

DOI: 10.19783/j.cnki.pspc.231191

# 基于 AVMD 多尺度模糊熵和 VPMCD 算法的宽频振荡分类

赵妍<sup>1</sup>, 潘怡<sup>2</sup>, 李亚波<sup>3</sup>, 聂永辉<sup>4</sup>

(1. 东北电力大学输变电技术学院, 吉林 吉林 132012; 2. 东北电力大学电气工程学院, 吉林 吉林 132012; 3. 国网浙江省电力有限公司杭州市富阳区供电公司, 浙江 杭州 310000; 4. 东北电力大学教务处, 吉林 吉林 132012)

**摘要:** 电力系统宽频振荡具有宽频域、非线性和时变性的特点, 对振荡分类在准确性、快速性等方面提出了更高的要求。为此, 提出一种基于自适应变分模态分解(adaptive variational mode decomposition, AVMD)的多尺度模糊熵(multi-scale fuzzy entropy, MFE)和变量预测模型(variable predictive model-based class discriminate, VPMCD)相结合的宽频振荡分类新方法。首先, 对宽频振荡信号进行 AVMD, 得到固有模态分量(intrinsic mode functions, IMFS)。然后, 引入 MFE 对 IMFS 进行时域特征描述, 同时实现对 IMFS 构造特征向量的降维处理。最后, 采用 VPMCD 对 MFE 降维后的特征向量实现宽频振荡的分类检测。通过仿真和实测数据分析, 结果表明, 所提方法的宽频振荡分类检测准确率比支持向量机(support vector machines, SVM)、BP 神经网络方法的分类准确率更高, 分类时间更短。

**关键词:** 宽频振荡分类; 多尺度模糊熵; 变分模态分解; 变量预测模型

## Broadband oscillation classification based on AVMD multi-scale fuzzy entropy and the VPMCD algorithm

ZHAO Yan<sup>1</sup>, PAN Yi<sup>2</sup>, LI Yabo<sup>3</sup>, NIE Yonghui<sup>4</sup>

(1. School of Power Transmission and Distribution Technology, Northeast Electric Power University, Jilin 132012, China; 2. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 3. Hangzhou Fuyang Power Supply Company, State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 310000, China; 4. Academic Administration Office, Northeast Electric Power University, Jilin 132012, China)

**Abstract:** The broadband oscillation of a power system has the characteristics of wide frequency domain, nonlinearity and time variation. This entails higher requirements for the accuracy and rapidity of the oscillation classification. Therefore, a new broadband oscillation classification method based on adaptive variational mode decomposition (AVMD), multi-scale fuzzy entropy (MFE), and variable prediction model-based class discriminate (VPMCD) is proposed. First, AVMD is performed on the broadband oscillation signal to obtain the intrinsic mode functions (IMFS). Then, MFE is introduced to describe the time-domain features of the IMFS, and dimensionality reduction of the eigenvectors constructed by the IMFS is realized. Finally, the VPMCD is used to realize the classification detection of broadband oscillations on the feature vectors after MFE dimensionality reduction. The simulation and measured data analysis results show that the proposed method has higher detection accuracy and shorter classification time for broadband oscillation than that of the support vector machines (SVM) algorithm and the BP neural network algorithm.

This work is supported by the National Natural Science Foundation of China (No. 61973072).

**Key words:** broadband oscillation classification; multi-scale fuzzy entropy; variational mode decomposition; variable predictive model

## 0 引言

随着2030年“碳达峰”和2060年“碳中和”目标的提出, 电力系统的结构和规模发生了深刻变革,

具有“双高”特点的新型电力系统逐渐形成<sup>[1-2]</sup>。双高电力系统中电力电子设备及其与电网多种元件之间的交互作用, 引发了具有多模态、宽频域、时变性、强非线性等特点的新型振荡<sup>[3-4]</sup>。此类振荡主要涉及由电力电子控制引发的电磁振荡, 涉及的频率范围为 $10^{-1}\sim 10^3$  Hz, 因此被称为宽频振荡<sup>[5-6]</sup>。近年来我国发生了多起与新能源发电和电力电子设备相

**基金项目:** 国家自然科学基金项目资助(61973072); 吉林省教育厅科学技术研究项目资助(JJKH20240144KJ)

关的宽频振荡事件<sup>[7-9]</sup>。宽频振荡已经成为影响电力系统安全稳定运行的新问题。宽频振荡一般与变流器的设备级控制相关<sup>[10-11]</sup>，针对不同的振荡类型采用不同的控制策略。电力电子变流器的功率控制、直流电压控制、交流电压控制、锁相环等控制环节的带宽覆盖低频段、次/超同步频段以及中频段，而交流电流控制和滤波器谐振的频段范围在中高频段和高频段<sup>[12-13]</sup>。因此，准确的振荡分类是采用正确的控制策略的前提。

宽频振荡分类方法通常包括两个步骤：1) 对量测的数据采用信号处理类方法进行特征提取，主要有快速傅里叶变换(fast fourier transform, FFT)<sup>[14]</sup>、类经验模态分解<sup>[15-16]</sup>、同步挤压小波变换(synchrosqueezing wavelet transform, SWT)<sup>[17]</sup>、同步提取变换(synchroextracting transform, SET)<sup>[18]</sup>等；2) 根据提取到的特征给出分类判据，或者采用机器学习方法进行振荡分类，如随机森林、K-means 聚类、朴素贝叶斯、支持向量机(support vector machines, SVM)等。文献[14]采用 FFT 提取低频振荡信号的频域特征，然后送入随机森林进行分类。FFT 是对一定时间窗内的信号进行卷积，结果不具有时域局部性特点，对非平稳振荡信号检测时存在误差，随机森林在噪声较大的情况下存在过拟合现象。文献[17]采用 SWT 提取次同步振荡信号的时频特征，然后采用 K-means 聚类获得振荡频率，判断是否发生次同步振荡。文献[18]采用 SET 提取次同步振荡的时频特征，然后采用希尔伯特变换得到频率和衰减因子，再交由朴素贝叶斯分类器判断是否发生次同步振荡。SET 和 SWT 分析效果和小波基函数的选择有关。K-means 聚类需要人为确定初始聚类中心，朴素贝叶斯在处理多分类问题时效果不好。文献[19]对大量 PMU 历史数据提取次同步振荡的趋势、包络波动率指数和固定子序列长度 3 个时频特征，然后根据特征自适应地在多 SVM 中选择分类器。对具有非线性特征的宽频信号，SVM 的核函数选择困难。在特征提取阶段，针对不同的振荡类型，选择不同的信号处理方法，需要大量的相关知识和经验。可能会出现特征提取不充分，或者由于构建的特征空间维度过高，特征提取冗余的问题。同上，分类阶段判据的确定也需要先验知识，缺乏普适性。当采用机器学习方法进行分类时，存在求解计算量大、参数难以选择等问题。宽频振荡是多种频率组合而成的复杂信号，上述分类方法大多针对其中一类进行分析，而且以低频或次同步为主，难以适用于其他振荡类型。因此，正确地提取宽频振荡的特征、减少分类计算量，提高分类准确性、快速性和

自适应性是宽频振荡分类研究的关键问题。

近年来，基于熵的特征提取方法被应用于电力系统的各个领域，如近似熵(approximate entropy, AE)、样本熵(sample entropy, SE)、排列熵(permutation entropy, PE)等。文献[20]将经验模态分解(empirical mode decomposition, EMD)和 AE 相结合提取断路器的故障特征，采用 SVM 进行故障诊断。但 AE 在熵值计算中存在自身匹配的问题，影响特征提取的效果。文献[21]将自适应噪声完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)和 SE 相结合得到断路器运行状态特征量，采用 SVM 识别断路器的运行状态。SE 不仅解决了 AE 的自身匹配问题，而且在相对一致性上表现更优秀，能够衡量序列的无规则程度，但 SE 对信号复杂程度的描述上比较单一，不能全面反映不同尺度下特征信息的缺点。文献[22]将变分模态分解(variational mode decomposition, VMD)和 PE 相结合，构成微电网故障诊断模型。但 PE 存在嵌入维数难以选择的问题。AE、SE、PE 等方法在提取故障信号特征时，都是在单个尺度上进行分析，仅度量单一时间序列的复杂度，可能会忽略其他时间尺度下的有用信息，从而影响后续的诊断准确性。在此基础上，文献[23]提出了多尺度模糊熵(multi-scale fuzzy entropy, MFE)，MFE 引入尺度因子将时间序列进行粗粒化重构，弥补了单一尺度熵值算法的不足，它包含了更多的时间模式信息，可以进一步提取信号的时域特征。目前，MFE 被广泛应用于机械轴承检测、故障诊断等领域。

基于此，本文提出了基于自适应变分模态分解(adaptive variational mode decomposition, AVMD)的多尺度模糊熵和变量预测模型(variable predictive model-based class discriminate, VPMCD)算法相结合的宽频振荡分类方法。在特征提取阶段，首先采用 AVMD 提取振荡信号的时频特征，然后采用多尺度模糊熵进一步描述每个模态分量的时域特征，同时实现对 IMF 构造的特征向量的降维。在振荡分类阶段，采用 VPMCD 分类算法来实现宽频振荡信号的分类。

## 1 基本原理

### 1.1 AVMD 多尺度模糊熵

#### 1.1.1 自适应变分模态分解

VMD 是一种非递归变分模式的信号分解方法，适用于处理非线性信号。分解后所得的 IMF 分量包含信号的时频域信息<sup>[24]</sup>。VMD 的原理见文献[25]。VMD 的分解层数  $K$  属于自定义变量。 $K$  值过小欠分解，会出现模态混叠现象； $K$  值过大过分解，会

产生虚假模态分量。本文将相关系数  $x$  和余弦相似度  $A$  结合来确定准确的  $K$  值, 获得 AVMD。惩罚因子  $\alpha$  取值 2000, 计算不同  $K$  值下的相邻模态之间的相似度  $Y$ , 如式(1)所示。

$$Y = \lambda x + \eta A \quad (1)$$

式中,  $\lambda$  和  $\eta$  为加权系数。

$$\begin{cases} \lambda = \frac{\varphi_1}{\varphi_1 + \varphi_2} \\ \eta = \frac{\varphi_2}{\varphi_1 + \varphi_2} \\ \varphi_1 = \frac{S_x}{\mu_x} \\ \varphi_2 = \frac{S_A}{\mu_A} \end{cases} \quad (2)$$

式中:  $\varphi_1$  为相关系数的变异系数;  $\varphi_2$  为余弦相似度的变异系数;  $S_x$ 、 $\mu_x$  分别为相关系数的标准差和均值;  $S_A$ 、 $\mu_A$  分别为余弦相似度的标准差和均值。

相似度  $Y$  将相关系数  $x$  和余弦相似度  $A$  相结合, 用来衡量 VMD 分解的相邻 IMF 模态之间的相似度。 $Y$  值越大, 代表着相邻两个 IMF 之间的相似度越大, 也代表着此刻 VMD 可能存在过分解。依据相关系数理论及大量试验验证, 当  $Y$  值大于 0.8 时, 本文判断 VMD 为过分解,  $K$  不再增加, 最佳的 VMD 分解层数为  $K-1$ 。

### 1.1.2 多尺度模糊熵

如果直接将 AVMD 获得的  $K-1$  个 IMF 分量构造的特征矩阵作为提取到的特征进行分类, 模型训练的时间长, 在线分类检测的快速性也不能满足要求。因此, 引入 MFE 对每个 IMF 进行相应频率范围内的时序特征进行描述, 同时实现对 IMF 构造特征向量的降维。MFE 算法步骤如下所述。

1) 对 IMF 分量序列  $M = \{x_1, x_2, \dots, x_N\}$  构造  $m$  维向量  $\mathbf{X}_i^m$ , 如式(3)所示。

$$\mathbf{X}_i^m = \{x(i), x(i+1), \dots, x(i+m)\} - x_0(i) \quad (3)$$

式中:  $i=1, 2, \dots, N-m+1$ ;  $x(i)$  为向量  $\mathbf{X}_i^m$  中的一维向量;  $x_0(i)$  为  $m$  个连续  $x(i)$  的均值。

$$x_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} x(i+j) \quad (4)$$

2) 定义向量  $\mathbf{X}_i^m$  和  $\mathbf{X}_j^m$  之间的距离  $d_{ij}^m$  是对应元素差的绝对值的最大值, 如式(5)所示。

$$d_{ij}^m = d[\mathbf{X}_i^m, \mathbf{X}_j^m] = \max_{k \in (0, m-1)} \{|[x(i+k) - x_0(i)] - [x(j+k) - x_0(j)]|\} \quad (5)$$

3) 根据模糊函数, 定义  $\mathbf{X}_i^m$  和  $\mathbf{X}_j^m$  之间的相似度  $D_{ij}^m$  为

$$D_{ij}^m = \exp(-(d_{ij}^m / r)^n) \quad (6)$$

式中:  $n$  为模糊函数梯度;  $r$  为相似容限。

4) 求样本平均相似度函数  $\varphi^m(n, r)$ , 如式(7)所示。

$$\varphi^m(n, r) = \frac{1}{K-1-m} \sum_{i=1}^{K-1-m} \left[ \frac{1}{K-1-m-1} \sum_{j=1, j \neq i}^{K-1-m} D_{ij}^m \right] \quad (7)$$

5) 设置维数  $m+1$ , 重复步骤 3)~步骤 7), 求  $\varphi^m(n, r)$ 。

6) 原始信号的模糊熵为

$$E_F(m, n, r, N) = -\ln \frac{\varphi^{m+1}(n, r)}{\varphi^m(n, r)} \quad (8)$$

7) 对  $M = \{x_1, x_2, \dots, x_N\}$  进行粗粒化处理, 得到新的时间序列, 如式(9)所示。

$$y_i(\tau) = \frac{1}{\tau} \sum_{j=(i-1)\tau}^{i\tau} x_j, 1 \leq i \leq \frac{N}{\tau} \quad (9)$$

式中,  $\tau$  表示尺度因子。对于给定的  $\tau$ , 原始序列被分割成长度为  $(K-1)/\tau$  的粗粒向量。

利用上述多尺度模糊熵值, 组成特征向量  $\mathbf{F} = [F_1, F_2, \dots, F_{K-1}]$ 。  $K-1$  为 AVMD 分解获得的 IMF 分量个数。其中: 嵌入维数  $m=3$ ,  $r$  取原始信号 0.15 倍标准差,  $n$  取 7,  $\tau$  取 16。AVMD-MFE 计算流程图如图 1 所示。

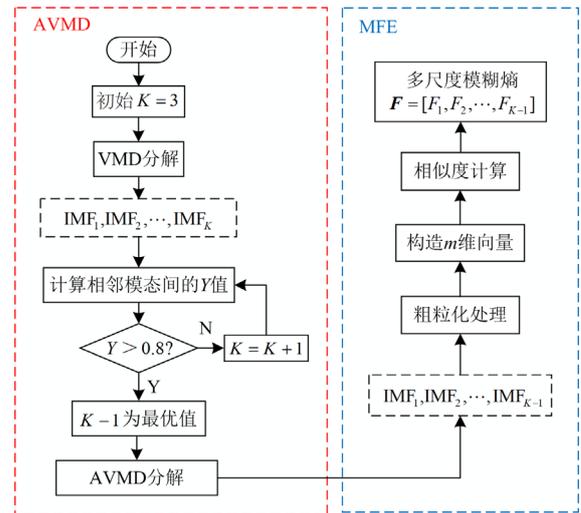


图 1 AVMD-MFE 计算流程图

Fig. 1 Calculation flow chart of AVMD-MFE

## 1.2 多变量预测模型

VPMCD 方法认为从原始数据中提取的特征值之间具有一定的相互内在关系, 利用特征值之间的

相互内在关系建立预测模型。VPMCD 是一种基于最小二乘回归的快速学习算法。不涉及神经网络训练的迭代过程和 SVM 的寻优过程,在对样本训练时采用参数估计的方法建立预测模型,大幅度减少了运算量。

宽频振荡信号经过 AVMD-MFE 后,获得 1 行  $n$  列的多尺度模糊熵特征量,即  $F = [F_1, F_2, \dots, F_{K-1}]$ ,将  $F$  作为 VPMCD 输入。在给定模型中采用 VPMCD 对特征向量之间的关系进行回归计算,构建能够表征不同区段下其特征量函数关系的数学模型 VPM,通过对测试样本的特征预测,得到测试样本的类型划分依据<sup>[26]</sup>。VPMCD 的分类步骤如下。

1) 针对  $p$  维特征量的  $K-1$  个同类样本,逐一选择每个维度作为因变量,其他  $p-1$  维数据作为自变量进行回归分析,得到  $p$  组回归系数。针对  $m$  种信号类型,构建  $m \times p$  维的预测模型  $VPM_i^j$ 。本文选取二次交互模型进行预测。

2) 将测试样本的特征值输入到预测模型中,得到预测值。每组特征值将生成  $m$  组与信号类型相关的预测值,每组包括  $p$  个预测值,通过最小二乘准则计算预测值与真实特征值的方差  $E_{mc}$ ,确定输入的样本属于哪一种信号类型,即

$$E_{mc} = \sum_{i=1}^p (t_i - f_i^c)^2 \quad (10)$$

式中:  $t_i$  表示特征向量中的真值;  $f_i^c$  表示模型预测特征值;  $c$  表示类型;

## 2 基于 AVMD-MFE-VPMCD 方法的宽频振荡分类步骤

本文方法包括模型训练和在线应用两个阶段,如图 2 所示。

### 1) 模型训练阶段

(1) 利用数值仿真,将各个模态参数进行自由组合,获得不同振荡类型,构成模型的数据集。

(2) 将数据集进行 AVMD 得到 IMF 分量,计算每个 IMF 分量的多尺度模糊熵值,获得特征向量  $F$  并标注标签,构成模型的样本集。

(3) 将样本集按照 6:4 随机划分为训练集和测试集,输送给 VPMCD 模型进行回归训练,每类信号选取方差  $E_{mc}$  最小的特征值模型。

(4) 模型训练完成后,根据测试集的分类结果,对模型参数进行调整直至达到理想状态。

### 2) 在线应用阶段

(1) 当系统发生宽频振荡时,对振荡信号进行 AVMD 分解并获得多尺度模糊熵特征值,将特征值

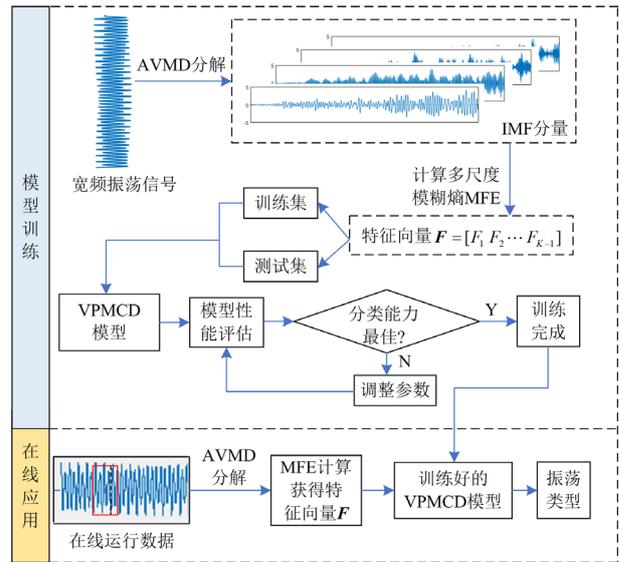


图 2 AVMD-MFE-VPMCD 方法的宽频振荡分类流程图

Fig. 2 Flowchart of broadband oscillation classification based on AVMD-MFE-VPMCD method

输送给 VPMCD 模型。

(2) 通过 VPMCD 模型对振荡类型进行分类检测,上传至调度中心。

## 3 仿真实验验证

### 3.1 构建仿真数据集

仿真数据频率  $f$  范围是 0.01~750 Hz,步长是 0.1;衰减因子  $\lambda$  范围是 -1~1,步长是 0.01;相位  $\varphi \in (-\pi, \pi)$ ,将各模态参数随机进行自由组合,振荡幅值随机生成,可得到大量的训练样本。信号的采样频率为 12.8 kHz,在构造的信号样本集中,随机选取 4000 条数据构成仿真数据集。将仿真数据集按照 6:4 划分为训练集和测试集。

### 3.2 标签设定

宽频振荡的频率范围如下:超低频段为 0.01~0.1 Hz、低频段为 0.1~2.5 Hz、次同步频段为 2.5~49.5 Hz、超同步频段为 50.5~100 Hz、中高频段为 100~2000 Hz。为了减少标签数量进而减少模型训练时的计算量,本文将振荡类型划分为超低频/低频振荡、次/超同步振荡、中高频振荡 3 类。具体标签类型如表 1 所示。

表 1 振荡类型及类别标签

Table 1 Oscillation type and category labels

振荡类型	类别标签
超低频/低频	1
次/超同步	2
中高频	3

### 3.3 性能分析

#### 3.3.1 抗噪性能分析

实际工程应用中, 检测到的宽频振荡信号会含有噪声, 噪声会对宽频振荡的分类准确性造成影响。为验证本文所提方法的抗噪性, 将具有不同信噪比的高斯白噪声加入测试数据中, 采用训练好的模型进行测试, 分类结果如表 2 所示。

表 2 不同信噪比噪声下的分类准确率

Table 2 Classification accuracy of different signal-to-noise ratio noise

信噪比/dB	0	20	15	10
平均准确率/%	99.21	97.76	95.43	94.35

由表 2 可以看出, 在加入不同强度白噪声后, 模型分类准确率都有了不同程度的下降, 信噪比为 10 dB 时下降更为明显, 但平均准确率只下降了 4.86%。这是因为, 本文方法在特征提取阶段采用的 AVMD-MFE 相结合的方法, 在对原始数据进行特征提取和特征降维的同时, 提高了方法的抗噪性。

#### 3.3.2 泛化性分析

为满足工程实用性要求, 对本文提出方法进行泛化性分析, 将实测数据加入测试集构成新的测试集。测试集 A: 原仿真数据 200 条和新加入实测数据 200 条。测试集 B: 全部为新的实测数据共 400 条。然后送入训练好的模型进行测试。测试结果如表 3 所示, 准确率为 10 次实验的平均值。

表 3 不同测试集下的分类准确率

Table 3 Classification accuracy of different test sets

测试集	准确率/%		
	最大值	最小值	平均值
A	97.35	95.40	96.88
B	95.67	92.42	93.54

由表 3 可知, 面对全新的实测数据, 训练好的模型能够对宽频振荡类型进行准确识别, 没有产生过拟合现象。这是因为 VMD-MFE 特征提取充分, 已经将数据按照类型大致聚类, 使 VPMCD 输出的分类准确率很高。因此, 本文所提方法具有良好的泛化性, 可以满足实际工程需求。

### 3.4 对比实验

#### 3.4.1 AVMD 对比实验

为了验证 AVMD-MFE 算法的有效性, 本文随机抽取 300 个信号样本(每种标签 100 个), 分别进行 AVMD-MFE 和 EMD-MFE 特征提取, 并比较二者的提取效果。实验结果如图 3 所示。

由图 3 可以看出, 此混合信号的 AVMD-MFE 特征差异性明显, 辨识度高; 而 EMD-MFE 特征差

异不明显, 走势、陡度都十分相似, 数值区间上也互有重叠, 不容易区分。

#### 3.4.2 多尺度模糊熵对比实验

分别选取 AE、SE 与 AVMD 相结合, 验证本文 AVMD-MFE 特征提取的有效性。3 种特征提取方法均以 6:4 的比例设置训练集和测试集, 输送给 VPMCD 模型, 结果如表 4 所示。

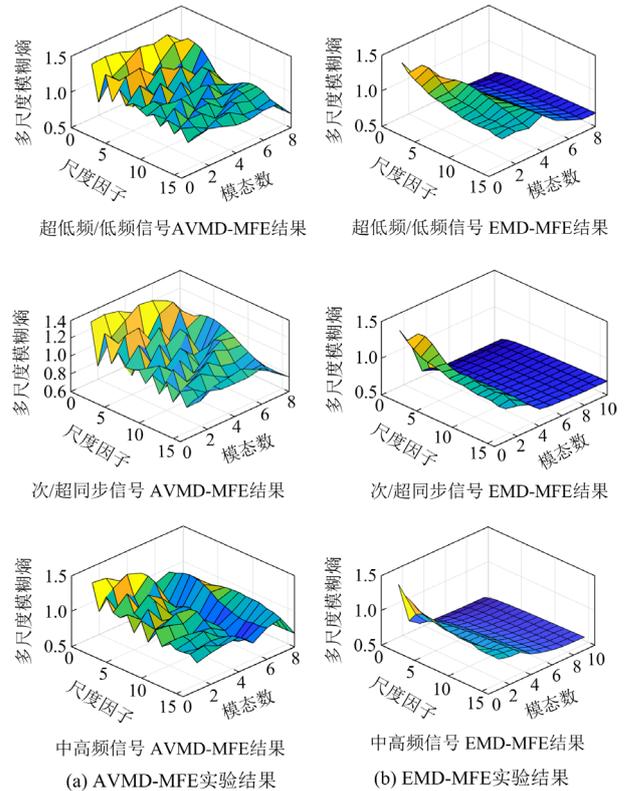


图 3 AVMD-MFE 和 EMD-MFE 方法的实验对比结果

Fig. 3 Comparative experiments between AVMD-MFE and EMD-MFE methods

表 4 不同特征提取方法的准确率

Table 4 Influence of different feature extraction methods

实验序号	准确率/%		
	AVMD-AE	AVMD-SE	AVMD-MFE
1	89.54	90.17	99.48
2	88.72	89.35	98.63
3	85.23	91.25	99.53
平均准确率	87.83	90.26	99.21

由表 4 可知, 由于 AE 和 SE 只反映时间序列在单一尺度上的信息, 因此其分类准确率低。而多尺度模糊熵可以反映时间序列在不同尺度因子下的自相似性和复杂性程度, 所以本文所提 AVMD-MFE 特征提取方法能够有效地提取信号特征, 分类效果好。

将多尺度模糊熵特征的效果用 t-SNE 降维可视化, 如图 4 所示。由图 4 可见, 各振荡类型已经呈零散聚类状态。AVMD-MFE 获得的多尺度模糊熵特征向量实现了对原始数据的特征提取和特征降维, 为后续 VPMCD 分类器获得较高的识别率和识别速度奠定了基础。

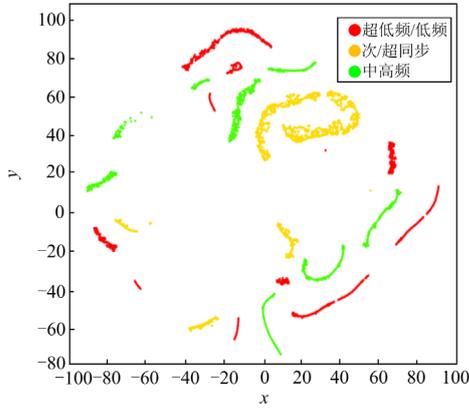


图 4 AVMD-MFE 特征提取 t-SNE 二维分布图

Fig. 4 Two-dimensional distribution map of AVMD-MFE features extracting t-SNE

### 3.4.3 VPMCD 对比实验

为了验证本文分类方法的性能, 选取了 SVM、BP 神经网络与 VPMCD 进行对比实验。在相同的训练集下, 各种方法的结果如图 5 所示。

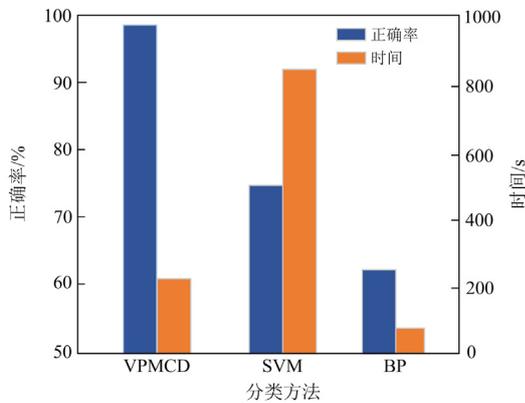


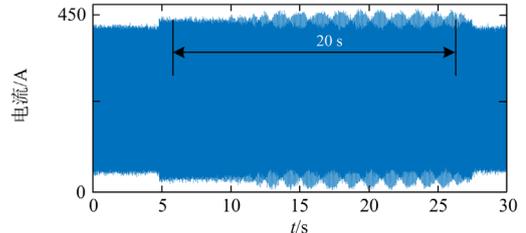
图 5 不同分类方法的对比

Fig. 5 Comparison of different classification methods

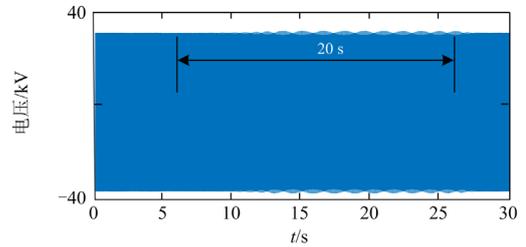
由图 5 可知, SVM 的分类正确率相较于 VPMCD 较低, 且在线分类时间长; BP 的分类正确率不高, 在线分类时间也较长。VPMCD 的分类效果最好, 能够达到 99.56%, 且在线分类时间相对较短; 这是因为 VPMCD 算法不需要输入超参数, 进而不必在算法参数的调优上花费时间, 训练时间短, 结构简单, 在线应用时分类时间也短。

## 4 实例验证

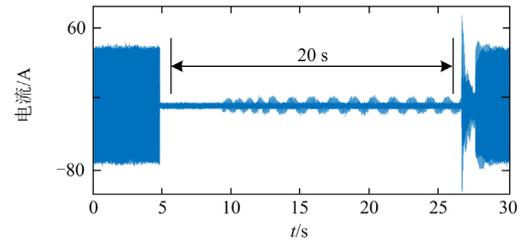
以某地区风电机组发生脱网现象时为例, 在 35 kV 电压下, 将 A 相电流、电压、SVG 电流实测数据作为模型输入, 采样频率为 12.8 kHz, 时间为 30 s, 实验结果如图 6 所示。



(a) A相电流



(b) A相电压



(c) A相SVG电流

图 6 实测数据

Fig. 6 The measured data

通过本文所提方法对风电机组线路进行宽频振荡在线监测。首先进行自适应变分模态分解, 其相似度计算结果如图 7 所示。当  $K = 5$  时, IMF3&4 所在列的  $Y$  值大于 0.8, 确定 AVMD 的最优模态分解数为 4。

选取 6~26 s 内的实测电流、电压、SVG 波形进行滑动检测。时窗长度为 2 s, 窗口重叠长度为 1 s, 每 2 s 进行一次 AVMD-MFE-VPMCD 分类监测。滑动检测过程如图 8 所示。

对 35 kV 电压下的 A 相电流进行如图 8 所示的滑动检测。得到每一个窗口的 AVMD 分解结果, 部分 AVMD 分解图(8~10 s)如图 9 所示。

对每个窗口得到的 IMF 求解多尺度模糊熵值, 得到一组特征量  $F$ 。以图 9 为例, 特征量如表 5 所示。

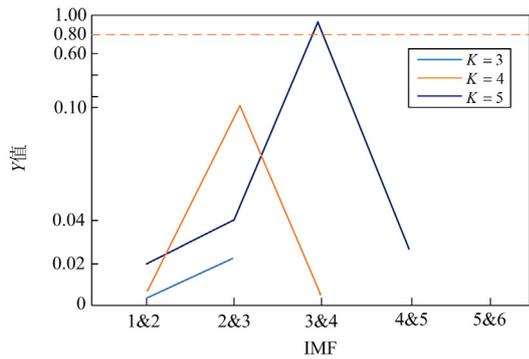


图 7 不同  $K$  取值下的相似度值

Fig.7 Similarity values at different values of  $K$

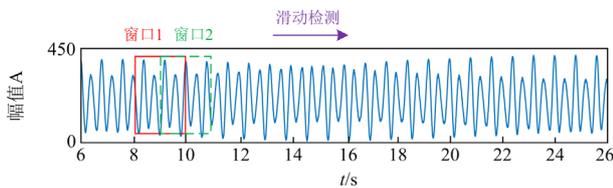


图 8 滑动检测示意图

Fig. 8 Slide detection schematic

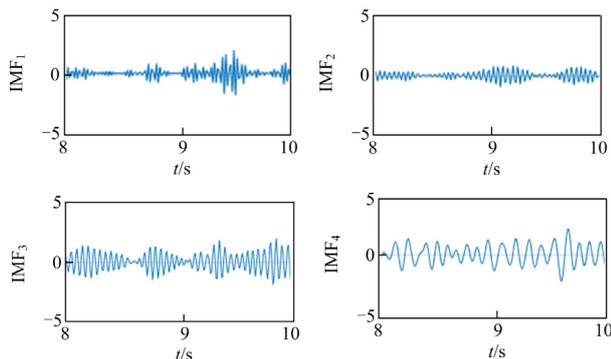


图 9 A 相电流 AVMD 分解图

Fig. 9 AVMD exploded view of A phase current

表 5 AVMD 分解的特征量  $F(8\sim 10\text{ s})$

Table 5 Eigenvalue vector  $F$  of the AVMD (8~10 s)

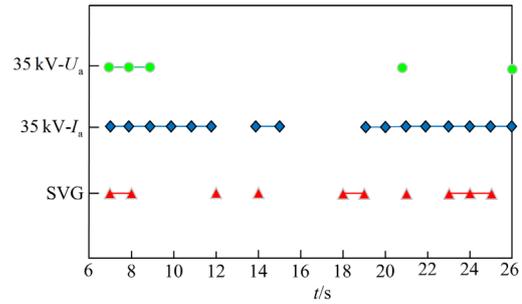
IMF	IMF <sub>1</sub>	IMF <sub>2</sub>	IMF <sub>3</sub>	IMF <sub>4</sub>
多尺度模糊熵	0.169	0.356	0.566	0.421

对  $F$  采用 VPMCD 模型进行滑动检测得到振荡类型结果, 如图 10 所示。

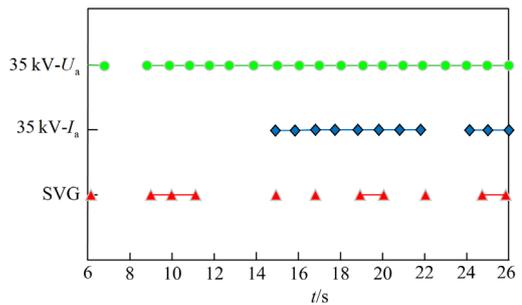
由图 10 可以看出, 宽频振荡同时存在慢相互作用(小于 10 Hz)与快相互作用(数十到数百赫兹), 这是由于变流器接口发电设备的多时间尺度控制特性会导致机、网之间既有机电暂态又有电磁暂态的耦合互动, 从而引发宽频率范围的振荡现象。

根据图 10 中 35 kV 电压下的 A 相电流振荡检

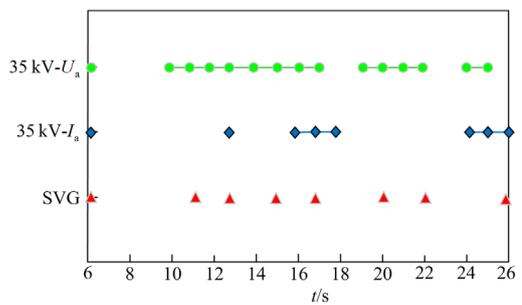
测结果可知: 在电流作为输入量的第 16~18 s、24~26 s 时间段内, 次/超同步振荡和超低频/低频振荡同时存在, 这是因为电力电子设备控制相互作用引发的电磁振荡频率范围非常宽广, 会出现次/超同步振荡模式, 也会对工频信号产生调制作用, 导致低频振荡现象的发生。针对这种频段混叠的现象, 不仅需要正确分类, 还要认识到机电-电磁动态共存且相互作用的复杂性。



(a) 中高频振荡监测结果



(b) 次/超同步振荡监测结果



(c) 超低频/低频振荡监测结果

图 10 A 相振荡类型检测结果

Fig. 10 Detection results of A-phase oscillation types

对比图 10(a)、图 10(b)、图 10(c)可知, 对于中高频振荡, 电流作为输入量的振荡检测结果包含了电压、SVG 的检测结果, 这是因为交流电流控制和滤波器谐振的频段范围在中高频段和高频段。对于次/超同步振荡及超低频/低频振荡, 电压作为输入量的检测结果比较全面, 这是因为电力电子变流器的功率控制、直流电压控制、交流电压控制、锁相

环等控制环节的带宽覆盖低频段、次/超同步频段以及中频段；由图 6(c)可以看出，发生宽频振荡时静止无功发生器中也受到影响，但是 SVG 的监测结果过于分散，因此不予考虑。

## 5 结语

本文将 VMD 多尺度模糊熵与 VPMCD 相结合来进行宽频振荡分类检测，主要结论如下。

1) 利用加权的相关系数和余弦相似度法确定了 VMD 的分解层数，实现了对宽频振荡信号的自适应 VMD 分解。

2) 对 IMF 进行多尺度模糊熵计算，构建成特征向量作为 VPMCD 模型的输入，达到对特征空间降维的目的。

3) 利用本文提出的 AVMD 多尺度模糊熵和 VPMCD 相结合的方法，减少了计算量、实现了较准确的宽频振荡分类检测，对多类型的宽频振荡分类具有宽适用性。

## 参考文献

- [1] 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): 461-475.  
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): 461-475.
- [2] 任柯政, 徐泰山, 郭瑾程, 等. 数据驱动的新型电力系统断面极限估算方法[J]. 智慧电力, 2022, 50(11): 9-16.  
REN Kezheng, XU Taishan, GUO Jincheng, et al. New data-driven power system section limit estimation method[J]. Smart Power, 2022, 50(11): 9-16.
- [3] 程静, 苏乐, 岳雷. 双馈风电并网系统的宽频振荡机理分析与抑制[J]. 电力系统保护与控制, 2023, 51(12): 1-13.  
CHENG Jing, SU Le, YUE Lei. Mechanism analysis and suppression of broadband oscillation in a DFIG wind power grid-connected system[J]. Power System Protection and Control, 2023, 51(12): 1-13.
- [4] 李相俊, 赵珊珊, 惠东. 面向新型电力系统的大型储能电站关键技术发展趋势分析与展望[J]. 供用电, 2022, 39(7): 2-8, 24.  
LI Xiangjun, ZHAO Shanshan, HUI Dong. Development trend analysis and prospect of key technologies of large energy storage station in new type power system[J]. Distribution & Utilization, 2022, 39(7): 2-8, 24.
- [5] 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): 7889-7905.  
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): 7889-7905.
- [6] 张天翼, 王海风. 风电并入弱交流系统引发次同步振荡的研究方法综述[J]. 电力系统保护与控制, 2021, 49(16): 177-187.  
ZHANG Tianyi, WANG Haifeng. Research methods for subsynchronous oscillation induced by wind power under weak AC system: a review[J]. Power System Protection and Control, 2021, 49(16): 177-187.
- [7] LIU H, XIE X, LI Y. Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and Elman neural network[J]. Energy Conversion and Management, 2018, 156(1): 498-514.
- [8] LIU H K, XIE X R, HE J B, et al. Subsynchronous interaction between direct-drive PMSG based wind farms and weak AC networks[J]. IEEE Transactions on Power Systems, 2017, 32(6): 4708-4720.
- [9] 邹常跃, 陈俊, 许树楷, 等. 长控制链路延时特征下柔性直流输电系统动态性能改善方法[J]. 电网技术, 2017, 41(10): 3216-3222.  
ZOU Changyue, CHEN Jun, XU Shukai, et al. Dynamic performance optimization of VSC-HVDC considering its long delay[J]. Power System Technology, 2017, 41(10): 3216-3222.
- [10] 杜镇宇, 阳岳希, 季柯, 等. 张北柔直工程高频谐波振荡机理与抑制方法研究[J]. 电网技术, 2022, 46(8): 3066-3075.  
DU Zhenyu, YANG Yuexi, JI Ke, et al. High frequency harmonic resonance and suppression in Zhangbei project[J]. Power System Technology, 2022, 46(8): 3066-3075.
- [11] 张思彤, 梁纪峰, 马燕峰, 等. 直驱风电场经柔性直流输电并网的宽频振荡特性分析[J]. 电力系统保护与控制, 2022, 50(14): 33-42.  
ZHANG Sitong, LIANG Jifeng, MA Yanfeng, et al. Broadband oscillation characteristics analysis of a VSC-HVDC connected direct drive wind farm[J]. Power System Protection and Control, 2022, 50(14): 33-42.
- [12] 吴翔宇, 张晓红, 许寅, 等. 微电网(群)宽频振荡分析和抑制研究进展与展望[J]. 电网技术, 2023, 47(9): 3727-3745.  
WU Xiangyu, ZHANG Xiaohong, XU Yin, et al. Research progress and prospect of wide-band oscillations analysis and suppression for microgrid (clusters)[J]. Power System

- Technology, 2023, 47(9): 3727-3745.
- [13] NEEVATIKA V, NARENDRA K, RAJEEV K. Battery energy storage-based system damping controller for alleviating sub-synchronous oscillations in a DFIG-based wind power plant[J]. Protection and Control of Modern Power Systems, 2023, 8(2): 524-541.
- [14] 赵妍, 霍红, 徐晗桐. 二阶段随机森林分类方法在低频振荡监测中的应用[J]. 东北电力大学学报, 2020, 40(2): 60-67.
- ZHAO Yan, HUO Hong, XU Hantong. Application of two-stage random forest classification method to low-frequency oscillation monitoring[J]. Journal of Northeast Electric Power University, 2020, 40(2): 60-67.
- [15] 张艳军, 殷祥翔, 葛延峰, 等. 基于 APIT-MEMD 的电力系统低频振荡模式辨识新方法[J]. 电力系统保护与控制, 2020, 48(14): 165-174.
- ZHANG Yanjun, YIN Xiangxiang, GE Yanfeng, et al. Low frequency oscillation mode estimation in power systems using adaptive-projection intrinsically transformed multivariate empirical mode decomposition[J]. Power System Protection and Control, 2020, 48(14): 165-174.
- [16] 陈志同, 徐晋, 李国杰, 等. 基于变分模态分解和压缩感知的电力系统宽频振荡监测方法[J]. 电力系统保护与控制, 2022, 50(23): 63-74.
- CHEN Zhitong, XU Jin, LI Guojie, et al. Monitoring method of power system wide-band oscillation based on variational mode decomposition and compressive sensing[J]. Power System Protection and Control, 2022, 50(23): 63-74.
- [17] 刘韶峰, 徐泰山, 鲍颜红, 等. 基于 K-means 聚类和同步挤压小波变换的次同步振荡检测[J]. 电力科学与技术学报, 2021, 36(4): 132-140.
- LIU Shaofeng, XU Taishan, BAO Yanhong, et al. Sub-synchronous oscillation detection based on K-means clustering and frequency synchrosqueezing wavelet transforms[J]. Journal of Electric Power Science and Technology, 2021, 36(4): 132-140.
- [18] 赵妍, 崔浩瀚, 荣子超. 次同步振荡在线监测的同步提取变换和朴素贝叶斯方法[J]. 电力系统自动化, 2019, 43(3): 187-192.
- ZHAO Yan, CUI Haohan, RONG Zichao. On-line monitoring of subsynchronous oscillation based on synchro extracting transform and naive Bayes method[J]. Automation of Electric Power Systems, 2019, 43(3): 187-192.
- [19] LIU H, QI Y, ZHAO J B, et al. Data-driven subsynchronous oscillation identification using field synchrophasor measurements[J]. IEEE Transactions on Power Delivery, 2022, 31(1): 165-175.
- [20] 王振浩, 顾欣然, 孙福军. 基于 EMD 近似熵的高压断路器故障诊断[J]. 高压电器, 2018, 54(10): 151-156, 163.
- WANG Zhenhao, GU Xinran, SUN Fujun. High voltage circuit breaker fault diagnosis based on EMD approximate entropy[J]. High Voltage Apparatus, 2018, 54(10): 151-156, 163.
- [21] 赵书涛, 马莉, 朱继鹏, 等. 基于 CEEMDAN 样本熵与 FWA-SVM 的高压断路器机械故障诊断[J]. 电力自动化设备, 2020, 40(3): 181-186.
- ZHAO Shutao, MA Li, ZHU Jipeng, et al. Mechanical fault diagnosis of high voltage circuit breaker based on CEEMDAN sample entropy and FWA-SVM[J]. Electric Power Automation Equipment, 2020, 40(3): 181-186.
- [22] 喻贞楷, 王斌, 闫塘, 等. 多扰动下微电网故障检测方法[J]. 电力系统及其自动化学报, 2023, 35(12): 151-158.
- YU Zhenkai, WANG Bin, YAN Yong, et al. Fault detection method of microgrid under multiple disturbance[J]. Proceedings of the CSU-EPSCA, 2023, 35(12): 151-158.
- [23] WEI Y, LI Y Q, XU M Q, et al. Intelligent fault diagnosis of rotating machinery using ICD and generalized composite multi-scale fuzzy entropy[J]. IEEE Access, 2019, 7: 38983-38995.
- [24] 汤吉鸿, 朱军飞, 李勇, 等. 基于变分模态分解的电力系统泛频带振荡辨识方法[J]. 电力系统保护与控制, 2019, 47(2): 1-8.
- TANG Jihong, ZHU Junfei, LI Yong, et al. VMD based mode identification for broad-band oscillation in power system[J]. Power System Protection and Control, 2019, 47(2): 1-8.
- [25] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [26] LUO S R, CHENG J S. VPMCD based novelty detection method on and its application to fault identification for local characteristic-scale decomposition[J]. Cluster Computing, 2017, 20(4): 2955-2965.

收稿日期: 2023-09-11; 修回日期: 2024-02-15

作者简介:

赵妍(1974—), 女, 博士, 副教授, 硕士生导师, 研究方向为电力系统稳定分析与控制、电力系统故障分析和信号处理; E-mail: zjb\_112006@163.com

潘怡(1999—), 女, 通信作者, 硕士研究生, 研究方向为人工智能在电力系统中的应用。E-mail: 729351636@qq.com

(编辑 周金梅)