

DOI:10.19651/j.cnki.emt.2416027

基于VMD的风机次同步振荡模态辨识方法研究^{*}

张彬彬 李聪 陈超波 王坤 李继超

(西安工业大学电子信息工程学院 西安 710021)

摘要: 针对变分模态分解算法在对风电并网过程中产生的次同步振荡信号进行分解时受噪声干扰、关键参数难以确定,导致的辨识精度不足问题,本文提出一种基于小波阈值去噪(WTD)和遗传算法(GA)优化变分模态分解(VMD)的信号分解算法,结合自回归滑动模型(ARMA)的次同步振荡模态辨识方法。首先,采用小波阈值对风电机组输出的有功功率进行去噪处理;其次,使用VMD对去噪后的信号进行分解,得到K个本征模态分量,为得到最优VMD分解效果,采用自适应遗传算法对惩罚因子 α 及模态分解层数K进行优化;最后,将信号重构并建立ARMA模型,直接辨识出次同步振荡信号的频率和阻尼比。通过仿真实验平台搭建直驱风电机组并网模型,采集次同步振荡信号进行模态辨识。仿真结果表明,与其他辨识算法相对比,所提出的基于VMD的方法具有更好的可行性和优越性。

关键词: 直驱风电机组;次同步振荡;变分模态分解;参数辨识

中图分类号: TM933;TN751.3 文献标识码: A 国家标准学科分类代码: 480.6040

Research on sub-synchronous oscillation mode identification method based on VMD for wind turbines

Zhang Binbin Li Cong Chen Chaobo Wang Kun Li Jichao

(School of Electronic Information Engineering, Xi'an University of Technology, Xi'an 710021, China)

Abstract: Regarding the problem of insufficient identification accuracy caused by noise interference and difficult determination of key parameters when using the variational mode decomposition (VMD) algorithm to decompose the sub-synchronous oscillation signals generated during the grid connection process of wind power, this paper proposes a signal decomposition algorithm based on wavelet threshold denoising (WTD) and genetic algorithm (GA) optimized VMD, combining with the sub-synchronous oscillation mode identification method of autoregressive moving average model (ARMA). Firstly, wavelet threshold denoising is used to process the active power output of the wind turbine; secondly, VMD is used to decompose the denoised signal, obtaining K intrinsic mode components. In order to achieve the optimal VMD decomposition effect, an adaptive genetic algorithm is used to optimize the penalty factor α and the number of decomposition layers K. Finally, the signal is restructured and an ARMA model is established to directly identify the frequency and damping ratio of the sub-synchronous oscillation signal. By building a simulation experiment platform for direct-drive wind turbine grid connection model and collecting sub-synchronous oscillation signals for mode identification, the simulation results show that, compared with other identification algorithms, the proposed VMD-based method has better feasibility and superiority.

Keywords: direct-drive permanent magnet synchronous wind turbine generator; sub-synchronous oscillation; variational mode decomposition; parameter identification

0 引言

近几年,在“双碳”目标的背景下,风力发电等一些清洁能源的规划与建设步伐持续加快。截至2022年底,我国风能的装机容量超过330GW^[1]。然而,我国风电场多分布在

西北地区,需要对这些风电场产生的电能进行远距离传输。在这个过程中,大量电力电子设备极易诱发次同步振荡(sub-synchronous oscillation, SSO),严重威胁了电力系统的稳定运行^[2]。因此,能够精确、迅速、有效地识别SSO模态参数,对于抑制次同步振荡问题至关重要。

收稿日期:2024-05-13

* 基金项目:陕西省教育厅专项科研项目(22JK041)资助

目前,国内外学者针对次同步振荡模态参数辨识的方法主要分为两大类:基于传统算法辨识和基于机器学习的辨识方法:

基于传统算法的SSO模态参数辨识在风电并网系统SSO分析中占据大部分,主要包括傅里叶变换^[3-4](Fourier transform, FFT)、希尔伯特变换^[5](Hilbert-Huang transform, HHT)、Prony算法^[6-7]等。文献[3]使用FFT对SSO信号进行辨识,这种方式能够增加模态辨识的效率,同时减少了模态辨识的时间,但是却无法辨识信号的瞬时频率和衰减因子。文献[4]使用FFT针对电力系统的SSO信号进行辨识,但在面对这种含噪且非平稳的SSO信号时,FFT难以进行全局分析,且分析结果误差较大。文献[5]使用HHT进行分析,但在噪声环境下出现了端点效应与模态混叠问题,因此在对含噪的SSO信号进行辨识时容易出现虚假的模态。文献[6]使用Prony算法可以直接对特征信号进行提取辨识,以获得SSO模态的幅值、频率和衰减因子等信息,然而,在分析含噪声的SSO时,该方法误差较大;文献[7]采用经验小波分解去除信号中的噪声,以改善Prony算法对噪声信号较为敏感的缺点,然而,在去噪过程中可能会导致虚假模态和模态遗漏的问题。

随着机器学习技术的发展,将其应用于SSO模态参数辨识领域成为一种新的方法。文献[8]运用卷积神经网络对SSO数据进行训练,不但缩短了辨识过程中的数据窗长,还提升了辨识效率;文献[9]将二维卷积神经网络改成一维卷积神经网络,直接接收一维的振动波形数据作为输入,通过多层卷积和池化处理,高效地提取出SSO中的模态参数。文献[10]建立了一种融合卷积层、若干残差层和全连接层的深度残差网络模型,专门用于训练SSO数据。这一类方法虽然在处理大规模SSO数据上具有一定的优势,但是对数据的质量要求高,且建模过程较为复杂。

以上的方法均不能解决非线性、非稳态的问题。而变分模态分解(variational mode decomposition, VMD)是一种适用于处理不确定性和非稳定性数据的信号处理技术^[11]。该方法具有出色的分解能力,可以有效地分离信号中的不同谐波成分,并允许有效地观察信号随时间的变化情况,但该方法对噪声较为敏感,并且其惩罚因子 α 及模态分解层数 K 难以获得^[12]。因此,本文先采用小波阈值对信号进行去噪处理,后选用遗传算法(genetic algorithm, GA)对VMD的 α 和 K 进行寻优处理。针对最终的模态参数辨识,自回归滑动模型(auto regressive moving average, ARMA)能够高效的捕捉时间序列数据的动态性能,从而精确辨识SSO信号的模态参数,包括频率和阻尼比等^[13-14]。

综上,本文将小波阈值去噪、变分模态分解和自回归滑动模型三种算法相结合,应用于风电并网系统产生的次同步振荡模态参数的辨识中。首先,使用小波变换对SSO信号进行多尺度分解,通过精细的小波阈值设定,滤除信号中

的噪声成分,保留与次同步振荡相关的有用信息;随后,使用遗传算法优化的VMD将信号分解成多个本征模态分量;最后对信号进行重构,通过建立ARMA模型拟合与参数估计,精确地辨识出SSO的模态参数。通过理想信号与仿真信号的双重分析,本文所提出的方法在风电并网系统次同步振荡模态参数的准确辨识中得到了有效验证,证明了其在实际应用中的可靠性和准确性。

1 小波分析

小波阈值去噪是由Donoho提出的一种基于小波变换的去噪方法^[15],主要过程如下:

首先,选取适当的子波分解层数和合适的小波基函数对含有噪声的信号进行小波分解。

其次,分解后的小波系数需要选择合适的阈值函数对其进行处理。通过阈值函数将受噪声影响的小波系数置为零,从而进行去噪操作,并保持特征信号。

最后,应用小波逆变换技术,恢复阈值小波系数,准确得到去噪信号。

小波阈值中参数的选择是最重要的。小波变换和小波逆变换是小波基函数下的变换,它们的表达式分别如下:

$$WT_f(a, \tau) = [f(t), \psi_{a, \tau}(t)] = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \varphi^* \left(\frac{t-\tau}{a} \right) dt \quad (1)$$

$$f(t) = \frac{1}{C_\psi} \int_0^{+\infty} \frac{da}{a^2} \int_{-\infty}^{+\infty} WT(a, \tau) \frac{1}{\sqrt{a}} \psi \left(\frac{t-\tau}{a} \right) dt \quad (2)$$

式中: a 是热胀冷缩量; τ 为平移量; $\psi(t)$ 是小波基函数; $WT_f(a, \tau)$ 是小波系数。对于阈值函数的选择,本文拟选用硬阈值函数。

对于硬阈值,小于阈值的小波系数置零,大于阈值的小波系数保留,表达如下:

$$\hat{W}_{j,k} = \begin{cases} W_{j,k}, & |W_{j,k}| \geq THr \\ 0, & |W_{j,k}| < THr \end{cases} \quad (3)$$

式中: Thr 为经典阈值,表达式如下:

$$THr = \epsilon \sqrt{2|lgN|} \quad (4)$$

2 变分模态分解及其优化

2.1 变分模态分解

变分模态分解是Dragomiretskiy于2014年提出的一种新型信号处理技术,该方法融合了数学严谨性与实际应用的灵活性,不仅重构了非定常信号的时域特征,而且还精确描述了信号的频域构成^[16],其基本思路把原始信息分解成一组相对稀疏的离散本征模态分量(intrinsic mode functions, IMF),一般简称为子模式。该方法通过对各个IMF的最大核心频率和带宽进行不断的改变,以便使目标函数实现最优化,进而求得各种最大核心带宽的IMF分量^[17]。

在VMD算法中,可将IMF定义为:

$$u_k(t) = A_k(t)\cos\phi_k(t) \quad (5)$$

式中: $A_k(t)$ 为 $u_k(t)$ 的瞬时幅值。

$$\omega_k = \phi'_k(t) = \frac{d\phi_k(t)}{dt} \quad (6)$$

式中: $\omega_k(t)$ 是 $u_k(t)$ 的瞬时频率。

VMD 的具体分解过程描述如下:

1) 对于每个模态分量 $u_k(t)$ 进行希尔伯特变换, 即可得到各模态分量的解析信号:

$$(\delta(t) + \frac{j}{\pi t}) * u_k(t) \quad (7)$$

2) 通过将解析信号乘以估计的中心频率, 将单边频谱移至相应的基带:

$$\left[(\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \quad (8)$$

3) 利用高斯平滑法对各模态的带宽进行估算, 进而建立了 VMD 的变分限制的数学模型:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ s. t. \sum_k u_k = f(t) \end{cases} \quad (9)$$

式中: $f(t)$ 为原始输入信号, $\{u_k\}$ 为分解后每个 IMF 的模态分量; $\{\omega_k\}$ 为分解后每个 IMF 的中心频率。 ∂_t 为狄拉克函数; $*$ 表示为卷积算子。

4) 引入拉格朗日乘子 λ 和惩罚因子 α 来变换方程。转化为非约束变分问题, 可表示为:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (10)$$

5) 利用交替方向乘法 (ADMM) 交替对以上推广的拉格朗日函数鞍点进行迭代计算^[18], 得到 $\{u_k\}$ 、 $\{\omega_k\}$ 的最优解, 结果如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (11)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (12)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau(\hat{f}(\omega) + \sum_k \hat{u}_k^n(\omega) - f(\omega)) \quad (13)$$

式中: $\hat{f}(\omega)$ 、 $\hat{u}_i^n(\omega)$ 、 $\hat{\lambda}^n(\omega)$ 分别代表 $f(t)$ 、 $u_i(t)$ 、 $\hat{\lambda}(t)$ 的傅立叶变换。直至满足式(14)的条件, 迭代终止。

$$\sum_k \frac{\|\hat{u}_k^{n+1} - u_k^n\|_2^2}{\|u_k^n\|_2^2} < \epsilon \quad (14)$$

最后, 可以得到 k 个 IMF 作为 VMD 的结果。

2.2 遗传算法优化 VMD

VMD 作为一种信号分解算法, 其分解效果易受惩罚

因子和模态分解层数的影响, 因此本文拟采用适当的优化算法对其参数进行调整。相较于其他智能优化算法, 遗传算法具有更强的全局搜索能力和更成熟的收敛分析方法。因此, 本文使用遗传算法对 VMD 的参数进行优化。GA-VMD 的算法步骤如下:

1) 确定遗传算法的参数, 并将优化目标函数表示为:

$$C = \min \sum_{i=1}^K \frac{E_i}{K} \quad (15)$$

约束条件可以表示为:

$$s. t. \begin{cases} K_{\min} \leq K_i \leq K_{\max} \\ a_{\min} \leq a_i \leq a_{\max} \\ K \in N_+, a \in N_+ \end{cases} \quad (16)$$

式中: K 为最佳 IMF 的个数, $i (i=1, 2, 3, \dots)$ 为原始信号分解得到的 IMF 序列, E_i 表示第 i 个 IMF 的包络熵, C 为目标函数, a_i 为第 i 个 IMF 的惩罚因子, K_i 为第 i 个 IMF 的最优 IMF 数, N 为自然数。

2) 初始化种群, 即 VMD 参数 $[K, \alpha]$ 。

3) 将总体输入 VMD 以获得 IMF, 计算所有 IMF 的平均包络熵作为适应度函数, 并保存最小平均包络熵及对应的 VMD 参数 $[K, \alpha]$, 包络熵可以表示为:

$$\begin{cases} P_{i,j} = \frac{a_i(j)}{\sum_{j=1}^N a_i(j)} \\ E_i = - \sum_{j=1}^N P_{i,j} \lg P_{i,j} \end{cases} \quad (17)$$

式中: $a_i(j)$ 是信号 $IMF_i(j)$ 经过希尔伯特调制后得到的包络信号, $P_{i,j}$ 是信号 $a_i(j)$ 的归一化形式。

4) 评价种群中所有个体的适应度, 即参数组合, 淘汰不合格的个体。

5) 在种群中, 按照最大的适应值选取最大的选择可能性, 选择出两个个体分别为父方和母方。通过二元交叉和变异产生后代;

6) 重复步骤 4) 和 5), 更新种群;

7) 循环步骤 3)~6), 直至完成最大迭代次数;

8) 选择步骤 7) 中得到的每次迭代的局部最小平均包络熵的最小值作为本次优化的全局最小值, 其对应的参数组合 $[K, \alpha]$ 为本次优化得到的最佳参数组合。

GA-VMD 的算法流程图如图 1 所示。

3 ARMA 模型

次同步振荡的特性显著受到风速波动、串联补偿度等多种复杂因素的影响, 这些可以在本质上被视为一系列具有随机特性的扰动因素的集合体, 从系统角度来看, 可以进一步将这些多扰动组合视为高斯白噪声^[19]。ARMA 模型的本质是, 当假设输入信号为白噪声时, 系统的高阶微分方程可以表示为微分形式^[20-21]。因此, 可以用 ARMA 模型的随机差分方程形式来描述系统的响应。

3.1 ARMA 模型的建立

经过处理重构后的次同步振荡信号可以看作平均、零

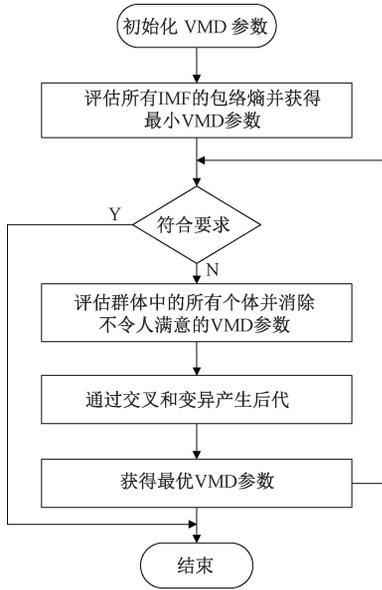


图1 GA-VMD算法步骤

Fig.1 GA-VMD algorithm steps

均值的时间序列 $\{X_t\} (t = 1, 2, \dots)$, 对其及建立 ARMA 模型, 如式(18):

$$X_t - \sum_{i=1}^N \alpha_i X_{t-i} = Y_t - \sum_{j=1}^M \beta_j Y_{t-j}, Y_t \sim L(0, \sigma^2) \quad (18)$$

式中: X_t 时间序列 $\{X_t\}$ 在 t 时刻的元素; Y_t 为随机小扰动 $\{Y_t\}$ 在 t 时刻的元素, 其 t 个元素应为高斯白噪声; $\alpha_i (i = 1, 2, \dots, N)$ 为自回归(auto regressive model, AR)模型的系数; $\beta_j (j = 1, 2, \dots, M)$ 为滑动平均(moving average, MA)模型的系数。N为AR模型的阶次, M为MA模型的阶次。L代表正态分布。

3.2 ARMA模型的定阶

ARMA模型的阶次精度对识别系统的精度有很大的影响。若模型阶次太高, 则含有太多无关的振动成份; 相反, 如果模型阶次太低, 振动模态的信息就不能被覆盖^[22]。所以, 只有对ARMA模型进行合适的定阶, 才能更全面地反映其模型性能。

确认ARMA模型阶次的经典方法主要有赤池信息量准则(AIC)、贝叶斯信息准则(BIC)、残差平方和法、F检验法等。其中, AIC准则因其灵活性, 常被优先考虑评估高阶模型; 残差平方和法虽然能够直观反映残差减少的显著性, 却因其缺乏一个统一且明确的量化标准; F检验法的应用受到较为严格的先决条件限制, 且需预先设定显著性水平, 这些因素在一定程度上限制了其广泛应用和灵活性。因此, 本文选用BIC准则对ARMA模型进行定阶, 该准则本质上是对AIC准则的改进。BIC准则的函数如下:

$$\delta_{BIC}(p) = L \ln \sigma^2 + p \ln L \quad (19)$$

式中: L 为数据长度, $p (p = M + N)$ 为ARMA模型的阶数。

3.3 ARMA模型参数估计

ARMA模型进行次同步参数辨识的关键在于参数估计, 本文考虑采用遗忘因子的加权递推最小二乘法进行参数估计^[23]。对式(19)变换得到如下:

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_N X_{t-N} - \beta_1 Y_{t-1} - \beta_2 Y_{t-2} - \dots - \beta_M Y_{t-M} + Y_t \quad (20)$$

将式(20)中的高斯白噪声 $\{Y_t\}$ 用其估计值 $\{\hat{Y}_t\}$ 近似代替, 可以得到以下的最小二乘公式:

$$X_t = \alpha^T \beta + Y_t \quad (21)$$

式中: β 为ARMA模型参数向量; α^T 为伪测量向量。 $\beta = [\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_N, \beta_1, \beta_2, \beta_3, \dots, \beta_M]^T$; $\alpha^T = [X_{t-1}, X_{t-2}, \dots, X_{t-N}, -\hat{Y}_{t-1}, -\hat{Y}_{t-2}, \dots, -\hat{Y}_{t-M}]$ 。

为了强调新近数据的作用, 引入遗忘因子 $\theta (0 < \theta < 1)$ 来反映系统相对于当前时刻数据的可靠性和过去时刻数据的忽略的时间变异性。定义加权准则函数为:

$$J(\beta) = \sum_{k=N+1}^t \theta^{t-k} (X_k - \alpha^T \beta)^2 \quad (22)$$

式中: t 代表当前时刻, 遗忘因子 θ 体现了模型在递归更新过程中对历史数据遗忘的速率, 取值范围通常设定在 $0.95 \sim 0.99$, 这一范围确保了模型既能够适当地保留历史信息, 又能够灵活地适应新的数据变化, 从而在两者之间达到一个平衡。

可以证明, 加权准则函数最小化时模型参数的估计公式为:

$$\begin{cases} \hat{\beta}_{t+1} = \hat{\beta}_t + K_{t+1} (X_{t+1} - \alpha_{t+1}^T \hat{\beta}_t) \\ K_{t+1} = \frac{P_t \alpha_{t+1}}{\theta + \alpha_{t+1}^T P_t \alpha_{t+1}} \\ P_{t+1} = \frac{1}{\theta} \left(1 - \frac{P_t \alpha_{t+1}}{\theta + \alpha_{t+1}^T P_t \alpha_{t+1}} \right) P_t \end{cases} \quad (23)$$

式中: K_t, P_t 为迭代过程中的中间变量; $\hat{\beta}_t$ 为 β_t 在迭代过程中的估计值, 且 $\hat{\beta}(0) = 0$; I 为 $(N+M)$ 阶单位矩阵, 且 $P(0) = \mu I$ (取 $\mu = 10^5$)。

估计ARMA模型的参数后, 可得到对应的离散信号 $\{X_t\}$ 的特征方程如下:

$$1 - \alpha_1 z^{-1} - \alpha_2 z^{-2} - \dots - \alpha_N z^{-N} = 0 \quad (24)$$

式中: z 为系统特征方程的特征根。

对特征方程(24)进行求解, 可以直接获取到系统的组合特征根 λ_h 和 λ_h^* ($h = 1, 2, \dots, \eta$), η 为系统次同步振荡模态次数。接下来, 为了将这些分析应用于实际控制系统模型, 将模型参数从 z 域转换到 s 域。这一转换过程结合后续的推导, 基于自回归滑动平均模型的框架下, 推导出次同步振荡模态参数的精确计算公式, 如下:

$$\begin{cases} f_h = \frac{\sqrt{\ln \lambda_h \ln \lambda_h^*}}{2\pi\delta} \times \sqrt{1 - \xi_h^2} \\ \xi_h = -\frac{\ln |\ln \lambda_h|}{\sqrt{\ln \lambda_h \ln \lambda_h^*}} \end{cases} \quad (25)$$

式中: δ 为采样时间间隔; f_h 为次同步振荡频率; ξ_h 为对应次同步振荡阻尼比。

4 基于 WTD-VMD-ARMA 次同步模态参数辨识流程

本文提出的基于 WTD-VMD-ARMA 的次同步振荡模态参数辨识流程图如图 2 所示,具体步骤如下:

步骤 1) 将风电并网系统中产生的次同步振荡信号当作原始输入数据;

步骤 2) 采用小波阈值去噪方法,对原始信号进行降噪处理,以减少噪声对后续分析的干扰,提高信号质量;

步骤 3) 采用遗传算法优化 VMD 得到合适的参数,再进行 VMD 分解得到 K 个本征模态分量,然后重构信号;

步骤 4) 对重构的信号建立 ARMA 模型;

步骤 5) 根据 BIC 准则确定 ARMA 模型的阶数,如果测量信号变化较大,则 AR 和 MA 部分模型都需要进行合理修正;

步骤 6) 利用式 (25) 对次同步振荡模态相关参数进行计算。

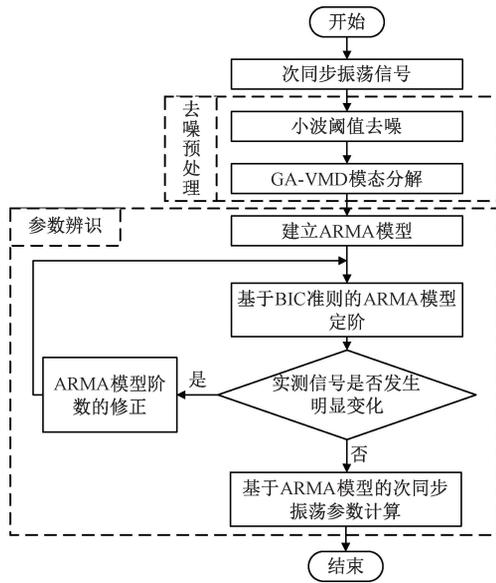


图 2 次同步振荡模态辨识流程

Fig. 2 Sub-synchronous oscillation mode identification flow

5 算例信号分析

5.1 理想信号分析

构造理想次同步振荡信号 $x(t)$:

$$x(t) = x_1(t) + x_2(t) + x_3(t) \tag{26}$$

式中:

$$\begin{cases} x_1(t) = 1.8e^{-0.15t} \cos(2\pi \times 15.7t + \frac{\pi}{3}) \\ x_2(t) = 2.4e^{-0.27t} \cos(2\pi \times 20.2t + \frac{\pi}{6}) \\ x_3(t) = 3.0e^{-0.60t} \cos(2\pi \times 32.2t + \frac{\pi}{4}) \end{cases} \tag{27}$$

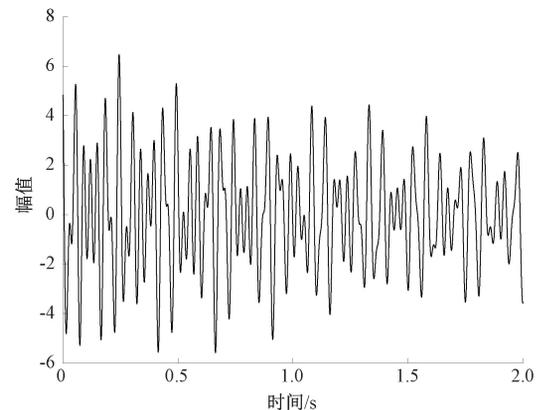
由式(28)可得该信号的主要参数如表 1。

表 1 理想信号参数

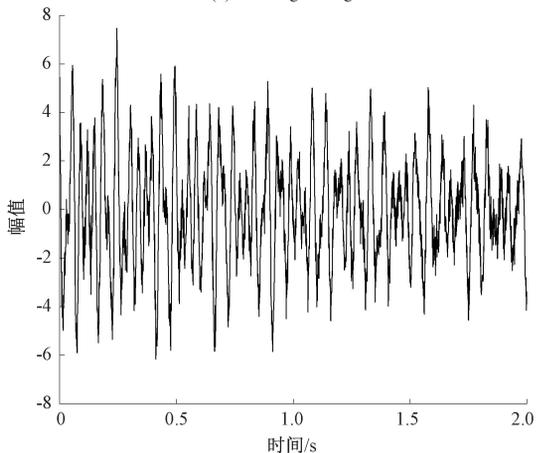
Table 1 Ideal signal parameters

振荡模态	幅值	频率/Hz	衰减因子	阻尼比/%
1	1.8	15.7	-0.15	0.152
2	2.4	20.2	-0.27	0.213
3	3	32.2	-0.6	0.297

为了验证本文算法在噪声环境下的有效性,首先在上述理想信号中添加了 SNR=5 dB 的高斯白噪声,然后对加噪的信号进行进一步处理。采用 5 层分解、db 5 小波基对信号进行平滑去噪,图 3 显示了去噪前后的效果图以及原始信号。可以看出,小波阈值去噪效果良好,为进一步处理信号奠定了基础。



(a) 原始信号
(a) The original signal



(b) 含噪原始信号
(b) Noisy original signal

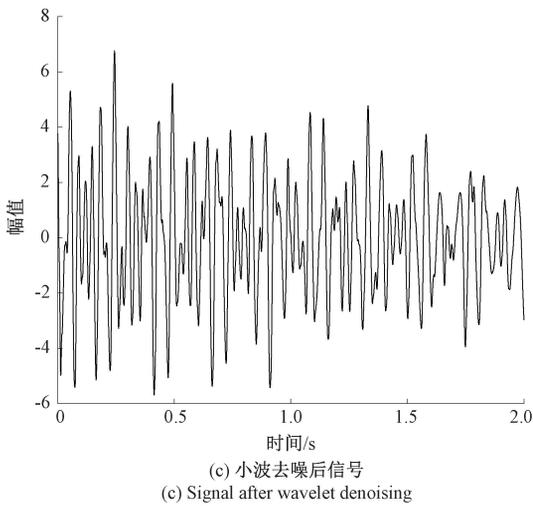


图3 原信号和去噪后的信号

Fig. 3 Original signal and denoised signal

针对复杂、非线性、非稳态的次同步振荡, VMD是一种新的自适应时频信号分解算法, 能将信号分解为不同尺度波动或趋势成分的固有模态分量^[24]。它具有较好的抗噪能力, 可以避免传统分解算法 EMD 模态混淆的问题, 只需要选择合适的惩罚因子 α 及模态分解层数 K 就能对信号进行准确的分解。因此, 本文选择使用遗传算法来优化 VMD 参数。通过遗传算法优化 VMD 后得到的结果如图 4 所示, 可以看到最优参数是 $\alpha = 2\ 310$, $K = 9$ 。基于最优参数, 图 5 展示了 VMD 在最优参数下的各个模态分解图。

为验证本文所提出方法的有效性, 除了使用本文方法外, 分别与基于经验模态分解(EMD)的 Prony 算法^[25]和基于多同步压缩变换(MSST)的希尔伯特变换^[26](HT)所使用的算法对信号进行辨识, 得到的结果如表 2 所示。

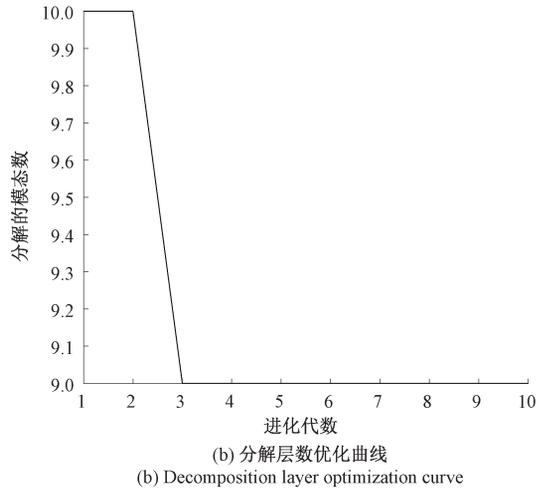
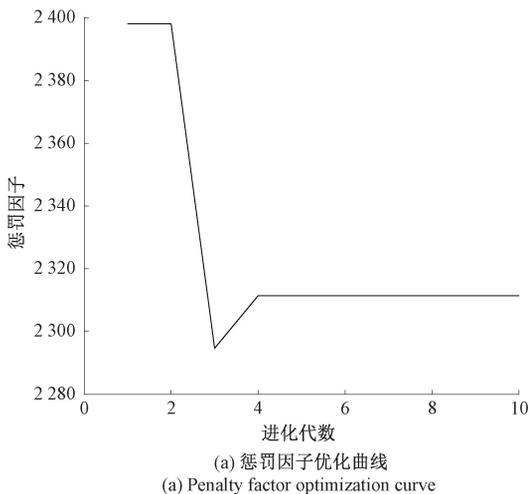


图4 遗传算法优化 VMD

Fig. 4 Genetic algorithm optimizes VMD

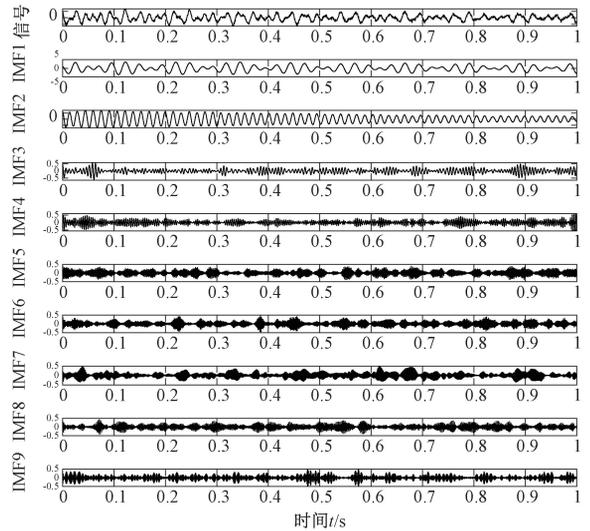


图5 SSO 模态分解图

Fig. 5 SSO modal decomposition diagram

表2 3种辨识方法的结果对比

Table 2 Comparison of the results of the 3 identification methods

方法	频率		阻尼比	
	数值/Hz	误差/%	数值	误差/%
本文方法	15.832	0.840	0.156	2.63
	20.314	0.564	0.217	1.87
	32.347	0.456	0.303	2.02
EMD-Prony	15.911	1.343	0.161	5.92
	20.512	1.544	0.229	7.51
MSST-HT	32.671	1.462	0.316	6.39
	15.871	1.089	0.159	4.60
	20.012	0.930	0.226	6.10
	32.538	1.049	0.318	9.09

根据表 2 所示结果,3 种辨识方法均能有效辨识次同步振荡信号的振荡模态参数。本文提出的基于 WTD-VMD-ARMA 的方法在频率和衰减因子方面比另外两种算法具有更高的识别精度,在频率上的辨识误差可以控制在 0.84% 以内,在衰减因子上的辨识误差可以控制在 3% 以内。

经过对测试信号的 FFT 分析后,其结果如图 6 所示。测试信号的频谱图显示出主导地位的模态分量分别为 15.7、20.2 和 32.2。与传统 FFT 变换相比,基于 WTD-VMD-ARMA 方法得出的次同步振荡模态参数基本一致,证实了本文算法的有效性和准确性。

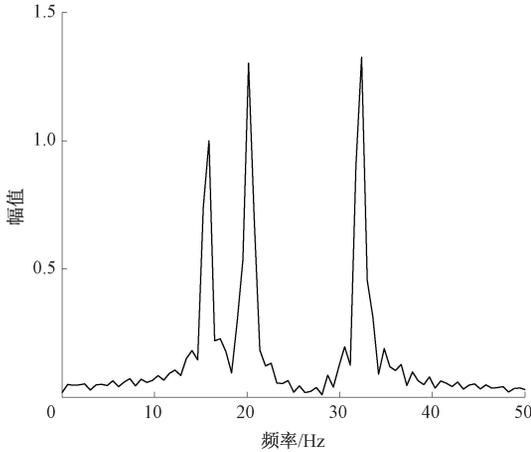


图 6 测试信号的 FFT 分析

Fig. 6 FFT analysis of test signals

5.2 风电场仿真信号

为进一步验证本文所提出的辨识方法的有效性,在 MATLAB/Simulink 中搭建直驱风力发电机 (direct-drive permanent magnet synchronous wind turbines, D-PMSG) 并网模型,如图 7 所示,通过调整相关参数产生次同步振荡信号来进行辨识。直驱风机经串补并入电压等级为 161 kV 的电网,单台风机容量为 1.5 WM,风力机数量为 66 台。整个仿真过程保持恒定风速 15 m/s,开始通过设置合适的电网参数使系统处于稳定运行状态,在 $t=2$ s 时,投入串补度 50%,得到的 D-PMSG 有功功率的波形如图 8 所示。可以看到,在 $t=0\sim 2$ s 之间,D-PMSG 输出的有功功率稳定在 100 WM; $t=2\sim 5$ s,由于开始投入串补度,输出的有功功率开始不稳定,其波形上下波动呈发散趋势,无法收敛,由此判断出现次同步振荡现象。

为分析 D-PMSG 并网在串补作用下系统发生次同步振荡模态的模态参数。选取图 8 中振荡开始时 2~3 s 时间段,对其进行采样,其结果如图 9 所示。

先使用小波阈值对风电机组产生的有功功率信号进行降噪处理,再使用参数优化下的 VMD 算法对信号进行分解,然后重构信号,并直接对重构后的信号建立 ARMA 模型,辨识出其频率和阻尼比,得到的结果如表 3 所示。

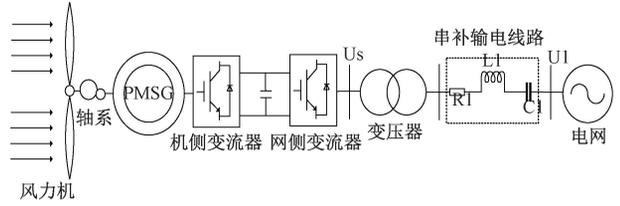


图 7 D-PMSG 并网结构图

Fig. 7 D-PMSG grid-connected structure diagram

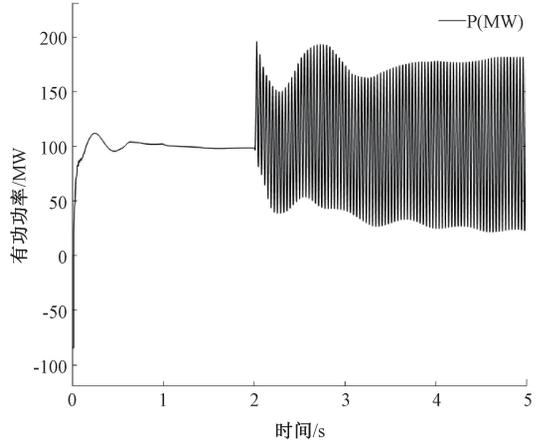


图 8 D-PMSG 输出的有功功率

Fig. 8 D-PMSG output active power

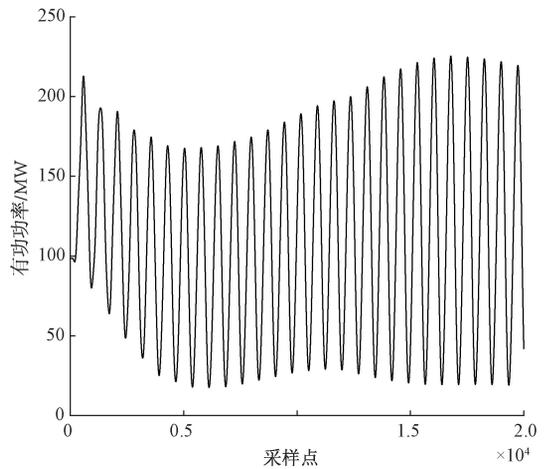


图 9 输出有功功率采样信号

Fig. 9 Output active power sampling signal

表 3 WTD-VMD-ARMA 模型辨识结果

Table 3 WTD-VMD-ARMA model identification results

方法	模式	频率/Hz	阻尼比
WTD-VMD-ARMA	1	15.345 1	-0.171 1
	2	37.175 8	0.027 4

根据表 3 的辨识结果,D-PMSG 输出的有功功率显现出双重振荡特性。模式 1 呈现出一种负阻尼的特性,若未采取相应措施进行抑制,这一特性将会加剧系统的 SSO 现

象;而模式2则表现为较小的正阻尼比,其值接近于零,反映出一种弱阻尼特性,虽然对系统整体性能的影响相对较小,但仍需关注其潜在的累积效应。

6 结 论

本文针对传统的次同步振荡模态辨识精度不足问题,提出了基于WTD-VMD-ARMA的模态辨识方法。首先利用小波阈值对原始信号进行去噪处理,克服了变分模态分解的精度易受噪声影响的问题。其次,使用遗传算法优化变分模态分解的惩罚因子和分解层数,得到的结果不论是分解效果还是迭代次数都优于传统变分模态分解算法。接着,基于优化后的VMD结果重构信号,并进一步建立ARMA模型进行辨识,提取关键的模态参数。最后,对理想信号和风电场仿真信号的研究表明,本文所提出的方法,有效地从SSO信号提取相关的模态参数,为下一步设计SSO现象的抑制措施,奠定了一定的理论基础。

参考文献

- [1] 杨秀,胡浩然,李增尧,等. 风电场交直流并网次/超同步振荡交互影响[J]. 电力建设,2022,43(1):49-62.
YANG X, HU H R, LI Z Y, et al. Frequency/super synchronous oscillation interaction of AC/DC grid-connected wind farms[J]. Power Construction, 2022, 43(1): 49-62.
- [2] 马闻达,王西田,解大. 大规模风电场并网系统次同步振荡功率传播特性研究[J]. 中国电机工程学报,2020,40(16):5217-5229.
MA W D, WANG X T, XIE D. Study on sub synchronous oscillation power transmission characteristics of large-scale wind farm grid-connected system[J]. Chinese Journal of Electrical Engineering, 2020, 40(16): 5217-5229.
- [3] 杨京,王彤,唐俊刺. 基于滑窗FFT的次同步振荡时变幅频在线监测方法[J]. 中国电力,2020,53(11):139-146.
YANG J, WANG T, TANG J C. On-line monitoring method of time-varying amplitude and frequency of sub-synchronous oscillation based on sliding window FFT[J]. China Power, 2020, 53(11): 139-146.
- [4] 姜涛,刘方正,陈厚合,等. 基于多通道快速傅里叶小波变换的电力系统主导振荡模式及模态协同辨识方法研究[J]. 电力自动化设备,2019,39(7):125-132.
JIANG T, LIU F ZH, CHEN H H, et al. Study on dominant oscillation mode and mode identification method based on multi-channel fast Fourier wavelet transform[J]. Power Automation Equipment, 2019, 39(7): 125-132.
- [5] 童涛,张新燕,孔德钱,等. 基于同步挤压变换的电力系统谐波分析[J]. 太阳能学报,2021,42(8):49-56.
TONG T, ZHANG X Y, KONG D Q, et al. Harmonic analysis of power system based on synchronous extrusion transform[J]. Journal of Solar Energy, 2021, 42(8): 49-56.
- [6] 公茂法,蔡芬,刘秀杰等. 基于数学形态学和改进Prony算法的谐波与间谐波参数估计[J]. 电测与仪表,2018,55(11):25-29,40.
GONG M F, CAI F, LIU X J, et al. Harmonic and inter-harmonic parameter estimation based on mathematical morphology and improved Prony algorithm[J]. Electrical Testing and Instrumentation, 2018, 55(11): 25-29,40.
- [7] 刘鹏翔,贾燕冰,罗宇恒. 基于EWT和改进Prony算法的含风电区域电网低频振荡模态及影响因素研究[J]. 电测与仪表,2021,58(5):46-54.
LIU P X, JIA Y B, LUO Y H, et al. Study on low frequency oscillation modes and influencing factors of regional power grid with wind power based on EWT and improved Prony algorithm [J]. Electrical Measurement and Instrumentation, 2021, 58(5): 46-54.
- [8] 陆友文,崔昊,陈佳宁,等. 基于RA-CNN和同步相量的风电场次/超同步振荡参数智能辨识方法[J]. 中国电力,2023,56(4):46-55,67.
LU Y W, CUI H, CHEN J N, et al. An intelligent identification method of wind farm sub/super synchronous oscillation parameters based on RA-CNN and synchronous phasor [J]. China Power, 2023, 56(4): 46-55,67.
- [9] 方宁,周宇,叶庆卫,等. 基于无监督学习卷积神经网络的振动信号模态参数识别[J]. 计算机应用,2017,37(3):786-790,822.
FANG N, ZHOU Y, YE Q W, et al. Modal parameter identification of vibration signal based on unsupervised learning convolutional neural network [J]. Computer Applications, 2017, 37(3): 786-790,822.
- [10] 况且,李娟,白淑华. 基于深度残差网络的SSO模态参数辨识[J]. 电子测量技术,2022,45(11):57-63.
KUANG Q, LI J, BAI SH H. SSO modal parameter identification based on depth residual network [J]. Electronic Measurement Technology, 2022, 45(11): 57-63.
- [11] 徐衍会,刘慧,成蕴丹,等. 基于VMD和主客观赋权的次同步振荡能量主导因素辨识[J]. 电力建设,2024,45(3):137-148.
XU Y H, LIU H, CHENG Y D, et al. Identification of dominant factors of sub synchronous oscillation energy based on VMD and subjective and objective weighting[J]. Power Construction, 2024, 45(3): 137-148.
- [12] 闫海鹏,郝新宇,秦志英. 基于参数优化VMD-小波阈值的轴承振动信号降噪方法[J]. 机电工程,2023,41(2):245-252.
YAN H P, HAO X Y, QING ZH Y. Bearing

- vibration signal denoising method based on parameter optimization VMD-wavelet threshold [J]. *Electrical and Mechanical Engineering*, 2023, 41(2): 245-252.
- [13] 王雨虹, 杨明昆, 包伟川, 等. 基于五点三次平滑和 ARMA 的次同步振荡参数辨识[J]. *合肥工业大学学报(自然科学版)*, 2020, 43(6): 790-796.
WANG Y H, YANG M K, BAO W CH, et al. Sub synchronous oscillation parameter identification based on five-point cubic smoothing and Arma[J]. *Journal of Hefei University of Technology Science (Natural Science)*, 2020, 43(6): 790-796.
- [14] 杨晨, 余一平, 樊陈, 等. 基于已知激励响应的低频振荡信息在线辨识[J]. *电力自动化设备*, 2023, 43(1): 193-201.
YANG CH, YU Y P, FAN CH, et al. On-line identification of low frequency oscillations based on known excitation response [J]. *Power Automation Equipment*, 2023, 43(1): 193-201.
- [15] WU G, WANG C, BAO J, et al. A wavelet threshold de-noising algorithm based on adaptive threshold function [J]. *Journal of Electronics & Information Technology*, 2014, 36(6): 1340-1347.
- [16] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[C]. *IEEE Trans. Signal Process*, 2013, 62(3): 531-544.
- [17] 王雅娴, 赵峰. 基于改进 VMD 和 SOBI 算法的直驱永磁同步风电机组次同步振荡模态辨识[J]. *噪声与振动控制*, 2020, 40(6): 102-108.
WANG Y X, ZHAO F. Sub synchronous oscillation modal identification of direct-driven permanent magnet synchronous wind turbine based on improved VMD and Sobi algorithm [J]. *Noise and Vibration Control*, 2020, 40(6): 102-108.
- [18] CHEON W, MIN B, SEO Y, et al. Non-blind deconvolution with an alternating direction method of multipliers (ADMM) after noise reduction in nondestructive testing[J]. *Journal of Instrumentation*, 2019, 14(11): P11032. DOI: 10.1088/1748-0221/14/11/P11032.
- [19] 马俊杰, 刘芳, 吴敏, 等. 基于类噪声小波分解的风电场次同步振荡辨识 [J]. *电网技术*, 2019, 43(4): 1294-1300.
MA J J, LIU F, WU M, et al. Sub synchronous oscillation identification of wind farm based on noise-like wavelet decomposition [J]. *Grid Technology*, 2019, 43(4): 1294-1300.
- [20] 闫红艳, Hwang Jin Kwon, 高艳丰. 基于类噪声数据的电力系统低频振荡模态参数辨识[J]. *发电技术*, 2022, 43(1): 19-31.
YAN H Y, HWANG J K, GAO Y F. Power system low frequency oscillation modal parameter identification based on noise-like data [J]. *Power Generation Technology*, 2022, 43(1): 19-31.
- [21] 尹温硕, 陶顺, 赵蕾. 基于 ARMA 模型的电压 RMS 值预测[J]. *电力工程技术*, 2018, 37(5): 20-25.
YI W SH, TAO SH, ZHAO L. RMS voltage prediction based on ARMA model [J]. *Electrical Engineering Technology*, 2018, 37(5): 20-25.
- [22] LIVIO F. Bootstrap order determination for ARMA models: A comparison between different model selection criteria [J]. *Journal of Probability and Statistics*, 2017, 1-12. DOI: 10.1155/2017/1235979.
- [23] HONG X, ORVAL HO A, H B W. Reflection on modern methods: A common error in the segmented regression parameterization of interrupted time-series analyses [J]. *International Journal of Epidemiology*, 2021, 50(3): 1011-1015.
- [24] 刘嘉敏, 彭玲, 刘军委, 等. 遗传算法 VMD 参数优化与小波阈值轴承振动信号去噪分析[J]. *机械科学与技术*, 2017, 36(11): 1695-1700.
LIU J M, PENG L, LIU J W, et al. Genetic algorithm VMD parameter optimization and wavelet threshold bearing vibration signal denoising analysis[J]. *Mechanical Science and Technology*, 2017, 36(11): 1695-1700.
- [25] 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 K T, HU X Y, LI X, et al. Sub synchronous oscillation mode identification method based on EMD and TLS-Prony and voltage feedback suppression strategy [J]. *Journal of Solar Energy*, 2023, 44(11): 294-302.
- [26] 任旭虎, 王浩, 刘通, 等. 基于 MSST-HT 的次同步振荡参数辨识研究[J]. *电子测量技术*, 2023, 46(17): 57-63.
REN X H, WANG H, LIU T, et al. Study on parameter identification of sub synchronous oscillation based on MSST-HT [J]. *Electronic Measurement Technology*, 2023, 46(17): 57-63.

作者简介

张彬彬, 博士, 讲师, 主要研究方向为智能控制。

E-mail: 624461918@qq.com

李聪, 硕士, 主要研究方向为方控制理论与控制工程。

E-mail: 3033433807@qq.com

陈超波(通信作者), 教授, 博士生导师, 主要研究方向为故障诊断与容错控制、智能控制。

E-mail: chenchao@xatu.edu.cn

王坤, 副教授, 硕士生导师, 主要研究方向为控制理论与控制工程、模式识别与智能系统。

E-mail: wangk@xatu.edu.cn

李继超, 硕士, 主要研究方向为控制理论与控制工程。

E-mail: 474501989@qq.com