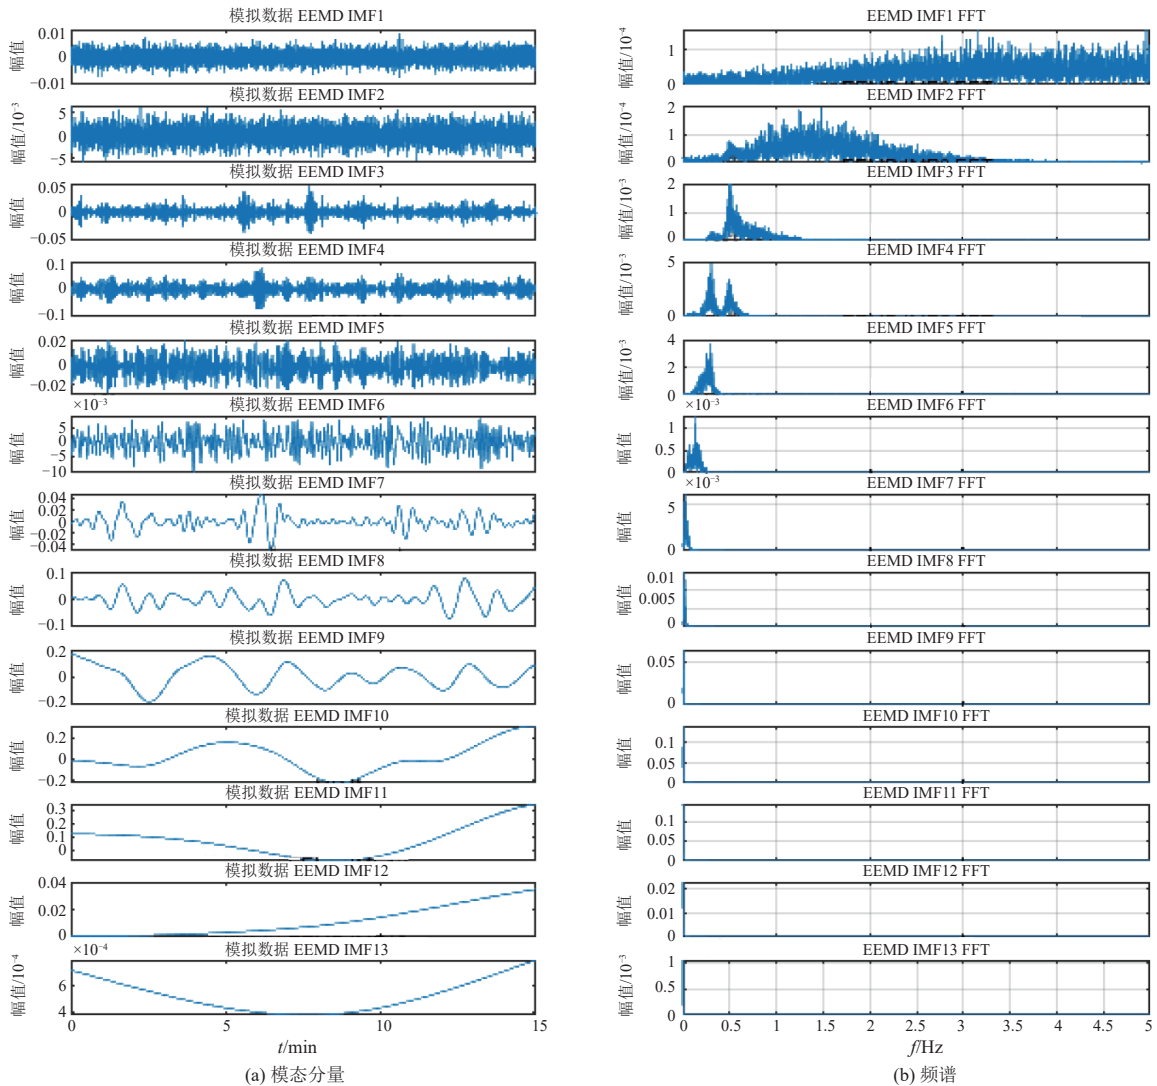


图 2 EEMD 模态分量及频谱

Fig. 2 The spectrum and EMD modal component

准确度高。图5给出IMF1分量的频率和阻尼比的辨识结果，从图中可以看出2个方法的频率偏差比较小，基于MEYW法的阻尼率值偏小，且受噪声影响某个时间段误差会比较大，而基于DFT的曲线拟合法变化比较平稳，抗噪性好。将各滑动窗口内辨识得到的模态参数取平均值得到辨识结果。采用同样的方法，将测量噪声设为10 dB高斯白噪声时， K 值为4，并对低频振荡频率范围内的分量进行模态辨识，模拟数据辨识结果如表4所示。




图3 模拟数据IMF1分量的频率偏差波形及自相关函数
Fig. 3 Frequency deviation waveform and autocorrelation function of IMF1

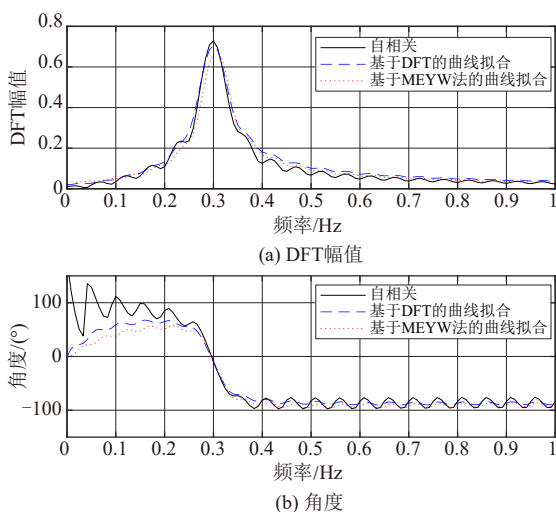


图4 模拟数据IMF1分量的DFT幅值和角度
Fig. 4 DFT amplitude and angle of IMF1

由表4可以看出，考虑量测噪声影响时，本文提出的辨识法能给出较为准确的频率值，而阻尼比




图5 模拟数据IMF1频率和阻尼率的辨识结果
Fig. 5 Frequencies and damping rates identification results of IMF1

表4 模拟数据的辨识结果

Tab. 4 Identification results of simulated data

算法	模态	\hat{f}_k/Hz	ζ_k	$\hat{A}_k/10^{-2}$	$\hat{\phi}_k/(\circ)$	S_{NRc}
本文算法	1	0.296 8	0.072 7	0.487 1	78.910 0	12.358 0
	SNR=30 dB	2	0.500 6	0.051 3	0.261 3	95.591 0
MEYW方法	1	0.304 6	0.061 3	0.430 3	73.776 0	10.548 1
	SNR=30 dB	2	0.504 8	0.058 5	0.181 9	102.673 3
本文算法	1	0.295 4	0.070 8	0.611 7	86.660 2	11.351 7
	SNR=10 dB	2	0.503 4	0.046 7	0.312 5	99.217 9
MEYW方法	1	0.305 2	0.054 0	0.489 6	82.909 7	10.840 1
	SNR=10 dB	2	0.505 5	0.037 4	0.220 3	97.576 4

和振荡幅值受系统运行方式的影响较大，所以信噪比越小，系统阻尼比和振荡幅值波动程度相对越大，但本文提出的方法波动相对较小，说明所提方法准确度高和抗噪性好。因此，文中采用的基于DFT曲线拟合的辨识法比目前应用广泛的在线辨识MEYW法更准确，拟合精度 S_{NRc} 如图6所示。

对比图6中2个分量的拟合精度 S_{NRc} 可以看出，弱阻尼辨识结果比高阻尼辨识结果更准确，阻尼比越小，振荡平息时间也越长，一段时间后该模式信号分量相对于噪声仍占据主导地位，同时也可看出环境噪声越弱，信噪比越高，辨识精度越高。

该方法的计算时间与VMD分解个数、采样频率、数序列长度、数据窗滑动步长以及时间窗长度直接相关，VMD计算时间占比较大，但相对于EEMD计算时间能减少很多，同时低通滤波后可

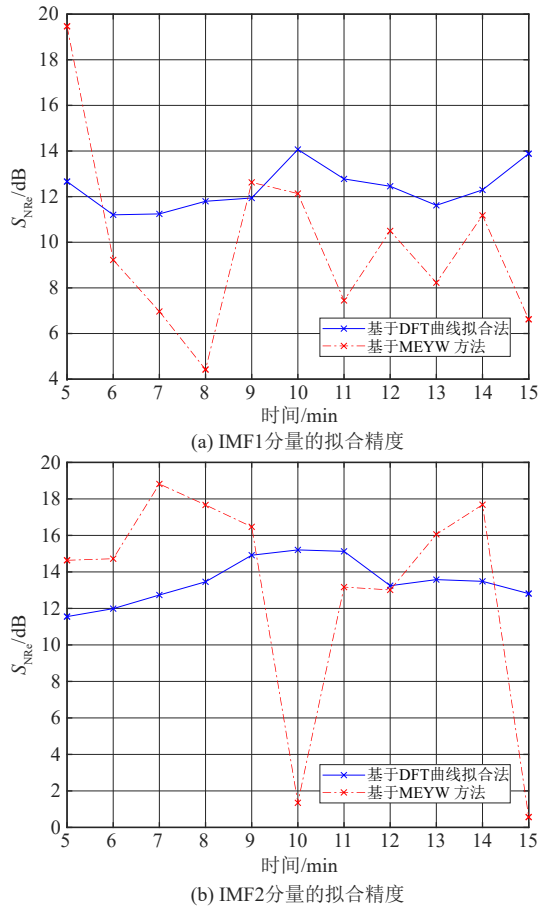


图6 模拟数据拟合精度图

Fig. 6 Fitting precision diagram

减少分解个数，提高运行速度。由于MEYW法中AR模型的阶数比DFT拟合法的阶数高，相比较，本文辨识方法运行时间短。以MATLAB 2018版进行编程，完成上述PMU模拟数据分析，SNR为30 dB时低通滤波后VMD分解个数为3，计算时间为6.372 7 s，基于DFT曲线拟合辨识运行时间为0.927 8 s，耗时7.518 9 s，占空比为0.835 4%，完全满足在线应用要求。

3.2 实测数据模态辨识

以某实际系统PMU录波数据为例，分析系统低频振荡特征。实际系统采样频率为0.033 3 s，选取时长为15 min的部分量测信号，实测数据减去额定频率60 Hz，得到实际频率的波动如图7所示。

VMD分解时经巴特沃斯低通滤波处理可以减少VMD分解个数，提高运行速度。本案例中，模态个数为5时最大相关系数大于阈值0.1，故取模态个数为4。VMD分解得到各分量及其频谱如图8

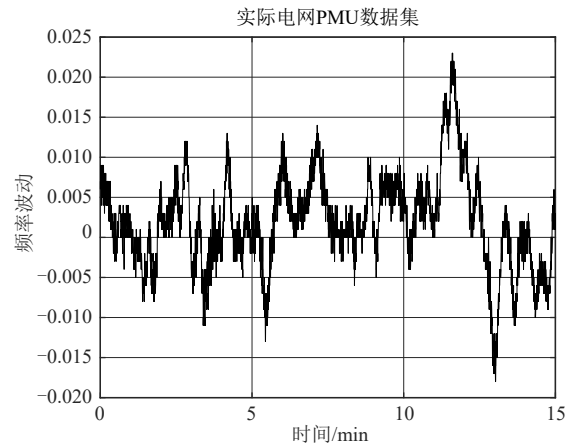


图7 某电网实测频率波动

Fig. 7 The measured frequency fluctuation of a power grid

所示，得到第一个IMF分量为中心频率为0的直流，同时得到3个不同频率段的信号，取危害较大的区域间低频振荡的信号IMF1和IMF3，用本文方法进行模态辨识，辨识时采样频率为30 Hz，自相关函数的有效持续时间为20 s，数据窗长设为5 min，相邻数据窗间隔为1 min。此时得到辨识结果如表5所示，IMF1分量的幅值和角度如图9所示，实测数据2个区间低频振荡模态分量的频率和阻尼比的辨识结果如图10所示，拟合精度如图11所示。通过对比结果可知，本文所提方法准确度高、抗噪性强，MEYW方法受随机测量噪声影响较大，同时通过对比拟合精度也验证了阻尼率越小，拟合精度越高。

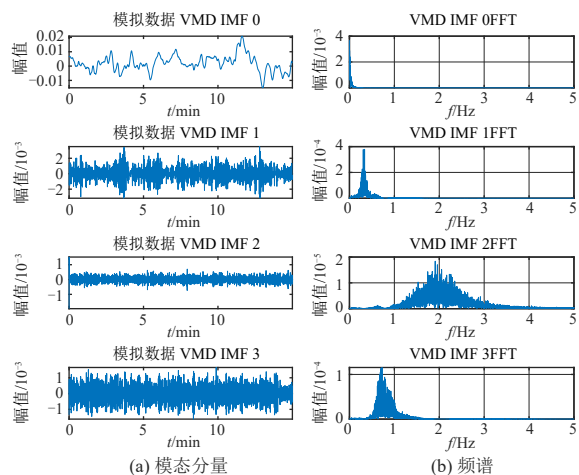


图8 某电网实测频率数据的模态分量及频谱

Fig. 8 Modal components and spectrum of a power network measured frequency data




图9 实测数据IMF1分量的DFT幅值和相角
Fig. 9 IMF1 DFT amplitude and angle of measured data




图10 实测数据2个模式的辨识结果
Fig. 10 Two modes identification results of measured data

表5 实测数据辨识结果

Tab. 5 Identification results of measured data

算法	模态	\hat{f}_k/Hz	ζ_k	$\hat{A}_k/10^{-6}$	$\hat{\phi}_k(^{\circ})$	S_{NRc}
本文算法	1	0.319 5	0.049 40	0.885 2	89.987 9	15.626 3
	2	0.675 3	0.135 1	0.323 8	112.821 0	12.260 1
MEYW法	1	0.319 3	0.063 7	0.982 4	93.850 4	14.963 0
	2	0.667 4	0.098 7	0.266 7	113.287 0	11.762 7




图11 实测数据拟合精度
Fig. 11 Fitting accuracy of measured data

在实测数据辨识过程中，采样频率较低，为30 Hz，同样在MATLAB 2018版本上运行程序。低通滤波后VMD分解个数为4，运行时间为8.404 8 s，总耗时为9.551 s，占空比为1.061%，提高了机电小干扰稳定评估的实时性。

以上结果表明，由于VMD算法和基于DFT的曲线拟合法都具有较好的噪声鲁棒性，参数辨识结果精度较高，辨识曲线平滑，符合实际的波动情况，并且计算速度满足在线应用要求，在用于实际量测数据分析时，同样取得了很好的辨识

效果,证明该方法能够有效分解信号及准确提取低频振荡模态参数。

4 结论

以类噪声数据为基础,应用改进VMD算法进行数据的预处理,提出一种基于DFT曲线拟合的电力系统低频振荡信号识别方法。得出以下结论:

1) 利用改进VMD分解方法可有效消除直流分量或趋势项,并能准确提取出低频振荡信号,抗噪性好;

2) 利用自相关函数保持原信号振荡模态参数特性,提出基于自相关函数DFT曲线拟合的模态参数辨识方法,通过DFT峰值个数可确定信号所含低频振荡模式的数量,运行时效性强;

3) 采用模拟PMU数据和某电网的实测数据计算分析,验证了所提方法的准确性和有效性。该方法可用于环境激励下的电力系统低频振荡在线模态参数辨识。

参考文献

- [1] 李青兰, 吴琛, 陈磊, 等. 抑制频率振荡的电力系统稳定器参数优化[J]. 电力系统自动化, 2020, 44(7): 93-98.
LI Q L, WU C, CHEN L, et al. Parameter optimization of power system stabilizer for suppressing frequency oscillation[J]. Automation of Electric Power Systems, 2020, 44(7): 93-98.
- [2] 张虹, 王迎丽, 勇天泽, 等. 基于IEWT和噪能转移SR-MLS反演识别技术的低频振荡信号分析[J]. 电网技术, 2019, 38(1): 1-10.
ZHANG H, WANG Y L, YONG T Z, et al. Analysis of low frequency oscillatory signals by IEWT and energy transfer SR-MLS inversion recognition techniques[J]. Power System Technology, 2019, 38(1): 1-10.
- [3] 丁仁杰, 沈钟婷. 基于EMO-EDSNN的电力系统低频振荡模态辨识[J]. 电力系统自动化, 2020, 44(3): 122-130.
DING R J, SHEN Z T. Power system low frequency oscillation mode identification based on exact mode order-exponentially damped sinusoids neural network[J]. Automation of Electric Power Systems, 2020, 44(3): 122-130.
- [4] 肖怀硕, 贾梧桐, 肖冰莹, 等. 基于改进变分模态分解的低频振荡模式辨别[J]. 电力工程技术, 2020, 39(2): 95-102.
XIAO H S, JIA W T, XIAO B Y, et al. An identification method for power system low-frequency oscillation based on parameter optimized variational mode decomposition[J]. Electric Power Engineering Technology, 2020, 39(2): 95-102.
- [5] 习工伟, 胡涛, 朱艺颖, 等. 基于新型交直流协调控制抑制电力系统低频振荡的仿真试验[J]. 电网与清洁能源, 2019, 35(4): 8-15.
XI G W, HU T, ZHU Y Y, et al. Simulation test of low frequency oscillation suppression in power system based on new AC-DC coordinated control[J]. Power System and Clean Energy, 2019, 35(4): 8-15.
- [6] HWANG J K, LIU Y L. Discrete Fourier transform-based parametric modal identification from ambient data of the power system frequency[J]. IET Generation Transmission Distribution, 2016, 10(1): 213-220.
- [7] HWANG J K, LIU Y. Noise analysis of power system frequency estimated from angle difference of discrete Fourier transform coefficient[J]. IEEE Transactions Power Delivery, 2014, 29(4): 1533-1541.
- [8] 于笑, 陈武晖. 风力发电并网系统次同步振荡研究[J]. 发电技术, 2018, 39(4): 304-312.
YU X, CHEN W H. Review of subsynchronous oscillation induced by wind power generation integrated system [J]. Power Generation Technology, 2018, 39(4): 304-312.
- [9] 吴涛, 梁浩, 谢欢, 等. 励磁系统控制关键技术与未来展望[J]. 发电技术, 2021, 42(2): 160-170.
WU T, LIANG H, XIE H, et al. Key technologies and future prospects of excitation system control[J]. Power Generation Technology, 2021, 42(2): 160-170.
- [10] 和萍, 申润杰, 祁盼, 等. 四种FACTS装置对改善风光互补系统稳定性的研究[J]. 智慧电力, 2020, 48(7): 65-72.
HE P, SHEN R J, QI P, et al. Four kinds of FACTS devices to improve the stability of wind-solar complementary system[J]. Smart Power, 2020, 48(7): 65-72.
- [11] 潘学萍. 电力系统低频振荡[M]. 北京: 中国水利水电出版社, 2013: 123-125.
PAN X P. Low frequency oscillation of power system [M]. Beijing: China Water Power Press, 2013: 123-125.
- [12] 孙英云, 游亚雄, 侯建兰, 等. 基于差分正交匹配追踪和Prony算法的低频振荡模态辨识[J]. 电力系统自

- 动化, 2015, 39(10): 69-74.
- SUN Y Y, YOU Y X, HOU J L, et al. Identification of low-frequency oscillation mode based on difference orthogonal matching pursuit and Prony algorithm[J]. *Electric Power Automation Equipment*, 2015, 39(10): 69-74.
- [13] 张程, 金涛. 基于 ISPM 和 SDM-Prony 算法的电力系统低频振荡模式识别[J]. *电网技术*, 2016, 40(4): 1209-1216.
- ZHANG C, JIN T. Identification of low frequency oscillations in power systems using an improved smoothness priors method and second-derivative method-Prony[J]. *Power System Technology*, 2016, 40(4): 1209-1216.
- [14] YANG J Z, LIU C W, WU W G. A hybrid method for the estimation of power system low-frequency oscillation parameters[J]. *IEEE Transactions of Power System*, 2007, 22(4): 2115-2123.
- [15] RUEDA J L, JUÁREZ C A, ERLICH I. Wavelet-based analysis of power system low-frequency electromechanical oscillations[J]. *IEEE Transactions of Power System*, 2011, 26(3): 1733-1743.
- [16] Zdrozny P A. Extended Yule-Walker identification of VARMA models with single or mixed-frequency data [J]. *Journal of Econometrics*, 2016, 193: 438-446.
- [17] WIES R W, PIERRE J W, TRUNDNOWSKI D J. Use of least-mean squares (LMS) adaptive filtering technique for estimating low-frequency electromechanical modes in power systems[C]/IEEE Power Engineering Society General Meeting, 2002: 4867-4873.
- [18] ZHOU N, PIERRE J W, TRUNDNOWSKI D J, et al. Robust RLS methods for online estimation of power system electromechanical modes[J]. *IEEE Transactions of Power System*, 2007, 22(3): 1240-1249.
- [19] 董飞飞, 刘涤尘, 涂炼, 等. 基于 MM-ARMA 算法的次同步振荡模态参数辨识[J]. *高电压技术*, 2013, 39(5): 1252-1257.
- DONG F F, LIU D C, TU L, et al. Subsynchronous oscillation modal parameter identification based on MM-ARMA algorithm[J]. *High Voltage Engineering*, 2013, 39(5): 1252-1257.
- [20] 耿海璇, 张济民. 基于 Yule-Walker AR 方法的振动信号除噪研究[J]. *机电一体化*, 2016(1): 34-37.
- GENG H X, ZHANG J M. A Study on vibration signal based on Yule-Walker AR method[J]. *Mechatronics*, 2016(1): 34-37.
- [21] ANDERSON M G, ZHOU N, PIERRE J W, et al. Bootstrap-based confidence interval estimates for electromechanical modes from multiple output analysis of measured ambient data[J]. *IEEE Transactions of Power System*, 2005, 20(2): 943-950.
- [22] 吴超, 陆超, 韩英铎, 等. 基于类噪声信号和 ARMA-P 方法的振荡模态辨识[J]. *电力系统自动化*, 2020, 34(6): 1-6.
- WU C, LU C, HAN Y D, et al. Identification of mode shape based on ambient signals and ARMA-P method[J]. *Automation of Electric Power Systems*, 2020, 34(6): 1-6.
- [23] 杨德友, 王文嘉, 高际惟, 等. 随机数据驱动下的机电振荡参数在线提取与阻尼调制(一): 基于 ORSSI 的模态参数在线辨识[J]. *中国电机工程学报*, 2018, 38(8): 2253-2261.
- YANG D Y, WANG W J, GAO J W, et al. On-line electromechanical oscillation analysis and damping modulation for power system using ambient data (part I): modal parameters identification based on ORSSI [J]. *Proceedings of the CSEE*, 2018, 38(8): 2253-2261.
- [24] 杨德昌, REHTANZ C, 李勇, 等. 基于改进希尔伯特-黄变换算法的电力系统低频振荡分析[J]. *中国电机工程学报*, 2011, 31(10): 102-108.
- YANG D C, REHTANZ C, LI Y, et al. Researching on low frequency oscillation in power system based on improved HHT algorithm[J]. *Proceedings of the CSEE*, 2011, 31(10): 102-108.
- [25] 朱永利, 王刘旺. 并行 EEMD 算法及其在局部放电信号特征提取中的应用[J]. *电工技术学报*, 2018, 33(11): 2508-2518.
- ZHU Y L, WANG L W. Parallel ensemble empirical mode decomposition and its application in feature extraction of partial discharge signals[J]. *Transactions of China Electrotechnical Society*, 2018, 33(11): 2508-2518.
- [26] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [27] 郑小霞, 陈广宁, 任浩瀚, 等. 基于改进 VMD 和深度置信网络的风机易损部件故障预警[J]. *振动与冲击*, 2019, 38(8): 153-160.
- ZHENG X X, CHEN G N, REN H H, et al. Fault detection of vulnerable units of wind turbine based on improved VMD and DBN[J]. *Journal of Vibration and Shock*, 2019, 38(8): 153-160.
- [28] PIERRE J W, TRUDNOWSKI D J, DONNELLY M K. Initial results in lectromechanical mode identification from ambient data[J]. *IEEE Transactions of Power*

- System, 1997, 12(3): 1245-1251.
- [29] INOUE T, TANIGUCHI N, IKEGUCHI Y, et al. Estimation of power system inertia constant and capacity of spinning-reserve support generators using measured frequency transients[J]. IEEE Transactions of Power System, 1997, 12(1): 136-143.
- [30] 李东辉, 臧晓明, 鞠平, 等. 电力系统频率响应的改进模型与参数估计[J]. 电力工程技术, 2019, 38(5): 85-90.
- LI D H, ZANG X M, JU P, et al. The improved model and parameter estimation for frequency response of power system[J]. Electric Power Engineering Technology, 2019, 38(5): 85-90.
- [31] KAKIMOTO N, SUGUMI M, MAKINO T, et al. Monitoring of interarea oscillation mode by synchronized phasor measurement[J]. IEEE Transactions of Power System, 2006, 21(1): 260-268.
- [32] 奥本海默. 信号与系统[M]. 西安: 西安交通大学出版社, 1999: 156-157.
- OPPENHEIM A V. Signals and systems[M]. Xi'an: Xi'an Jiaotong University Press, 1999: 156-157.
- [33] 张俊甲, 马增强, 王梦奇, 等. 基于VMD与自相关分析的滚动轴承故障特征提取[J]. 电子测量与仪器学报, 2017, 31(9): 1372-1378.
- ZHANG J J, MA Z Q, WANG M Q, et al. Fault feature extraction of rolling bearing based on VMD and autocorrelation analysis[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(9): 1372-1378.
- [34] 胡楠, 李兴源, 李宽, 等. 基于CCF-TLS-ESPRIT算

法的低频振荡在线辨识[J]. 物理学报, 2014, 63(6): 316-324.

HU N, LI X Y, LI K, et al. Online identification of low frequency oscillation based on CCF-TLS-ESPRIT algorithm[J]. Acta Physica Sinica, 2014, 63(6): 316-324.

收稿日期: 2021-06-18。

作者简介:



闫红艳

闫红艳(1980), 女, 博士研究生, 讲师, 研究方向为电力系统稳定性分析与控制, yhyan118@126.com;



Hwang Jin Kwon

Hwang Jin Kwon(1961), 男, 教授, 博士生导师, 研究方向为控制与仪表, 电力系统稳定性和智能电网;



高艳丰

高艳丰(1979), 男, 副教授, 硕士生导师, 研究方向为电气设备状态监测与故障诊断, 电力系统保护与控制, 本文通信作者, gaoyanfeng01@126.com。

(责任编辑 辛培裕)