第 52 卷 第 5 期：2366-2376 高电压技术 Vol.52, No.5: 2366-2376
2026 年 5 月 31 日 High Voltage Engineering May 31, 2026
DOI: 10.13336/j.1003-6520.hve.20250768

基于增强 VMD 和贝叶斯推理的电力振荡模态参数辨识方法

段俊峰[1]，左　剑[2]，姚文轩[1]
（1. 湖南大学电气与信息工程学院，长沙 410082；
2. 国网湖南省电力有限公司电力科学研究院，长沙 410017）

摘　要：针对电力系统扰动录波数据中振荡模态混叠和噪声干扰导致参数辨识精度下降的问题，提出一种基于增强变分模态分解(variational mode decomposition，VMD)和贝叶斯推理的电力振荡模态参数辨识方法。首先，在 VMD 中引入稀疏性约束，并结合遗传算法优化模态数和惩罚参数，提高各振荡分量的分离效果。然后，构建基于马尔可夫链蒙特卡罗采样的贝叶斯推理模型，以时域振荡模型为似然函数，对振幅、频率、衰减因子和相位等参数进行后验估计，并给出相应置信区间。仿真算例及湖南电网实际录波数据验证结果表明：在信噪比不低于 10 dB 时，所提方法仍能实现较准确的模态参数辨识，且具有较好的抗噪性能和不确定性量化能力。该方法可为电力系统振荡机理分析和动态稳定评估提供参考。

关键词：振荡参数辨识；变分模态分解；贝叶斯推理；马尔科夫链蒙特卡洛；不确定性量化

Power System Oscillation Modal Parameter Identification Method Based on Enhanced VMD and Bayesian Inference

DUAN Junfeng[1], ZUO Jian[2], YAO Wenxuan[1]
(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;
2. State Grid Hunan Electric Power Company Limited Research Institute, Changsha 410017, China)

Abstract: To address the issue of degradation in modal parameter identification accuracy caused by mode aliasing and noise contamination in power system disturbance recordings, a power oscillation modal parameter identification method based on enhanced variational mode decomposition (VMD) and Bayesian inference is proposed. First, a sparsity constraint is introduced into VMD, and a genetic algorithm is employed to optimize the number of modes and the penalty parameter, thereby improving the separation performance of oscillatory components. Then, a Bayesian inference model based on Markov chain Monte Carlo sampling is established. Moreover, the time-domain oscillation model is taken as the likelihood function, the posterior distributions of amplitude, frequency, damping factor, and phase are estimated, and the corresponding confidence intervals are obtained. Simulation cases and measured disturbance recordings from the Hunan power grid show that the proposed method can still be adopted to identify modal parameters accurately when the signal-to-noise ratio is no lower than 10 dB, while exhibiting good noise robustness and uncertainty quantification capability. The proposed method can provide supports for oscillation mechanism analysis and dynamic stability assessment in power systems.

Key words: oscillation parameter identification; variational mode decomposition; Bayesian inference; Markov chain Monte Carlo; uncertainty quantification

0　引言

随着以风电、光伏为代表的可再生能源持续高比例接入，电力系统结构和运行特性发生深刻变化，系统频率稳定性与功角稳定性面临严峻挑战[1-2]。大量电力电子设备与主网耦合带来的非线性特性和宽频响应，使得传统机电振荡逐步演化为跨频段、多模态的电磁振荡[3]，其频率范围拓展至 0.1 Hz 至数百赫兹甚至更高。这类振荡现象普遍具有多模态混叠、阻尼特性不稳定、时变性强等特征，极大地削弱了输电系统的调控能力与安全裕度[4-7]。因此，面向多频段、多扰动环境下的电力振荡模态参数高精

基金资助项目：国家自然科学基金(52177078)。
Project supported by National Natural Science Foundation of China (52177078).

度提取与不确定性建模，已成为电力系统动态稳定性研究的核心问题之一。

在量测支撑方面，广域测量系统中部署的同步相量测量单元(phasor measurement unit，PMU)为电力振荡的快速检测和异常追踪提供了基础数据支撑[8]。此外，部分新型 PMU 或录波装置具备更高频带宽的波形采集能力，能够在扰动事件发生时记录高采样率的电压、电流或功率瞬时值波形，为事后振荡特性分析与参数辨识提供原始数据[9]。目前，也有研究针对新型电力系统更宽动态信号的采集与量测技术进行突破[10]。同时，主站系统的信息架构、数据接口、可视化展示能力等也日益完善，为开展电力振荡模式在线识别和智能预警提供了现实基础[11-12]。然而，量测信号在现场运行中仍面临噪声扰动强、模态混合严重、边界效应明显等挑战，传统参数辨识方法在该类复杂信号条件下普遍面临性能下降问题。

现有电力系统振荡模态分析方法主要包括频域分析法、时频变换法、模态分解法及模型驱动型方法等。其中，离散傅里叶变换(discrete Fourier transform，DFT)[13]和 Hilbert 变换[14]在处理稳态低频振荡中具有一定优势，但对非平稳信号无法有效建模。短时傅里叶变换(short time Fourier transform，STFT)[15]、小波变换(wavelet transform，WT)[16]等时频方法可实现对非平稳信号的联合分析，但对窗口函数或母小波的选取敏感，在复杂噪声背景下稳定性差。模态分解类方法如经验模态分解(empirical mode decomposition，EMD)[17]和变分模态分解(variational mode decomposition，VMD)[18]因具备自适应性，在实际振荡信号处理中受到关注。但 EMD 存在端点效应、模态混叠问题，VMD 虽然在抑制模态交叠方面性能更优，却对参数选取(如惩罚因子、模态个数)高度敏感，缺乏鲁棒性。模型驱动类方法如 Prony[19]、TLS-ESPRIT[18]、随机子空间识别[20]方法等，虽可直接提取频率、阻尼等参数，但依赖模型阶数选择，且在噪声下稳定性不足。

同时，随着电力系统测量数据规模的扩大，人工智能方法也被逐步引入振荡模式识别领域[21]。基于深度学习[22-23]的卷积神经网络、长短期记忆网络等结构，可从原始时序数据中自动提取振荡特征，提升模式识别与趋势预测能力。然而，此类方法在工程落地中仍面临可解释性不足、依赖训练数据量大、对异常样本泛化能力差等问题，尤其在高置信度辨识和高噪声环境下应用受限。

综上所述，当前振荡辨识方法在面向高噪且混叠信号场景时，仍面临参数依赖强、分解结果不稳定和工程实用性不足等问题。为提升辨识的准确性与鲁棒性，亟需引入具备自适应能力、不确定性建模能力且适用于复杂工况的新型辨识方法。贝叶斯方法在处理噪声强、数据不足、参数动态变化等场景中表现出良好的稳定性与可信度。然而，贝叶斯推理高度依赖输入信号的模态结构清晰度，若原始信号频带交叠严重、模态耦合强，容易导致推理不收敛或估计误差增大。因此，如何为贝叶斯辨识模型提供良好的输入结构，是提升整体辨识效果的关键问题之一。

基于以上分析，本文建立一种基于增强 VMD 和贝叶斯推理的新型电力系统振荡参数辨识方法。首先，利用一种结合遗传算法改进优化函数的增强型 VMD 自适应寻优确定带宽约束惩罚参数 α、振荡模态分解个数 K 以及拉格朗日乘子更新步长 τ。随后，将去耦分解得到的各单模态振荡信号进行快速傅里叶变换(fast Fourier transform，FFT)得到幅值、频率的粗略信息。最后，利用上一步的信息作为贝叶斯模型的先验进行贝叶斯推理得到电力振荡信号的幅值、衰减因子和频率参数的稳健估计。仿真与实际振荡录波案例验证了本文方法的高精度、强鲁棒识别能力，具备良好的工程实用价值。

1　增强 VMD 和贝叶斯推理原理

电力系统在受到扰动或控制失调影响时，常会产生具有不同频率和衰减特性的多模态振荡现象。尤其在大规模电力电子设备接入背景下，振荡信号呈现出模态耦合强、非平稳性明显、幅值变化快等特点，给参数辨识带来挑战。为构造代表性的仿真测试信号，本文采用 1 组多频率模态组合的衰减振荡信号作为输入，覆盖典型的低频、次同步、中频等振荡模态，其数学表达形式如式(1)所示：

$$x_{\text{multi}}=\sum_{i=1}^{K}A_i\mathrm{e}^{-\gamma_i t}\cos\left(2\pi f_i t+\phi_i\right) \tag{1}$$

式中：K 为耦合的振荡模态个数；t 为时间；A_i、γ_i、f_i 和 ϕ_i 分别代表第 i 个振荡初始模态振幅、衰减因子、振荡频率和初始相位。

1.1　增强 VMD 算法

1.1.1　标准 VMD

VMD 是一种非递归信号分解方法，通过定义

将复杂多模态振荡信号 $x_{\mathrm{wbo}}(t)$分解为 K 个具有窄带频率特性的本征模态函数 $u_k(t)$，并使各模态分量估计带宽之和最小，即满足如式(2)的约束变分模型。

$$\begin{cases}\min\limits_{\{u_k\},\{\omega_k\}}\left\{\sum\limits_k\left\|\partial_t\left(\left(\delta(t)+\dfrac{\mathrm{j}}{\pi t}\right)*u_k(t)\right)\mathrm{e}^{-\mathrm{j}\omega_k t}\right\|_2^2\right\}\\ \text{s.t.}\sum\limits_{k=1}^{K}u_k(t)=x_{\mathrm{wbo}}\end{cases}\tag{2}$$

式中：$u_k(t)$为分解得到的第 k 个单模态振荡分量；ω_k 为第 k 个单模态振荡分量的中心角频率；*表示卷积运算；j 为虚数单位；$\delta(t)$为狄拉克函数；∂_t 为对时间 t 的偏导运算；$\|\cdot\|_2^2$ 为平方二范数。

为求解式(2)的约束变分问题，引入拉格朗日乘子 $\lambda(t)$，并构造其增广拉格朗日目标函数 L，如式(3)所示。进一步，利用交替方向乘子法对 $u_k(t)$和 ω_k 进行交替更新，并按式(4)更新拉格朗日乘子 $\lambda(t)$。

$$\begin{aligned}&L\left(\{u_k\},\{\omega_k\},\lambda\right)=\\&\alpha\sum_k\left\|\partial_t\left(\left(\delta(t)+\frac{\mathrm{j}}{\pi}\right)*u_k(t)\right)\mathrm{e}^{-j\omega_k t}\right\|_2^2+\\&\left\|x_{\mathrm{wbo}}(t)-\sum_k u_k(t)\right\|_2^2+\left\langle\lambda(t),x_{\mathrm{wbo}}(t)-\sum_K u_k(t)\right\rangle\end{aligned}\tag{3}$$

$$\lambda^{n+1}(t)=\lambda^n(t)+\tau\left(x_{\mathrm{wbo}}(t)-\sum_{k=1}^{K}u_k^{n+1}(t)\right)\tag{4}$$

式中：$\langle\cdot,\cdot\rangle$ 表示内积运算；α 为带宽约束惩罚参数，用于控制各模态分量的带宽与分解平滑性，α 越大，分解所得模态越平滑、频带越窄；τ 为拉格朗日乘子更新步长，用于控制对偶变量 $\lambda(t)$的更新幅度；K 为分解模态个数。

1.1.2 增强 GA-VMD

如 1.1.1 节分析，VMD 适合于未知模态耦合振荡信号的分解，但其分解效果明显受限于参数选取。目前有学者利用寻优算法对 VMD 进行改进，此时参数选取问题转化为适应度函数优化问题。文献[24]利用遗传算法(genetic algorithm, GA)对参数 K 进行自适应优化，并以包络熵作为其适应度函数。

这种寻优方法没有考虑同时优化 τ，此外其适应度函数设计简单，依然可能存在模态混叠的现象。为此，本文改进适应度函数，提出一种双约束的增强适应度函数，通过最小化重构误差和稀疏性惩罚来综合 VMD 的分解质量。如式(5)，通过加入所分解模态的 L2 范数作为稀疏性惩罚项 Ψ 对分解出的 K 值进行约束，避免模态过分解出现。

$$\min_{\alpha,K,\tau}\left(\frac{\|x_{\mathrm{wbo}}(t)-\hat{x}(t)\|_2}{\|x_{\mathrm{wbo}}(t)\|_2}+\psi\sum_{k=1}^{K}\|u_k(t)\|_2\right)\tag{5}$$

式中：Ψ 为正则化系数，用于平衡信号重构误差和模态分量的总幅值以避免过分解；$\hat{x}(t)$为由各分解模态重构得到的近似信号；$x_{\mathrm{wbo}}(t)$为原始多模态振荡信号。

1.2 贝叶斯推理算法

贝叶斯推理将待辨识电力振荡参数 θ 视为随机变量，通过参数后验分布 $p(\theta|D)$刻画观测数据 D 和先验信息 $p(\theta)$之间的关系。其核心数学原理建立在如式(6)的贝叶斯公式之上，后验分布由似然函数和先验分布共同决定。

$$p(\theta\mid D)=\frac{p(D\mid\theta)p(\theta)}{p(D)}\tag{6}$$

式中：p 代表参数分布；$\theta=\{A_i,\gamma_i,f_i,\phi_i\}_{i=1}^{K}$为待辨识的参数集合；$p(D|\theta)$为似然函数；$p(\theta)$为振荡参数先验分布；$p(D)$为边际似然。

似然函数用于衡量模型预测值与观测数据之间的匹配程度。在似然函数构造中，第 i 个单模态振荡分量可表示为：

$$u_i(t_j)=A_i\mathrm{e}^{-\gamma_i t_j}\cos(2\pi f_i t_j+\phi_i)+\varepsilon_{ij}\tag{7}$$

式中：ε_{ij} 为观测噪声；假设观测噪声 $\varepsilon(t)$服从均值为 0、方差为 σ^2 的高斯分布 N(·)，即：

$$\varepsilon_{ij}\sim\mathrm{N}\left(0,\sigma^2\right)\tag{8}$$

式中：N(·)表示正态分布；σ^2 为观测噪声方差。则第 i 个单模态振荡分量在第 j 个采样时刻的条件概率密度可写为：

$$p(u_i(t_j)\mid\theta_i)=\frac{1}{\sqrt{2\pi\sigma^2}}\exp\left(-\frac{(u_i(t_j)-A_i\mathrm{e}^{-\gamma_i t_j}\cos(2\pi f_i t_{ij}+\phi_i))^2}{2\sigma_i^2}\right)\tag{9}$$

设第 i 个单模态振荡分量对应的数据集为 $D_i=\{u_i(t_1),u_i(t_2),\cdots,u_i(t_N)\}$，若各采样点在给定参数 θ_i 条件下相互独立，则其似然函数可表示为：

$$p(D_i\mid\theta_i)=\prod_{j=1}^{N}p\left(u_i(t_j)\mid\theta_i\right),\ i=1,2,\cdots,K\tag{10}$$

进一步可得：

$$p(D_i\mid\theta_i)\propto\exp\left(-\frac{1}{2\sigma_i^2}\sum_{j=1}^{N}\left(u_i(t_j)-A_i\mathrm{e}^{-\gamma_i t_j}\cos(2\pi f_i t_{ij}+\phi_i)\right)^2\right)\tag{11}$$

式中：$\theta_i=\{A_i,\gamma_i,f_i,\phi_i\}$为第 i 个振荡模态的待辨识参数集合；N 为该单模态振荡分量包含的数据点总数；K 为振荡模态个数。

为从单模态振荡数据中推断出各参数的后验

分布，需要进一步设定参数 A_i、γ_i、f_i 和 ϕ_i 的先验分布。贝叶斯推理以各参数的物理意义或先验知识为前提进行设定。结合各参数的物理意义及先验知识，具体设定如式(12)—(15)。

$$A_i \sim \text{Gamma}(a,b) \tag{12}$$

$$\gamma_i \sim \text{Normal}(0,1) \tag{13}$$

$$f_i \sim \text{Uniform}(f_{\min}, f_{\max}) \tag{14}$$

$$\phi_i \sim \text{Uniform}(0,2\pi) \tag{15}$$

式中：$\theta_i=\{A_i, \gamma_i, f_i, \phi_i\}$为第 i 个振荡模态的待辨识参数集合；N 为该单模态振荡分量包含的数据点总数；K 为振荡模态个数。a 和 b 分别为 Gamma 分布的形状参数和率参数；$f_{\min}$ 和 $f_{\max}$ 分别为频率先验分布的下界和上界。由于幅值参数 A_i 取值非负，采用 Gamma 分布能够较好表征其正值特性；衰减因子 γ_i 采用正态分布建模，以兼顾振荡衰减与发散两种情形；频率 f_i 根据振荡类型所处频段设定为区间均匀分布；相位 ϕ_i 则在[0, 2π]范围内采用非信息性均匀先验。

2　振荡参数贝叶斯推理辨识方法构建

基于增强 VMD 与贝叶斯推理的电力振荡参数辨识流程如图 1 所示。具体步骤如下所述。

1）多模态电力振荡信号输入。输入可能包含多个频率成分和复杂衰减特性的电力振荡信号。

2）增强 VMD 参数优化。初始化遗传算法的种群大小、交叉率、变异率最大迭代次数以及稀疏性权重等参数；执行 VMD 分解，计算重构误差和稀疏性正则化项获取适应度函数值，并选取较好的个体进行繁殖；对选择出的个体进行交叉和变异操作，产生新的参数组合，重复适应度评估、选择、交叉和变异操作更新 VMD 参数，直到达到最大迭代次数或适应度函数收敛；输出优化的 VMD 参数(K,α,τ)。

3）最优 VMD 分解。设定寻优值(K,α,τ)进行耦合电力振荡信号分解，所得到的 K 个单模态信号即为 K 个振荡的时域成分。

4）贝叶斯推理振荡参数辨识。对包含单模态的振荡模态信号构建似然函数 $p(D|\theta)$和先验分布 $p(\theta)$；通过马尔科夫蒙特卡洛(Markov Chain Monte Carlo，MCMC)方法从后验分布中采样，获取各参数的后验估计值和不确定性信息；检查 MCMC 是否收敛，未收敛则重新调整先验设定。

5）辨识结果输出。若 MCMC 采样收敛，则输出各模态振荡幅值、衰减因子、振荡频率和初始相位的贝叶斯推理结果。

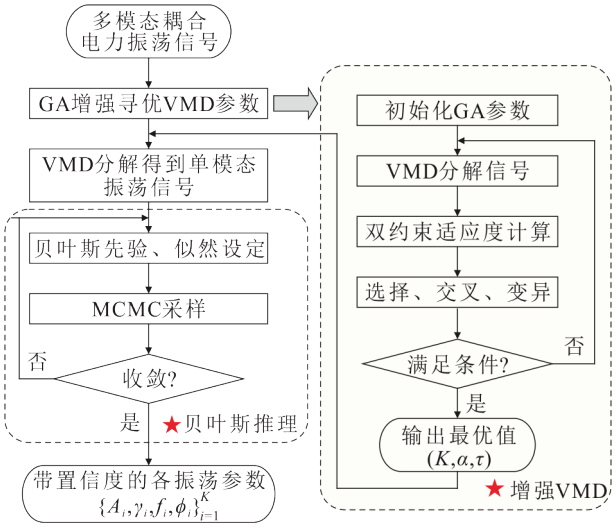


图 1　基于增强 VMD 与贝叶斯推理的电力振荡参数辨识流程

Fig.1　Flowchart of power oscillation parameter identification based on enhanced VMD with Bayesian inference

3　仿真与分析

为测试所提新型辨识方法的性能，首先以已知模态参数的单模态合成低频振荡信号为例进行贝叶斯推理，并进行抗噪测试，以凸显所提贝叶斯推理振荡参数的优越性。然后合成包含 4 种频率成分的多模态振荡信号进行 VMD 分解测试，验证其增强分解效果。接着，通过贝叶斯推理其分解模态的参数进行准确性校验。最后，通过实际电网的振荡信号对本文所提方法做进一步的性能验证。

3.1　单模态合成信号测试

3.1.1　贝叶斯推理振荡参数辨识验证

首先合成式(16)所示低频振荡信号 $x_{\text{lfo}}(t)$进行模态参数辨识。设定 3 个先验较弱的参数先验分布为：A~Gamma(2,1)；γ~Normal(0,1)；ϕ~Uniform(0,2π)。设定频率参数的先验分布为：f~Uniform(1,2.5)。另外设定 MCMC 的迭代次数为 3 000，其中预烧期为 1 000。

$$x_{\text{lfo}}(t)=0.9\text{e}^{-(-0.13)t}\cos(2\pi\cdot 2.5t+\frac{\pi}{4})+\varepsilon(t) \tag{16}$$

该单模态振荡 4 个参数(A、γ、f、ϕ)的 MCMC 求解过程及参数后验分布如图 2 所示。由图 2(a)可知，该种参数求解方式以参数概率分布为视角，其辨识结果由 2 000 次的蒙特卡洛迭代得出，各参数的 MCMC 抽样轨迹均表现出良好的收敛性。由图 2(b)可知，贝叶斯推理能给出振荡参数的后验分布，

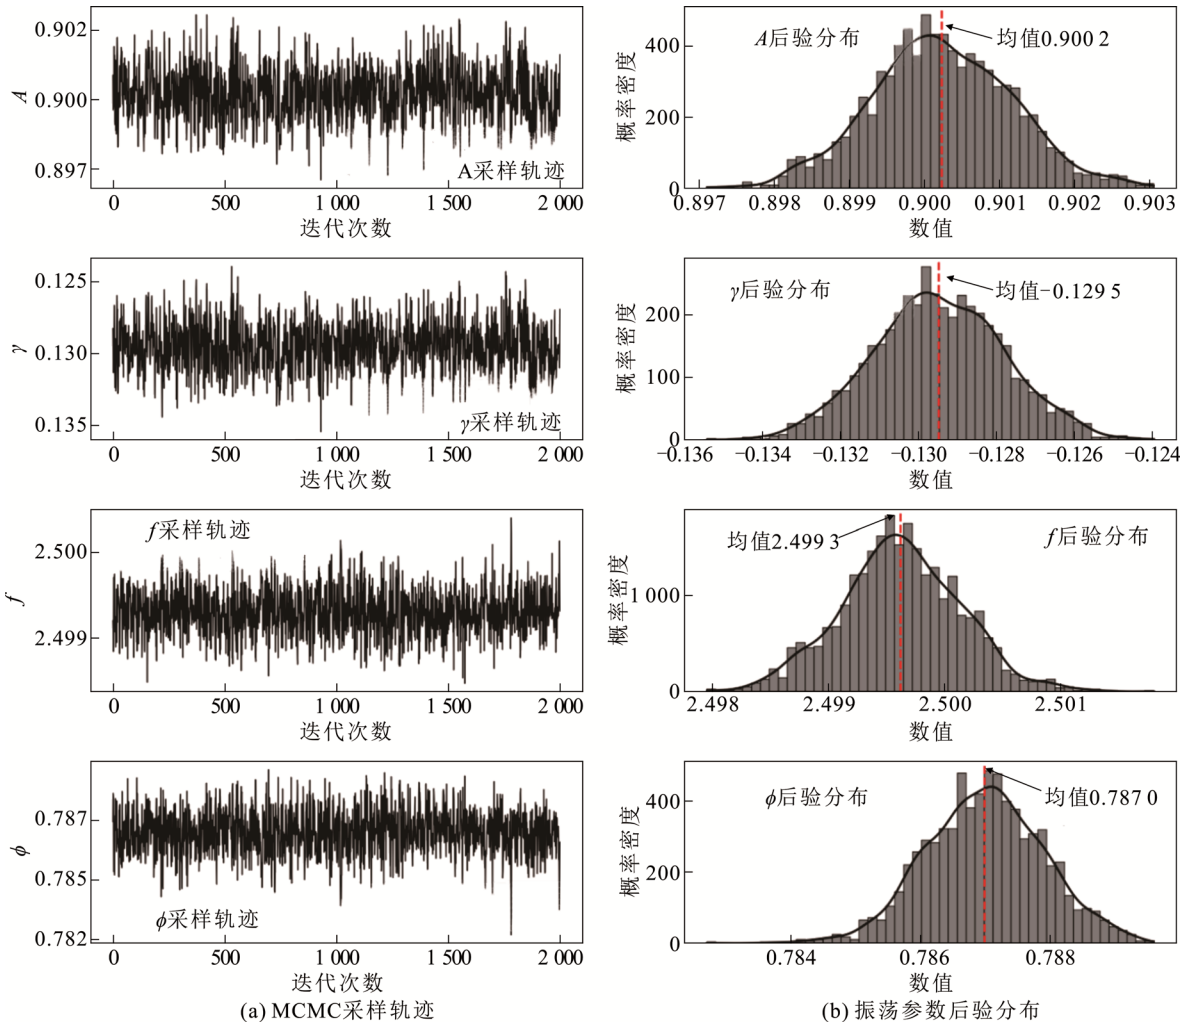


图 2 MCMC 抽样轨迹和各振荡参数后验分布

Fig.2 Sampling trajectory and posterior distribution of each parameter via MCMC

其均值为辨识结果，且能衡量结果置信度。

合成信号的各模态参数求解结果如表 1。由表 1 可知，基于贝叶斯推理方法能得到准确的参数辨识值。例如，对于模态幅值 A，真实值为 0.9，而辨识均值为 0.900，标准差为 0.001，且 95%置信区间为[0.898, 0.902]；对于衰减因子 γ，辨识均值为 –0.129，标准差为 0.0002，95%置信区间为[–0.133, –0.126]，也精确包含了真实值。该辨识结果表明，贝叶斯推理辨识结果既能准确辨识振荡模态参数的真实值，又能给出参数的置信区间。

3.1.2 贝叶斯推理振荡参数抗噪性验证

为进一步验证所提贝叶斯推理方法辨识振荡参数的抗噪性，给式(14)的信号依次添加，不同水平(30 dB、20 dB、10 dB 和 0 dB)的噪声，并进行贝叶斯推理进行参数辨识。

表 2 详细展示了在不同信噪比条件下，基于贝叶斯推理方法对振荡参数幅值 A、阻尼系数 γ、频率 f 和相位 ϕ 的辨识结果及其相对误差。结果表明，随着信噪比的降低(从 30 dB 降至 0 dB)，4 个参数的辨识精度均呈下降趋势。其中，幅值 A 的相对误差从 30 dB 条件下的 0.111%逐渐增加到 0 dB 条件下的 1.556%；衰减因子 γ 的相对误差在高信噪比下(30 dB)为 0.769%，在低信噪比下(0 dB)显著增加至 20.000%。频率 f 的辨识精度变化相对较小，相对误

表 1 基于本文方法的各模态参数辨识结果

Table 1 Identification results of each modal parameter based on the proposed method

参数	真值	贝叶斯推理辨识			
		均值	标准差	2.5%分位数	97.5%分位数
A	0.900	0.900	0.001	0.898	0.902
γ	–0.130	–0.129	0.002	–0.133	–0.126
f	2.500	2.499	0.000	2.499	2.500
ϕ	0.785	0.787	0.001	0.785	0.789

差从 0 增加到 1.960%；相位 ϕ 的相对误差则从 1.019%上升至 18.089%。

从 95%置信区间变化情况看，信噪比从 30 dB 降至 20 dB 情况下，各参数的 95%置信区间较窄，说明辨识结果的不确定性较低。例如，幅值 A 的置信区间范围从[0.897, 0.904]仅略微扩大到[0.891, 0.914]；频率 f 的置信区间范围从[2.499, 2.502]扩大至[2.492, 2.498]。在低信噪比(10 dB 及以下)条件下，置信区间显著变宽。例如：γ 的置信区间范围从 30 dB 噪声下的[–0.135,–0.123]扩大至 0 dB 噪声下的[–0.292,–0.109]；相位 ϕ 的置信区间范围从[0.785, 0.793](30 dB)扩大至[0.806, 1.049](0 dB)。这表明在低信噪比条件下，参数辨识的不确定性大幅增加。

噪声实验表明，所提方法在≥10 dB 信噪比下能够对幅值、阻尼系数、频率和相位实现高精度辨识，但在低信噪比 10 dB 条件下，噪声对参数辨识结果的影响显著增加，尤其对 γ 和 ϕ 的辨识精度影响尤为显著。

3.2　多模态合成信号测试

3.2.1　增强型 GA-VMD 分解效果验证

为验证本文方法对多模态耦合电力系统振荡信号参数辨识的适用性，随机构造 1 个跨多频域且包含多种衰减特性的合成多模态振荡信号 x_{wbo} 如式(17)所示。

$$\begin{aligned} x_{\mathrm{wbo}}(t) = {} & 0.9\mathrm{e}^{0.13t}\cos(2\pi\times 2.5t) + \\ & 0.8\mathrm{e}^{0.17t}\cos(2\pi\times 26.52t+\frac{\pi}{3}) + \\ & 0.3\mathrm{e}^{-0.32t}\cos(2\pi\times 72t+\frac{\pi}{2}) + \\ & 0.5\mathrm{e}^{0.28t}\cos(2\pi\times 155t+\frac{\pi}{4}) + \varepsilon(t) \end{aligned} \tag{17}$$

假定式(15)合成信号仿真时采样率 f_{s}=1 kHz，采样时间 t=1 s，噪声 $\varepsilon(t)$为标准差 0.1 的高斯随机噪声，其时域波形如图 3(a)，其内部包含的各模态振荡时域波形如图 3(b)—(e)。

为了验证本文所提双约束增强的效果，对上述合成信号进行分解效果对比验证。在实验中，为确保对比的公平性，传统 GA-VMD 和本文所提增强 VMD 的初始化参数保持一致，包括：最大迭代次数为 30，种群大小为 15，变异概率为 0.1，精英比例为 0.01，交叉概率为 0.5，父代占比为 0.3，交叉类型均为均匀交叉，最大无改进迭代次数为 10；对 VMD 进行长度为 200 的镜像延拓以应对端点效应；对(K,α,τ)参数的搜索范围初始化分别为 K∈[2,10]、

表 2　不同噪声水平下贝叶斯推理振荡参数辨识的结果

Table 2　Results of Bayesian inference for oscillation parameter identification at different noise levels

噪声水平/dB	模态参数	真值	辨识值	相对误差/%	95%置信区间
30	A	0.900	0.901	0.111	[0.897,0.904]
	γ	–0.130	–0.129	0.769	[–0.135,–0.123]
	f	2.500	2.499	0.040	[2.497,2.500]
	ϕ	0.785	0.789	0.510	[0.785,0.793]
20	A	0.900	0.902	0.222	[0.891,0.914]
	γ	–0.130	–0.126	3.077	[–0.148,–0.105]
	f	2.500	2.495	0.200	[2.492,2.498]
	ϕ	0.785	0.799	1.783	[0.787,0.810]
10	A	0.900	0.905	0.556	[0.871,0.944]
	γ	–0.130	–0.120	7.692	[–0.181,–0.051]
	f	2.500	2.485	0.600	[2.474,2.494]
	ϕ	0.785	0.829	5.605	[0.795,0.865]
5	A	0.900	0.907	0.078	[0.840,0.973]
	γ	–0.130	–0.117	10.000	[–0.233,0.006]
	f	2.500	2.472	1.120	[2.451,2.490]
	ϕ	0.785	0.866	10.318	[0.804,0.945]
0	A	0.900	0.914	1.556	[0.806,1.036]
	γ	–0.130	–0.104	20.000	[–0.292,0.109]
	f	2.500	2.451	1.960	[2.416,2.483]
	ϕ	0.785	0.927	18.089	[0.806,1.049]

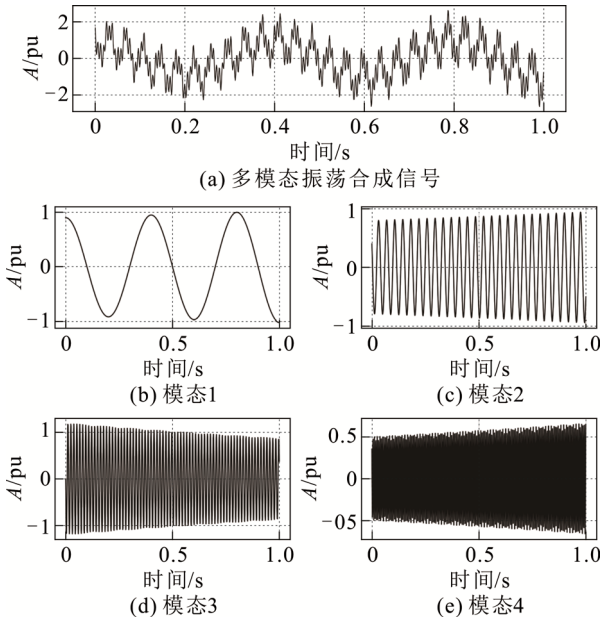


图 3　含多种模态的电力振荡合成信号

Fig.3　Power system oscillation signal with multiple modes

α∈[100,5 000]和 τ∈[10^{-7}, 10^{-4}]；另外，本文所提算法稀疏性惩罚权重项 ψ 值设定为 0.005。GA-VMD 和所提增强 VMD 的寻优的结果分别：[7 378, 1.378×10^{-5}]和[4 298,1.685×10^{-6}]。基于此寻优值进行 VMD 分解得到的各模态结果对比如图 4 所示。

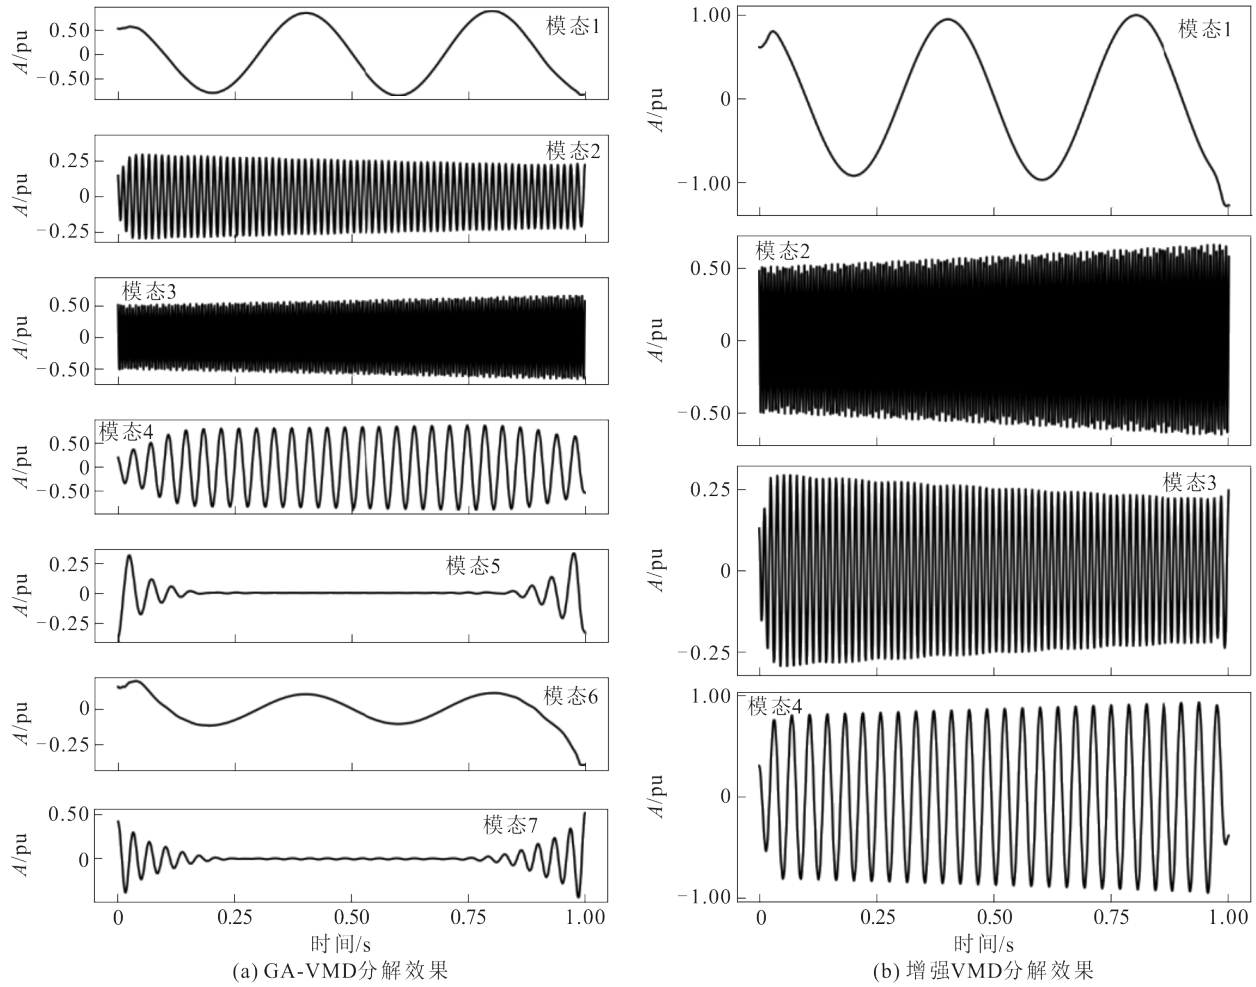


图 4 GA-VMD 与本文所提增强 VMD 的分解对比

Fig.4 Decomposition comparison between GA-VMD and the proposed enhanced VMD

由图 4(a)可知，单一优化目标(仅优化重构误差)的 GA-VMD 虽然也能有效分解出各模态的振荡分量，尽管没有出现模态混叠的现象，但其模态分离效果不具备稀疏性约束，导致分解结果中存在冗余模态，影响分解的物理意义。比如模态 5 的存在导致低频振荡模态 1 幅值损失；模态 6 与模态 7 导致模态 4 在信号边缘处出现信息损失。这种现象说明 GA-VMD 对信号幅值敏感，缺乏鲁棒性。图 4(b)通过双约束自适应函数改进的 GA-VMD 分解，有效避免了传统 GA-VMD 由于过分解出现的冗余模态问题，提高了模态间信号的独立性，有利于后续贝叶斯推理精准提取各振荡模态参数。

3.2.2 不同分解算法下振荡参数辨识对比

为进一步验证本文所提方法在振荡模态提取与参数辨识方面的有效性，选取式(15)所构造的多模态振荡合成信号，在 30 dB 信噪比条件下，分别采用 TVF-EMD、EWT、GA-VMD 和本文提出的增强型 VMD 4 种代表性模态分解方法进行处理。各方法完成模态提取后，针对所得模态分量分别进行贝叶斯推理，提取其幅值 A、衰减因子 γ、频率 f、初相位 ϕ 等参数，并计算其相对于真实值的相对误差。识别结果如表 3 所示。

由表 3 可知，TVF-EMD 在频率聚焦性上略优于 EWT，尤其在中频模态下能较好重构原始结构；EWT 方法在低频和高频模态中存在一定的模态泄露和幅值失真。相比之下，本文所提增强 VMD 方法在所有模态下均取得了最小的振荡参数相对误差，进一步验证了本文方法在模态解耦性、抗噪性以及后端贝叶斯推理适配性方面的综合优势。

3.2.3 讨论

通过对振荡各参数的先验分布设定与观测数据的似然函数进行贝叶斯推理，得到振荡模态参数的后验分布。以单模态阻尼振荡信号建模为例，理论上贝叶斯推理对频率大小不敏感，若满足采样充

表 3　不同分解算法下贝叶斯推理振荡参数辨识的相对误差

Table 3　Relative errors of Bayesian inference for oscillation parameter identification under different decomposition algorithms

模态	分解方法	相对误差/%			
		幅值	衰减因子	频率	相位
LFO	TVF-EMD	1.351	3.476	0.752	4.158
	EWT	0.986	2.580	0.412	2.672
	GA-VMD	1.124	3.051	0.631	3.836
	本文方法	0.111	0.769	0.040	0.510
SSO	TVF-EMD	1.687	3.843	0.508	4.805
	EWT	1.328	2.791	0.324	3.127
	GA-VMD	1.561	3.433	0.417	4.632
	本文方法	0.168	1.145	0.072	0.898
SUR-SO	TVF-EMD	1.812	4.217	0.598	4.466
	EWT	1,463	3.243	0.392	3.745
	GA-VMD	1.741	3.869	0.514	4.114
	本文方法	0.231	1.853	0.093	1.325
MHO	TVF-EMD	1.640	4.031	0.631	4.709
	EWT	1.201	2.820	0.398	3.221
	GA-VMD	2.043	3.943	0.547	4.458
	本文方法	0.278	2.042	0.112	1.597

分、先验合理的条件，可用于任意频率段的模态参数估计。然而，在实际振荡信号处理中，多种机制对建模过程产生间接影响如下所述。

1）高频振荡信号周期短，对时间窗口长度与采样密度要求更高，若观测不充分将降低建模精度。

2）高频模态通常能量较低，在存在背景噪声(如 PMU 测量误差)情况下更易被掩盖。

3）高频段模态频谱更密集，解耦算法(如 VMD)模态分离能力下降，导致目标模态提取不准。

4）后验分布对初值和先验敏感性更强，造成采样效率下降或推理不收敛。

综上，在高频段，贝叶斯模型实用性受限。对于高频模态，若频率先验分布设定范围过宽或远离真实值，则可能导致 MCMC 采样效率降低、后验不集中或收敛性差。如表 4，为使本文方法在实际场景中的适用性与识别效果，可采用以下参数先验设定准则。

3.3　湖南某电站振荡录波数据测试

3.3.1　振荡录波数据分解

为验证所提方法在实际振荡场景中的有效性，利用实际振荡事件波形数据进行了性能测试。2018 年 6 月 24 日，湖南省调 WAMS 系统上报如图 5 某地区火 CD 电厂某机组出现低频振荡现象。事后调查报告显示，励磁系统中二次回路 B 相间歇性接地导致分流，从而引发了如图 6 录波所示的系统间歇

表 4　振荡参数的贝叶斯先验分布设定准则

Table 4　Guidelines of oscillation parameters prior distribution in Bayesian inference

参数	推荐先验类型	先验范围选取方法
频率 f	高斯分布	主频为均值，偏差值为标准差
衰减因子 γ	均匀/高斯分布	对数包络线拟合值±(0.05~0.10)
幅值 A	伽马/正态分布	包络最大值±20%
相位 ϕ	均匀(0~2π)	采用非信息性先验

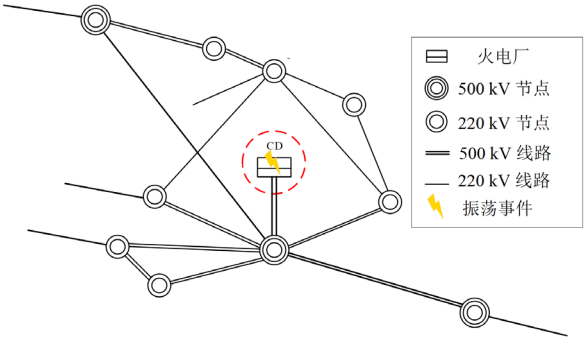


图 5　湖南电网某地区拓扑图

Fig.5　Topology map of a region of Hunan Power Grid

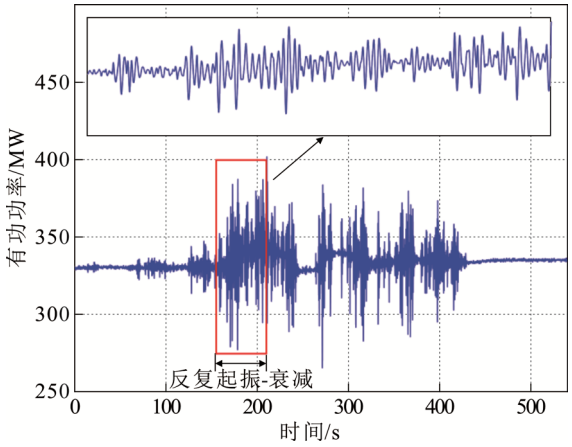


图 6　湖南某地区 PMU 实测录波振荡数据

Fig.6　Measured recorded wave oscillation data of PMU in a region of Hunan

性复归强迫功率振荡。

由图 6 可知，该振荡事件的录波信号并不平滑，中间存在一个振荡发散和抑制的时变过程。为此，首先对这一段信号进行归一化处理，然后再进行本文所提增强 VMD 算法去除噪声项和趋势项，得到主要的振荡成分。如图 7 所示，分解结果中有 2 个低频振荡成分，包括频率为 2.073 Hz 的 IMF1 和频率为 1.382 Hz 的 IMF2。然而，IMF1 的振荡分量的振幅仅为 7.26×10^{-3}，因此被确定为噪声项。

3.3.2 振荡参数贝叶斯推理

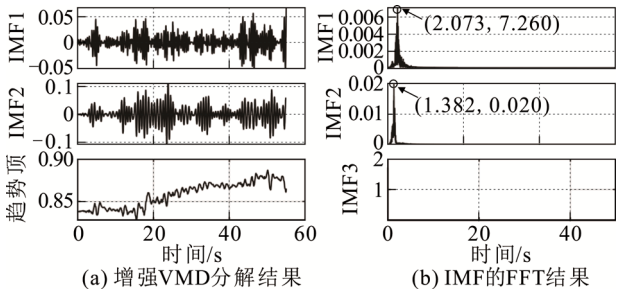
由于本文所分析振荡信号主导频率为 1.382 Hz，对应单周期时长约 0.724 s，为提高频率与衰减参数估计的稳定性，本文设置滑动窗口长度为 5 s。该长度对应约 6~7 个完整振荡周期，能有效支撑贝叶斯推理的后验拟合精度，同时兼顾对时变振荡过程的动态跟踪能力。鉴于 IMF2 表现出典型的时变阻尼振荡特性，本文采用滑动时间窗策略(窗长 5 s，步长 5 s)对该模态信号的动态演化过程进行贝叶斯推理分析，以识别其频率与衰减因子的后验估计结果，如图 8 所示。结果显示，在该振荡事件期间，主要模态频率在 1.375~2.138 Hz 间波动，第 6 窗频率短时升高至 2.138 Hz，提示系统可能受到激励增强或外部扰动。衰减因子则在初期为负值(如第 1 窗为 –3.656)，表征系统振荡发散，随后逐步转为正值，系统进入衰减阶段，趋于稳定。

根据 GB 38755—2019《电力系统安全稳定导则》，在大扰动后需识别系统是否进入“发散”、“持续振荡”或“动态稳定”状态。图 8 中所呈现的衰减因子变化趋势，在起振初期(如第 1 个窗口)数值较大，随后趋于减小并稳定在接近 0 的区间内波动，表明在该案例分析中该振荡处于不断的发散和被抑制的动态变化中。这与导则中对次同步敏感频段(工程上一般取 2.5~50 Hz)与阻尼正负判断的要求相符。该趋势体现了贝叶斯推理在不同时间窗内对信号模态特征的统计平均估计能力，具有一定的能量平滑与抗波动效果。此外，图中附加的 95%置信区间反映了参数估计的统计不确定性，进一步增强了辨识结果的可信度。

由于实际 PMU 录波数据的真实模态参数不可获得，本文选取振荡扰动显著、辨识不确定性较高的第 4 个时间窗为典型时段，基于各方法提取的主模态参数对该段扰动波形进行重构，并与原始信号进行拟合比对，以此定量评估辨识性能差异。表 5 列出了各方法重构波形的均方根误差(root mean squared error，RMSE)、平均绝对误差(mean absolute error，MAE)以及拟合优度(R square, R^2)。结果显示，本文方法在 RMSE 和 MAE 指标方面最小而 R^2 最大，均取得最优结果，表明其在实际工况下具备更优的模态参数提取能力及系统行为重建效果。

3.3.3 讨论

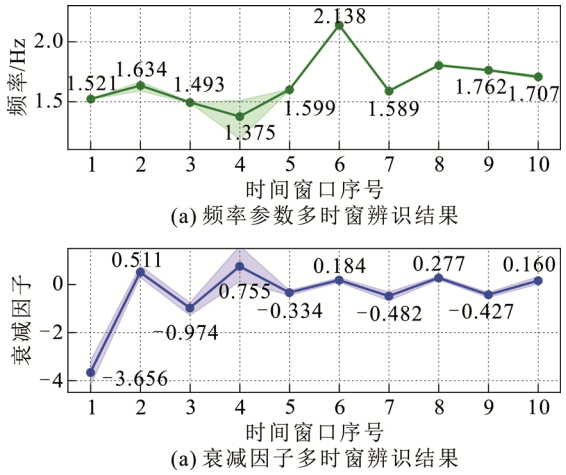
在湖南某电站实际录波中，振荡信号表现出明显的剧烈非平稳特征，频率和阻尼参数随时间快速变化，呈现“起振迅速、幅值骤升、衰减迟缓”的典型复杂模态特性。本文方法通过增强 VMD 算法对多模态信号进行稳健分解，有效隔离出主导振荡分量；随后结合滑动时间窗内的贝叶斯推理建模，实现对频率与阻尼因子的动态辨识与趋势跟踪。辨识结果不仅展现出起振初期的系统发散特征，也揭示了振荡向稳定演化的过程，表明本文方法具备在强干扰下追踪振荡模式演化的能力，然后通过后验分布估计提供参数可信度量化，提升了辨识的解释



(a) 增强VMD分解结果 (b) IMF的FFT结果

图 7 所提增强 VMD 对实际振荡录波信号的分解

Fig.7 Decomposition of the proposed enhanced VMD for the real oscillation recording signal



(a) 频率参数多时窗辨识结果

(a) 衰减因子多时窗辨识结果

图 8 所提方法对主要振荡参数的辨识结果

Fig.8 Identification results of the main oscillation parameters by the proposed method

表 5 不同辨识算法波形重构效果对比

Table 5 Performance comparison of waveform reconstruction for different identification methods

方法	RMSE	MAE	R^2
Prony	0.142	0.108	0.905
SSI	0.121	0.097	0.942
DMD	0.138	0.111	0.923
本文方法	0.089	0.067	0.951

性与可靠性。

基于上述分析，本文方法可嵌入实际电网在线监测与事件分析流程中，作为对剧烈扰动下振荡模式的辅助识别工具。一方面，其高鲁棒性与动态识别能力可为后续振荡源定位、控制器投切等运维策略提供数据依据；另一方面，推理结果中的置信区间信息可作为辅助预警指标，有助于实现从“后验分析”向“前馈预警”的过渡。整体来看，该方法适用于模态频率变化剧烈、参数不可显式建模的复杂振荡过程，在提升系统运行态势感知水平方面具备良好的应用潜力。

4　结论

本文提出了一种基于双约束增强 VMD 和贝叶斯推理的电力系统振荡参数辨识方法，并通过仿真实验和现实中实际的振荡录波数据进行了验证，得到如下结论：

1）本文方法在传统 VMD 的基础上引入模态稀疏性约束和动态适应性调整策略，显著提高了分解精度和鲁棒性。通过多目标优化实现了模态稀疏性与分解效果的权衡，使得各模态信号的频带更加清晰，边界模态泄露问题显著减少，为信号分解质量的提升提供了新思路。

2）结合贝叶斯推理方法进行振荡参数辨识，能够有效地利用先验知识，提高辨识的精度和稳定性，尤其在低信噪比条件下表现出优越的抗噪性能，为振荡信号的高精度辨识提供了理论支持。

3）本文当前的研究重点聚焦于“已起振”状态下的模态参数识别，并未引入起振点的自动判别机制。未来研究可引入滑动窗口与能量门限的联合触发机制，并结合突变点检测算法定位起振时刻并动态调整分析窗口，以进一步提升本文方法在复杂非平稳扰动场景中的鲁棒性与实时响应能力。

参考文献　References

[1] 张智刚，康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报，2022，42(8)：2806-2818.
ZHANG Zhigang, KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2818.

[2] 谢小荣，贺静波，毛航银，等. “双高”电力系统稳定性的新问题及分类探讨[J]. 中国电机工程学报，2021，41(2)：461-474.
XIE Xiaorong, HE Jingbo, MAO Hangyin, et al. New issues and classification of power system stability with high shares of renewables and power electronics[J]. Proceedings of the CSEE, 2021, 41(2): 461-474.

[3] 王渝红，王馨瑶，廖建权，等. 交直流电网宽频振荡产生、辨识及抑制研究综述[J]. 高电压技术，2023，49(8)：3148-3162.
WANG Yuhong, WANG Xinyao, LIAO Jianquan, et al. Review of generation, identification and suppression of wide-band oscillation in AC-DC power system[J]. High Voltage Engineering, 2023, 49(8): 3148-3162.

[4] 马宁宁，谢小荣，贺静波，等. 高比例新能源和电力电子设备电力系统的宽频振荡研究综述[J]. 中国电机工程学报，2020，40(15)：4720-4731.
MA Ningning, XIE Xiaorong, HE Jingbo, et al. Review of wide-band oscillation in renewable and power electronics highly integrated power systems[J]. Proceedings of the CSEE, 2020, 40(15): 4720-4731.

[5] 吴天昊，谢小荣，姜齐荣. 风电系统次同步等幅振荡的机理与特性分析[J]. 中国电机工程学报，2023，43(7)：2689-2698.
WU Tianhao, XIE Xiaorong, JIANG Qirong. On subsynchronous sustained oscillation issues of wind power systems[J]. Proceedings of the CSEE, 2023, 43(7): 2689-2698.

[6] 谢小荣，李浩志. 电力系统振荡研究进展[J]. 科学通报，2020，65(12)：1119-1129.
XIE Xiaorong, LI Haozhi. Advances on power system oscillation[J]. Chinese Science Bulletin, 2020, 65(12): 1119-1129.

[7] 樊　陈，姚建国，张琦兵，等. 英国“8·9”大停电事故振荡事件分析及思考[J]. 电力工程技术，2020，39(4)：34-41.
FAN Chen, YAO Jianguo, ZHANG Qibing, et al. Reflection and analysis for oscillation of the blackout event of 9 August 2019 in UK[J]. Electric Power Engineering Technology, 2020, 39(4): 34-41.

[8] 吴　熙，陈　曦，吕　万，等. 电力系统次同步振荡检测与在线定位技术综述[J]. 电力自动化设备，2020，40(9)：129-141.
WU Xi, CHEN Xi, LÜ Wan, et al. Review of detection and online localization technology of sub-synchronous oscillation in power system[J]. Electric Power Automation Equipment, 2020, 40(9): 129-141.

[9] 靳宗帅，张恒旭，石　访，等. 宽频带同步测量技术与应用[J]. 中国电机工程学报，2022，42(7)：2497-2507.
JIN Zongshuai, ZHANG Hengxu, SHI Fang, et al. Synchronized wideband measurement technology and its applications[J]. Proceedings of the CSEE, 2022, 42(7): 2497-2507.

[10] 李振华，崔九喜，卢和平，等. 电力系统宽频宽动态电流量测技术研究综述[J]. 高电压技术，2024，50(8)：3421-3439.
LI Zhenhua, CUI Jiuxi, LU Heping, et al. Review of wideband and wide-dynamic-range current measurement techniques in power systems[J]. High Voltage Engineering, 2024, 50(8): 3421-3439.

[11] 孙名扬，王　艳，张琦兵，等. 电网宽频广域监测主站构建关键技术研究及应用[J]. 电网与清洁能源，2021，37(8)：84-91.
SUN Mingyang, WANG Yan, ZHANG Qibing, et al. Study and application of key technologies constructing power grid wide-frequency and wide-area monitoring system[J]. Power System and Clean Energy, 2021, 37(8): 84-91.

[12] 马宁宁，谢小荣，唐　健，等. “双高”电力系统宽频振荡广域监测与预警系统[J]. 清华大学学报(自然科学版)，2021，61(5)：457-464.
MA Ningning, XIE Xiaorong, TANG Jian, et al. Wide-area measurement and early warning system for wide-band oscillations in “double-high” power systems[J]. Journal of Tsinghua University (Science & Technology), 2021, 61(5): 457-464.

[13] HWANG J K, LIU Y L. Identification of interarea modes from ringdown data by curve-fitting in the frequency domain[J]. IEEE Transactions on Power Systems, 2017, 32(2): 842-851.

[14] LAURIA D, PISANI C. On Hilbert transform methods for low frequency oscillations detection[J]. IET Generation, Transmission & Distribution, 2014, 8(6): 1061-1074.

[15] ESTEVEZ P G, MARCHI P, MESSINA F, et al. Forced oscillation identification and filtering from multi-channel time-frequency representation[J]. IEEE Transactions on Power Systems, 2023, 38(2): 1257-1269.

[16] 张 程，邱炳林. 基于可调 Q 因子小波变换与稀疏时域法的电力系统低频振荡模态辨识[J]. 电力系统保护与控制，2022，50(13)：63-72.
ZHANG Cheng, QIU Binglin. Power system low frequency oscillation modal identification based on a tunable Q-factor wavelet transform and sparse time domain method[J]. Power System Protection and Control, 2022, 50(13): 63-72.

[17] 刘克天，胡新宇，李 想，等. 基于 EMD 和 TLS-Prony 的次同步振荡模态辨识方法及电压反馈抑制策略[J]. 太阳能学报，2023，44(11)：294-302.
LIU Ketian, HU Xinyu, LI Xiang, et al. Sub-synchronous oscillation modal identification method based on EMD and TLS-Prony algorithm and voltage feedback suppression strategy[J]. Acta Energiae Solaris Sinica, 2023, 44(11): 294-302.

[18] 李文博，钱伟荣，李淑蓉，等. 改进自适应 VMD 和 TLS-ESPRIT 的风电系统次/超同步振荡参数辨识[J]. 高电压技术，2025，51(1)：146-157.
LI Wenbo, QIAN Weirong, LI Shurong, et al. Improved adaptive VMD and TLS-ESPRIT sub/sup-synchronous oscillation parameter identification for wind power systems[J]. High Voltage Engineering, 2025, 51(1): 146-157.

[19] 李 磊，都成刚，王维兵，等. 基于改进 Prony 算法的新能源配网谐波和振荡复合扰动参数提取[J]. 电力系统及其自动化学报，2023，35(11)：152-158.
LI Lei, DU Chenggang, WANG Weibing, et al. Extraction of harmonic and oscillation composite disturbance parameters of new energy distribution network based on improved Prony algorithm[J]. Proceedings of the CSU-EPSA, 2023, 35(11): 152-158.

[20] 赵 妍，李志民，李天云. 低频振荡模态参数辨识的共振稀疏分解 SSI 分析方法[J]. 电工技术学报，2016，31(2)：136-144.
ZHAO Yan, LI Zhimin, LI Tianyun. Low frequency oscillation modal parameter identification using resonance-based sparse signal decomposition and SSI method[J]. Transactions of China Electrotechnical Society, 2016, 31(2): 136-144.

[21] 冯 双，崔 昊，陈佳宁，等. 人工智能在电力系统宽频振荡中的应用与挑战[J]. 中国电机工程学报，2021，41(23)：7889-7904.
FENG Shuang, CUI Hao, CHEN Jianing, et al. Applications and challenges of artificial intelligence in power system wide-band oscillations[J]. Proceedings of the CSEE, 2021, 41(23): 7889-7904.

[22] 秦心筱，张昌华，徐子豪，等. 基于卷积神经网络的电力系统低频振荡主导模态特征定性辨识[J]. 电力系统保护与控制，2021，49(10)：51-58.
QIN Xinxiao, ZHANG Changhua, XU Zihao, et al. Research on qualitative identification of a low frequency oscillations dominant mode in power system based on a convolutional neural network[J]. Power System Protection and Control, 2021, 49(10): 51-58.

[23] 王渝红，李晨鑫，周 旭，等. 压缩感知和图卷积神经网络相结合的宽频振荡扰动源定位方法[J]. 高电压技术，2024，50(3)：1080-1089.
WANG Yuhong, LI Chenxin, ZHOU Xu, et al. Localization method of wide-band oscillation disturbance sources based on compressed sensing and graph convolutional neural networks[J]. High Voltage Engineering, 2024, 50(3): 1080-1089

[24] 陈 祥，杨志强，田 镇，等. GA-VMD 与多尺度排列熵结合的 GNSS 坐标时序降噪方法[J]. 武汉大学学报(信息科学版)，2023，48(9)：1425-1434.
CHEN Xiang, YANG Zhiqiang, TIAN Zhen, et al. Denoising method for GNSS time series based on GA-VMD and multi-scale permutation entropy[J]. Geomatics and Information Science of Wuhan University, 2023, 48(9): 1425-1434.



段俊峰
1995—，男，博士生
主要从事电能计量设备可靠性、电力系统稳定性分析以及电力态势感知方面的研究工作
E-mail: duanjunfeng@hnu.edu.cn

DUAN Junfeng
Ph.D. candidate



姚文轩(通信作者)
1988—，男，博士，教授，博导
主要从事广域测量系统与态势感知、电力传感与电力测量用方面的研究工作
E-mail: wenxuanyao@hnu.edu.cn

YAO Wenxuan
Ph.D., Professor
Corresponding author

收稿日期 2025-05-25 在线出版日期 2025-10-10 编辑 卫李静