

DOI: 10.19783/j.cnki.pspc.241013

基于 S-Koopman 能量矩阵的互联电网扰动事件 分类及区域定位

周书宇^{1,2}, 杨晶莹^{1,2}, 蔡国伟¹, 刘 斌¹, 姜 超¹

(1. 现代电力系统仿真与绿色电能新技术教育部重点实验室(东北电力大学), 吉林 吉林 132012;

2. 国网吉林省电力有限公司, 吉林 长春 132000)

摘要: 扰动类型及扰动发生的区域位置信息对互联电网稳定分析与调控具有重要作用。为此, 提出了一种基于 S-Koopman 能量矩阵的扰动事件分类及区域定位方法。该方法利用子空间最优模式分解算法(subspace optimal mode decomposition algorithm, Sub-OpMD)计算得到包含随机系统动态信息的 S-Koopman 算子的低维最优矩阵。并根据最优低维矩阵的特征分解结果构建 S-Koopman 能量矩阵。S-Koopman 能量矩阵与系统动态行为相关; 其行/列向量可以提取系统扰动事件发生后的不同特征数据以及不同位置 PMU 数据波动强弱。并进一步根据不同扰动类型以及扰动区域下的 PMU 数据动态变化规律, 提出系统扰动事件分类及区域定位的量化评估指标。新英格兰 10 机 39 节点仿真系统和 CEPRI-SSFS 197 节点实际系统的计算和分析验证了所提方法的合理性、有效性和准确性。
关键词: 扰动事件分类; 扰动区域定位; S-Koopman 能量矩阵; 量化指标

Disturbance event classification and regional localization in interconnected power grids based on the S-Koopman energy matrix

ZHOU Shuyu^{1,2}, YANG Jingying^{1,2}, CAI Guowei¹, LIU Cheng¹, JIANG Chao¹

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education (Northeast Electric Power University), Jilin 132012, China; 2. State Grid Jilin Electric Power Co., Ltd., Changchun 132000, China)

Abstract: The classification of disturbance event types and the identification of their regional locations are critical for the stability analysis and control of interconnected power grids. To address this, a disturbance event classification and localization method based on the S-Koopman energy matrix is proposed. This method uses the subspace optimal mode decomposition algorithm (Sub-OpMD) to calculate the optimal low dimensional matrix of the S-Koopman operator, which captures the dynamic information of the stochastic system. The S-Koopman energy matrix is then constructed according to the eigen decomposition results of the optimal low dimensional matrix. The S-Koopman energy matrix reflects the dynamic behavior of the system; its row/column vectors can extract different feature data following disturbance events, as well as the fluctuation strengths of PMU data at different positions. Furthermore, by analyzing the dynamic variation patterns of PMU data under different disturbance types and regions, quantitative indicators of disturbance event classification and regional localization are proposed. The calculation and analysis of the New England 10-generator 39-bus simulation system and the CEPRI-SSFS 197-bus real-world system verify the rationality, effectiveness, and accuracy of the proposed method.

This work is supported by the National Key Research and Development Program of China (No. 2021YFB2400800).

Key words: disturbance event classification; disturbance regional localization; S-Koopman energy matrix; quantitative indicator

0 引言

随着互联系统规模的扩大及复杂度的增加, 扰

动引发系统大停电事故的可能性也随之提升^[1]。调控人员需及时获取扰动类型及扰动发生的区域位置信息, 并采取相对应的安全稳定判别方法及区域稳定控制措施, 以减小扰动对系统的冲击。因此, 扰动类型及区域辨识的准确性对保证大电网安全稳定运行具有重要意义^[2-4]。

基金项目: 国家重点研发计划项目资助(2021YFB2400800)
“响应驱动的大电网稳定性智能增强分析与控制技术”

同步相量测量单元(phasor measurement unit, PMU)能够自动准确地记录电力系统发生扰动前后各种响应数据的变化情况^[5-6]。随着 PMU 在系统中的广泛部署,利用先进的数据驱动技术从响应数据中辨识系统扰动类型及扰动发生位置至关重要,这将给调控人员实时决策提供新途径^[7]。

针对扰动类型及位置辨识的数据驱动方法大致可分为监督类方法和非监督/统计类方法。监督类方法需要对大量工况的实际扰动特征进行标记,并通过离线训练得到输入与标记之间的映射模型,进而实现扰动类型及位置辨识。文献[8]提出一种基于双层卷积神经网络的扰动类型分类器,该方法的输入为响应数据的主特征值和奇异值,减少了训练的复杂性。文献[9]将故障检测模块与极限学习机分类器相结合,提高了计算效率和准确率。文献[10]提出基于扩散型核密度估计器的深度神经网络算法,该方法能用较短的数据实现扰动类型的高精度辨识。文献[11]提出一种基于附加角度边距损失函数优化的长短期记忆网络扰动类型分类方法,并结合再辨识策略实现高比例新能源系统扰动类型辨识。文献[12]提出了一种基于深度子领域自适应的振荡源定位方法。该方法通过输入样本与迁移模型的构建实现次/超同步振荡源在线定位,能够在较短的时间内给出更为准确的定位信息。

非监督/统计类方法主要利用变换、分解等手段直接从量测数据中提取扰动类型及位置信息,无需离线标记等辨识预先准备工作。文献[13]提出一种基于非负稀疏事件分解的扰动类型辨识及定位方法,该方法能从多维数据中提取扰动特征,但其仅考虑系统中与频率相关的扰动。为了能够实现在线辨识,文献[14]提出一种基于移动窗口主成分分析的扰动检测和分类方法,该方法同样仅考虑了与频率相关的扰动,对系统中的其余扰动类型考虑不全。文献[15]提出一种基于频谱分布分析的扰动位置辨识方法,该方法利用有功数据实现较高的辨识准确率,但无法提取扰动类型信息。文献[16]提出一种基于时间序列的能量相似性度量方法,划分系统扰动类型,利用 Teager-Kaiser 能量算子辨识扰动位置。文献[17]定义各区域的等效虚拟注入电流,并计算线路首末节点电压,进而通过计算值与实际值的关系定位扰动区域。

基于 Koopman 算子的扰动类型及位置辨识已受到国内外研究人员的广泛关注^[18-20]。文献[18]针对确定性系统进行分析,利用动态模式分解算法(dynamic mode decomposition, DMD)提取表征确定系统动态的有限维度 Koopman 算子,并构建相应的

Koopman 能量矩阵,该矩阵中不同数据类型和 PMU 中能量的强弱可用于表征扰动类型及位置。该方法有明确物理含义,具有较强的可解释性,并能对不同特征的数据进行辨识且无须进行标记。然而实际系统并非是完全的确定性系统,随机过程是系统动态的重要组成部分。上述针对确定系统的扰动特征辨识会导致辨识准确度不高。为了克服 Koopman 算子的缺点,本文提出一种基于随机 Koopman (S-Koopman)算子的扰动类型及扰动区域辨识方法,该方法针对包含随机过程的动态系统进行分析,利用子空间最优模式分解算法(subspace optimal mode decomposition, Sub-OpMD)计算得到包含随机系统动态信息的 S-Koopman 算子的低维最优矩阵,利用特征分解进一步构建 S-Koopman 能量矩阵,通过 S-Koopman 能量矩阵的行/列向量可以提取系统扰动事件发生后的不同特征数据以及不同位置 PMU 数据波动强弱,并进一步提出基于系统动态特性的扰动类型及扰动区域评估指标。本文利用新英格兰 10 机 39 节点仿真系统和 197 节点实际系统数据进行仿真验证,相比基于 Koopman 算子的扰动特征辨识方法,本文所提方法同样具有较强的可解释性并且辨识准确度更高,充分满足了现代大型区域互联系统对扰动特征辨识的精度要求。

1 S-Koopman 算子

Koopman 理论本质上类似于“坐标变换”,它最初使用希尔伯特空间上的线性变换来分析非线性哈密顿系统^[21-22]。通过使用无限维度的线性 Koopman 算子,可以将非线性系统近似成一个线性系统,进而通过分析线性系统就可以得到非线性动态系统的特征信息。

在 Koopman 算子的分析过程中将系统假设为仅包含状态量之间映射关系的确定性系统。然而在实际中,随机过程是系统动态的重要组成部分。因此,与确定性系统不同,考虑包含随机过程的离散动态系统^[21],如式(1)所示。

$$\mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k, w_k) \quad (1)$$

式中: \mathbf{x}_k 为时刻 k 系统的一个状态量; w_k 为时刻 k 系统的一个随机量,其与 \mathbf{x}_k 相互独立; $\mathbf{f}(\cdot)$ 表示一个随机系统的映射。

设 $g(\cdot)$ 为随机系统观测函数,则随机系统的 Koopman 运算符即 S-Koopman 运算符 \mathbf{K} 可定义为

$$\mathbf{K}g(\mathbf{x}) = \mathbb{E}[g(\mathbf{f}(\mathbf{x}, w))] \quad (2)$$

式中: $\mathbb{E}[\cdot]$ 表示计算括号内的数学期望。

随机系统存在相应的特征值和特征函数满足式

(3)的关系。

$$\mathbf{K}\boldsymbol{\varphi}_i(\mathbf{x}) = \mu_i\boldsymbol{\varphi}_i(\mathbf{x}) \quad (3)$$

式中: $\boldsymbol{\varphi}_i$ 为第 i 个 S-Koopman 特征函数; μ_i 为第 i 个 S-Koopman 特征值。

同样, 在 k 时刻设随机系统中存在一组观测函数 $\mathbf{g}(\mathbf{x}_k) = [g_1(\mathbf{x}_k) g_2(\mathbf{x}_k) \cdots g_r(\mathbf{x}_k)]^\top$, 存在一组 S-Koopman 算子满足式(4)。

$$[\mathbf{K}_k g_1(\mathbf{x}_k) \mathbf{K}_k g_2(\mathbf{x}_k) \cdots \mathbf{K}_k g_r(\mathbf{x}_k)]^\top = \mathbf{K}_k \mathbf{g}(\mathbf{x}_k) \quad (4)$$

式中: \mathbf{K}_k 为 k 时刻系统的 S-Koopman 算子。

则

$$\mathbf{g}(\mathbf{x}_{k+1}) = \mathbf{K}_k \mathbf{g}(\mathbf{x}_k) + \mathbf{e}_k \quad (5)$$

其中

$$\mathbf{e}_k \triangleq \mathbf{g}(\mathbf{f}(\mathbf{x}_k, \mathbf{w}_k)) - \mathbb{E}[\mathbf{g}(\mathbf{f}(\mathbf{x}_k, \mathbf{w}_k))] \quad (6)$$

S-Koopman 算子在 Koopman 算子的基础上考虑了系统的随机动态过程。在实际应用过程中, 无限维度的 S-Koopman 算子难以求取, 可以考虑将 S-Koopman 算子截断到有限高维子空间中。因此, 需要通过合适的方法提取有限维度的近似 S-Koopman 算子。

2 子空间最优模式分解算法(Sub-OpMD)

本文利用 DMD 的修改算法 Sub-OpMD 提取无限维度的 S-Koopman 算子最优近似矩阵^[22]。

考虑如式(1)所示的电力系统模型, 假设系统布置了 n 个 PMU, 每个 PMU 采集 5 种特征数据(电压 U 、有功功率 P 、无功功率 Q 、电流 I 、频率 f), 利用这些采集数据构建 k 时刻的 $\mathbf{g}(\mathbf{x}_k)$, 如式(7)所示。

$$\mathbf{g}(\mathbf{x}_k) = [U_k \ P_k \ Q_k \ I_k \ f_k]^\top \quad (7)$$

式中: $U_k, P_k, Q_k, I_k, f_k \in \mathbb{R}^{n \times 1}$, 分别表示 k 时刻系统的电压、有功功率、无功功率、电流和频率。

设输入数据的长度为 m , 则定义 k 时刻输入数据矩阵 \mathbf{X}_k^m 为

$$\mathbf{X}_k^m = [\mathbf{g}(\mathbf{x}_k) \ \mathbf{g}(\mathbf{x}_{k+1}) \ \cdots \ \mathbf{g}(\mathbf{x}_{m+k-1})] \quad (8)$$

式中: $\mathbf{X}_k^m \in \mathbb{R}^{5n \times m}$ 。

设置 $k=1, 2, 3, 4$, 可以得到数据矩阵 $\mathbf{X}_1^m, \mathbf{X}_2^m, \mathbf{X}_3^m, \mathbf{X}_4^m$, 进而构造矩阵 \mathbf{X}_p 和 \mathbf{X}_f , 如式(9)所示。

$$\begin{cases} \mathbf{X}_p = [(\mathbf{X}_1^m)^\top (\mathbf{X}_2^{m+1})^\top]^\top \\ \mathbf{X}_f = [(\mathbf{X}_3^{m+2})^\top (\mathbf{X}_4^{m+3})^\top]^\top \end{cases} \quad (9)$$

式中: $\mathbf{X}_p, \mathbf{X}_f \in \mathbb{R}^{10n \times m}$ 。

将 \mathbf{X}_f 的行向量投影到 \mathbf{X}_p 的行空间上, 构造正交投影矩阵 \mathbf{O} , 如式(10)所示。

$$\mathbf{O} = \mathbf{X}_f \mathbf{X}_p^\top (\mathbf{X}_p \mathbf{X}_p^\top)^{-1} \mathbf{X}_p \quad (10)$$

式中: $\mathbf{O} \in \mathbb{R}^{10n \times m}$ 。

对正交投影矩阵 \mathbf{O} 进行 SVD 分析, 如式(11)所示。

$$\mathbf{O} = \mathbf{B}\mathbf{S}\mathbf{V}^\top \quad (11)$$

式中: \mathbf{B} 和 \mathbf{V} 分别为 \mathbf{O} 的左奇异向量和右奇异向量; \mathbf{S} 为 \mathbf{O} 的奇异值矩阵。

定义 \mathbf{B}_1 和 \mathbf{B}_2 分别为 \mathbf{B} 的前 $5n$ 行子矩阵和后 $5n$ 行子矩阵, 引入正交矩阵 \mathbf{L} , 则系统低维近似矩阵构建问题可表示为

$$\min \|\mathbf{B}_2 - \mathbf{L}\mathbf{A}^* \mathbf{L}^\top \mathbf{B}_1\|_F^2 \quad (12)$$

式中: \mathbf{A}^* 为在矩阵 \mathbf{L} 构成空间下的系统最优低维近似矩阵; 正交矩阵 \mathbf{L} 满足 $\mathbf{L}^\top \mathbf{L} = \mathbf{I}$, \mathbf{I} 为单位矩阵; $\|\cdot\|_F$ 为 Frobenius 范数。

利用共轭梯度算法可以实现式(12)单变量优化问题的求解, 目的是计算 \mathbf{L} 的最佳维度矩阵 \mathbf{L}^* 。基于 \mathbf{L}^* , 可进一步得到矩阵 \mathbf{A}^* , 如式(13)所示。

$$\mathbf{A}^* = \mathbf{L}^{*\top} \mathbf{B}_2 \mathbf{B}_1^\top \mathbf{L}^* (\mathbf{L}^{*\top} \mathbf{B}_1 \mathbf{B}_1^\top \mathbf{L}^*)^{-1} \quad (13)$$

Sub-OpMD 算法在 DMD 法的基础上引入基于正交投影的矩阵线性变换以及共轭梯度算法^[23], 来弥补 DMD 的不足。

3 扰动事件分类及区域定位

3.1 S-Koopman 能量矩阵

对低维近似矩阵 \mathbf{A}^* 进行特征分解, 如式(14)所示。

$$\mathbf{A}^* = \boldsymbol{\Phi} \boldsymbol{\Lambda} \boldsymbol{\Phi}^{-1} \quad (14)$$

式中: $\boldsymbol{\Phi}$ 为特征向量构成的矩阵, $\boldsymbol{\Phi} = [\boldsymbol{\phi}_1 \ \boldsymbol{\phi}_2 \ \cdots \ \boldsymbol{\phi}_{5n}]$;

$\boldsymbol{\Lambda}$ 为系统特征值矩阵, $\boldsymbol{\Lambda} = \text{diag}[\lambda_1 \ \lambda_2 \ \cdots \ \lambda_{5n}]$ 。

定义模式模态矩阵 \mathbf{W} 和模式能量矩阵 \mathbf{E} 分别为

$$\mathbf{W} = \mathbf{B}_2 \mathbf{V}_i \mathbf{S}_i^{-1} \boldsymbol{\Phi} \boldsymbol{\Lambda}^{-1} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \cdots \ \mathbf{w}_{5n}] \quad (15)$$

$$\mathbf{E} = \boldsymbol{\Phi}^{-1} \mathbf{S}_i \mathbf{V}_i^\top = [\mathbf{e}_1 \ \mathbf{e}_2 \ \cdots \ \mathbf{e}_{5n}]^\top \quad (16)$$

式中: 模式能量矩阵 \mathbf{E} 可表示为系统不同模式下的总能量, 其含义可理解为模式的激发程度, 某一模式的能量越大代表该模式的激发程度越大; $\mathbf{e}_i = [e_{1,i} \ e_{2,i} \ \cdots \ e_{5n,i}]^\top$, \mathbf{e}_i 中各元素表征在模式 i 下对应各输入数据的能量值; 模式模态矩阵 \mathbf{W} 的含义可解释为不同模式下输入特征数据间的振荡关系, 同样也可以表征模式能量的扩散方向; $\mathbf{w}_i = [w_{1,i} \ w_{2,i} \ \cdots \ w_{5n,i}]^\top$, \mathbf{w}_i 中元素表征模式 i 下对应所有输入数据的能量扩散方向; \mathbf{S}_i 和 \mathbf{V}_i 分别是对 \mathbf{B}_1 进行 SVD 分解得到奇异值矩阵和右奇异向量。

通过模式模态矩阵 \mathbf{W} 和模式能量矩阵 \mathbf{E} 的组合可以得到输入数据窗口下全部能量, 这一组合可称为系统 S-Koopman 能量矩阵, 表示为 \mathbf{M} 。

$$\mathbf{M} = \begin{bmatrix} |w_{1,1}| & |w_{1,2}| & \cdots & |w_{1,5n}| \\ |w_{2,1}| & |w_{2,2}| & \cdots & |w_{2,5n}| \\ \vdots & \vdots & & \vdots \\ |w_{5n,1}| & |w_{5n,2}| & \cdots & |w_{5n,5n}| \end{bmatrix} \begin{bmatrix} \|e_1\| \\ \|e_2\| \\ \vdots \\ \|e_{5n}\| \end{bmatrix} = [M_1, M_2, \dots, M_{5n}] \quad (17)$$

式中： M_1 可表示第1个PMU中电压 U 的波动强弱； M_2 可表示第2个PMU中电压 U 的波动强弱； M_{5n} 可表示第5个PMU中频率 f 的波动强弱，依此类推。系统S-Koopman能量矩阵 \mathbf{M} 内各元素由模式模态矩阵和模式能量矩阵构成，具有明确的物理解释，具体可理解为不同位置PMU采集的不同特征数据在所有系统模式下的能量(波动)强弱，元素值越大表示能量(波动)越大。

为了辨识扰动类型，需要体现出扰动对系统中所有PMU采集的某一特征数据的波动强弱，同样为了辨识扰动发生位置，需要体现出扰动对某一PMU采集的所有特征数据的波动强弱。因此，对式(17)得到的S-Koopman能量矩阵内元素进行重新排列可得矩阵 \mathbf{M}^r ，如式(18)所示。

$$\mathbf{M}^r = \begin{bmatrix} M_1 & M_2 & \cdots & M_n \\ M_{n+1} & M_{n+2} & \cdots & M_{2n} \\ M_{2n+1} & M_{2n+2} & \cdots & M_{3n} \\ M_{3n+1} & M_{3n+2} & \cdots & M_{4n} \\ M_{4n+1} & M_{4n+2} & \cdots & M_{5n} \end{bmatrix} \quad (18)$$

\mathbf{M}^r 矩阵的行向量反映了系统中所有PMU采集的不同特征数据的波动强弱，列向量反映了不同位置PMU采集的所有特征数据的波动强弱。因此行向量可以用来辨识扰动类型，列向量可以用来辨识扰动位置。

3.2 扰动类型辨识

通过大量的仿真及系统实际运行经验，对于有功功率扰动(有功负载、发电机组投切等)，系统中的频率或无功功率会产生较大的波动^[18]；对于无功功率扰动(无功补偿装置投切等)，系统中的电压或无功功率会产生较大的波动；而系统故障(三相短路等)则会导致系统中所有电气量均波动较大^[24]。式(18)的行向量可以将这种波动强弱量化表征，因此基于上述不同系统扰动导致电气量波动情况的差异，结合式(18)的S-Koopman能量矩阵的行向量特点可以判断系统的扰动类型。

对式(18)所得矩阵 \mathbf{M}^r 的各行向量分别求和得到系统各特征数据对应的S-Koopman能量值。

$$\mathbf{M}_{\text{type}}^r = \text{sum}(\text{row}(\mathbf{M}^r)) = [M_U^r \ M_P^r \ M_Q^r \ M_I^r \ M_f^r]^T \quad (19)$$

式中： $\mathbf{M}_{\text{type}}^r$ 表示不同类型扰动事件下 \mathbf{M}^r 的各行向量分别求和后的矩阵； $\text{sum}(\text{row}(\cdot))$ 表示对矩阵的各行向量元素分别求和； M_U^r 、 M_P^r 、 M_Q^r 、 M_I^r 、 M_f^r 分别表示输入的电压、有功功率、无功功率、电流、频率数据对应的S-Koopman能量值。特征数据的能量值越大，表示系统中该数据的波动越大，因此式(19)可对系统不同特征数据受扰动影响程度进行量化表征。即对于无功扰动， M_U^r 或 M_Q^r 的值较大；对于有功扰动， M_P^r 或 M_f^r 的值较大；而对于故障， M_U^r 、 M_P^r 、 M_Q^r 、 M_I^r 、 M_f^r 的值均很大，且故障下S-Koopman能量矩阵内所有元素相加的总能量会远远大于有功/无功扰动下的能量矩阵内总能量值(后文仿真验证也证明，有功/无功扰动下总能量值的数量级与故障相差很大)。因此可以通过计算式(19)中能量值总和的大小区分故障和有功/无功扰动，二者存在如式(20)的关系。

$$\text{sum}(\mathbf{M}_{\text{fault}}^r) \gg \text{sum}(\mathbf{M}_{\text{dis}}^r) \quad (20)$$

式中： $\mathbf{M}_{\text{fault}}^r$ 和 $\mathbf{M}_{\text{dis}}^r$ 分别表示故障和有功/无功扰动下的 $\mathbf{M}_{\text{type}}^r$ 矩阵。

为了能够区分故障与有功/无功扰动类型，本文选取系统典型运行方式预想故障集中可能出现的最严重单一有功/无功扰动下的总能量值作为临界能量值 $\text{sum}(\mathbf{M}_{\text{dis,max}}^r)$ ，并构建故障与有功/无功扰动区分量化指标 F 。

$$F = \text{sum}(\mathbf{M}_{\text{dis,max}}^r) / \text{sum}(\mathbf{M}_{\text{type}}^r) = \begin{cases} > 1 \text{ 有功/无功扰动} \\ < 1 \text{ 故障扰动} \end{cases} \quad (21)$$

由式(21)可知，当 $F > 1$ 时，可判定系统发生有功/无功类型扰动，当 $F < 1$ 时，可判定系统发生故障类型的扰动。通常发生故障时， F 会远小于1。

在区分故障类型的扰动后，为了清晰辨识有功扰动和无功扰动，本文利用上述不同扰动下特征数据所对应能量大小的特点，构建有功/无功扰动类型辨识量化指标 D 。

$$D = (M_U^r + M_Q^r) / (M_P^r + M_f^r) = \begin{cases} > 1 \text{ 无功扰动} \\ < 1 \text{ 有功扰动} \end{cases} \quad (22)$$

由式(22)可知， $D > 1$ 时，可判定系统发生无功扰动， $D < 1$ 时，可判定系统发生有功扰动。

3.3 扰动区域辨识

扰动发生后，其对系统造成的影响会随着与扰动源距离的增加而减小^[25]。将该结论与式(18)的S-Koopman能量矩阵的列向量特点相结合，可以判

断系统的扰动位置, 对 M^r 的各列向量分别求和, 如式(23)所示。

$$M_{PMU}^r = \text{sum}(\text{column}(M^r)) = [M_{PMU1}^r \ M_{PMU2}^r \ \dots \ M_{PMUn}^r] \quad (23)$$

式中: $\text{sum}(\text{column}(\cdot))$ 表示对矩阵的各列向量元素分别求和; $M_{PMU1}^r, M_{PMU2}^r, \dots, M_{PMUn}^r$ 分别表示不同 PMU 对应的 S-Koopman 能量值。能量值越大表示系统中该 PMU 距离扰动点越近, 因此式(23)可对系统中不同位置 PMU 受扰动影响程度进行量化表征。

对于大规模互联电力系统, 通过对比不同区域内 PMU 的 S-Koopman 能量之和占总能量的比重, 可以判断扰动发生的区域。

$$R = \text{index} \left(\max \left(\frac{\sum_{i \in n_j} M_{PMUi}^r}{\text{sum}(M_{PMU}^r)} \right) \right) \quad (24)$$

式中: R 为扰动区域辨识指标; n_j 表示区域 j 内设置的 PMU 集合, $j=1,2,3,\dots$; $\text{index}(\cdot)$ 表示不同区域的 PMU 能量之和占总能量比例最大的区域标号。利用式(24)计算扰动发生区域的前提是保证各区域配置的 PMU 数量一致, 否则各区域能量大小的对比是无意义的。

基于 Sub-OpMD 的扰动类型和扰动区域辨识流程如图 1 所示。

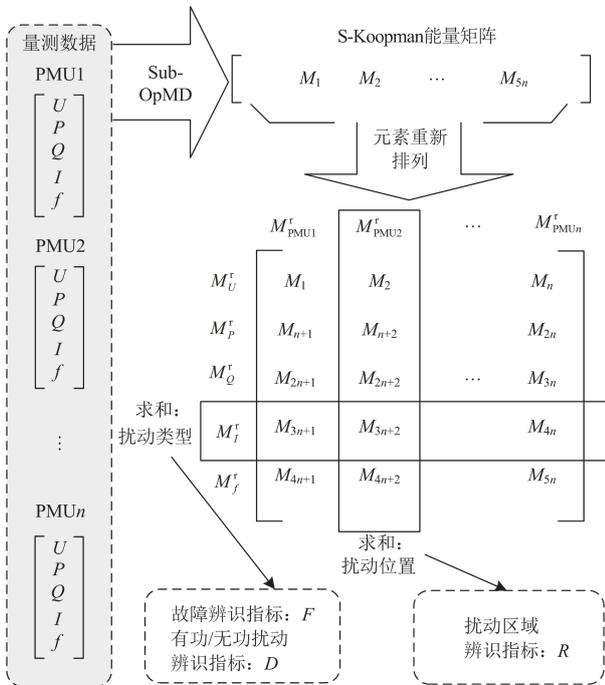


图 1 基于 Sub-OpMD 的扰动类型和扰动区域辨识流程图

Fig. 1 Flow chart of disturbance type and disturbance region identification based on Sub-OpMD

4 算例分析

4.1 10 机 39 节点仿真系统

本文采用 PSASP 平台, 以 10 机 39 节点仿真系统作为仿真算例, 该系统可划分为 3 个区域, 详细接线图见图 2。系统中各区域选取两个节点的 PMU 数据用于所提算法输入, 区域 1 选取节点 8、11; 区域 2 选取节点 19、23; 区域 3 选取节点 25、29。各节点均提取电压 U 、有功功率 P 、无功功率 Q 、电流 I 、频率 f 作为特征量。为了验证所提方法辨识的有效性, 本文在仿真系统中不同位置设置了不同类型的扰动, 详细设置见表 1。具体验证工作在 OptiPlex 7080 工作站(Intel Core i7-10700 CPU, 2.90 GHz)完成。

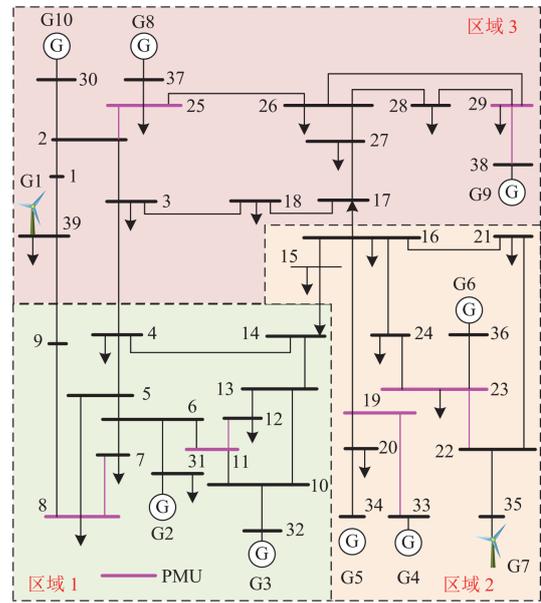


图 2 10 机 39 节点仿真系统

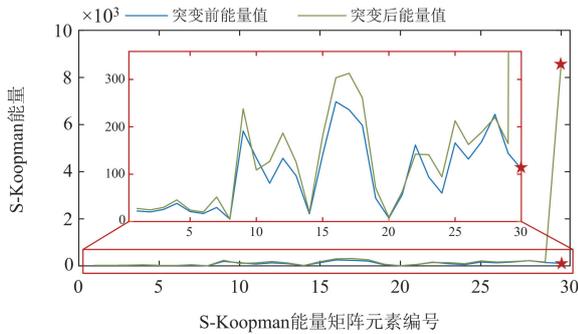
Fig. 2 New England 10-generator 39-bus simulation system

表 1 仿真系统扰动区域和扰动类型辨识结果

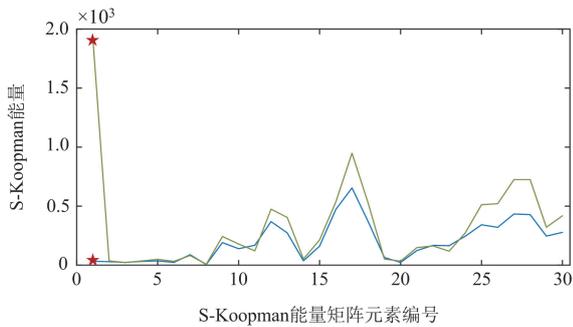
Table 1 Disturbance region and disturbance type identification results of simulation system

编号	扰动	扰动节点	扰动区域	扰动类型	扰动区域辨识结果
1	三相短路	5-6	1	故障	1
2	三相短路	25-26	3	故障	3
3	两相短路	23-24	2	故障	2
4	两相短路	28-29	3	故障	3
5	单相短路接地	21-22	2	故障	2
6	单相短路接地	2-25	3	故障	3
7	负载无功增加	3	3	无功扰动	3
8	负载有功增加	3	3	有功扰动	3
9	负载有功减小	20	2	有功扰动	2
10	负载无功减小	20	2	有功扰动	2
11	同步机脱网	36	2	有功扰动	2
12	同步机脱网	30	3	有功扰动	3

本文所提指标是基于 S-Koopman 能量矩阵 M 中的元素与不同 PMU 采集的特征数据之间存在的关联关系。因此，为了证明所提指标的合理性，本节利用试探法验证这种关联关系。在母线 36 同步机脱网扰动及母线 3 负载有功增加扰动下，分别额外设置母线 29 频率数据及母线 8 电压数据发生短时突变，观察对应的 S-Koopman 能量矩阵 M 中元素变化情况，具体如图 3 所示。由图 3(a)可以看出，在母线 29 频率数据设置短时突变前后，除母线 29 频率数据对应的能量值发生较大变化，其余能量均变化不大；同样由图 3(b)可以看出，在母线 8 电压数据设置短时突变前后，除母线 8 电压数据对应的能量值发生较大变化，其余能量均变化不大。通过以上分析可以看出，S-Koopman 能量矩阵与各 PMU 采集的特征数据之间关联性较强，这为本文所提指标的合理性打下了基础。



(a) 母线36同步机脱网扰动下母线29频率突变



(b) 母线3负载有功增加扰动下母线8电压突变

图 3 仿真系统特征数据突变下 S-Koopman 能量结果

Fig. 3 S-Koopman energy results under sudden changes in simulation system characteristic data

本文验证不同数据窗长度对扰动类型及扰动区域辨识结果的影响，以此找到最佳长度的数据窗。设置用于验证的数据窗长度分别为 0.5、0.7、0.9、1.1、1.3 s，辨识准确度结果如图 4 所示。可以看出，在计算时间方面，随着数据窗长度的增加，所提方

法计算时间会逐渐增加，但是增加的幅度不大。在扰动类型辨识方面，0.5 s 和 0.7 s 长度的数据辨识准确度结果为 91.7%，随着数据窗长度增加到 0.9 s 以上，准确度可达到 100%。在扰动区域辨识方面，所有数据窗长度均能达到 100% 的准确率。在实际应用中，为了快速准确地辨识系统的扰动类型和区域，除要求算法的快速性外，还需要使用尽可能短的扰动数据得到准确的辨识结果，这样可以在扰动发生后尽早获取有指导性的系统动态信息，为后续安全稳定判别和控制策略制定争取更多时间。综合以上分析，几种窗长数据的计算时间较为接近，但 0.5 s 的数据长度最短，且辨识准确度在可接受的范围内，因此，本文选取 0.5 s 长度的数据用于计算分析。

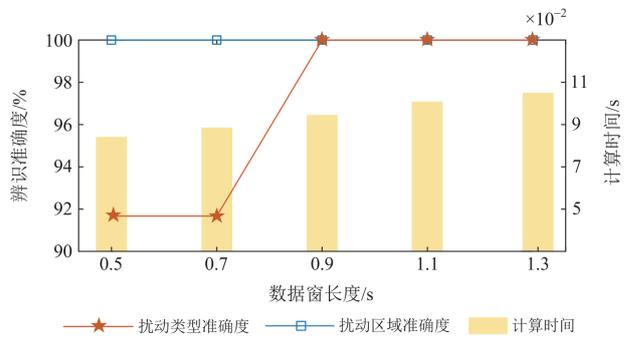


图 4 仿真系统不同数据窗长辨识准确度对比

Fig. 4 Comparison of identification accuracy for different data window lengths of simulation system

基于 0.5 s 长度数据的辨识结果见表 1，下面对其进行具体分析。首先对扰动类型进行分析，不同扰动下的总 S-Koopman 能量值如图 5 所示，从图 5 可以看出，当系统发生短路类型的故障时，计算得到的总 S-Koopman 能量值明显较大，这是因为短路故障对系统产生的冲击较大，使得系统各种电气量剧烈波动，导致总 S-Koopman 能量值激增。进一步通过式(21)计算 F 指标(其中临界能量值选取 G1 切机下的总能量)，计算结果如图 6 所示，可以看出该指标能准确区分故障和有功/无功扰动类型。在筛选出短路故障类型的扰动后，需对有功/无功扰动类型进一步分辨，根据式(18)可计算不同扰动下各特征数据的 S-Koopman 能量归一化计算结果，如图 7 所示。可以看出，发生有功扰动时频率的能量值是最大的，在发生无功扰动时无功功率的能量值是最大的，这与 3.2 节中的描述是一致的。进一步通过式(22)计算用于辨识有功/无功扰动类型的 D 指标，从图 6 的 D 指标可以看出，扰动 7 辨识为无功扰动，其余均为有功扰动。这一辨识结果与扰动 10 的实际故障类型不符，但整体的辨识精度仍然较高。

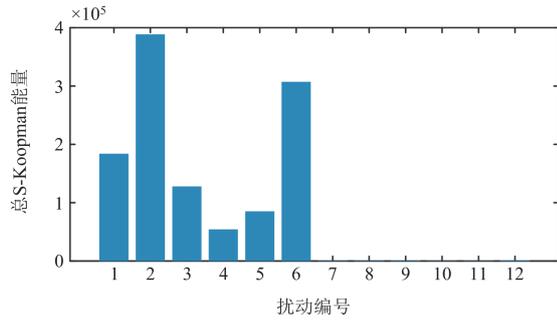


图5 仿真系统不同扰动下的总 S-Koopman 能量值

Fig. 5 Total S-Koopman transient energy values under different disturbances of simulation system

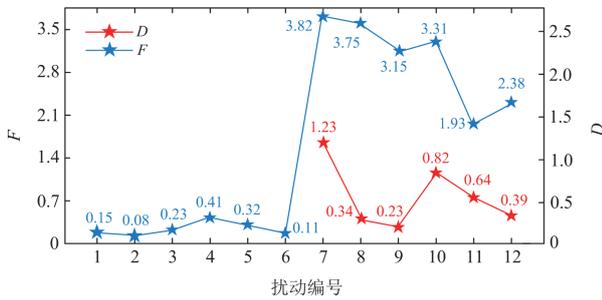


图6 仿真系统不同扰动下的扰动类型辨识结果

Fig. 6 Identification results of disturbance types under different disturbances of simulation system

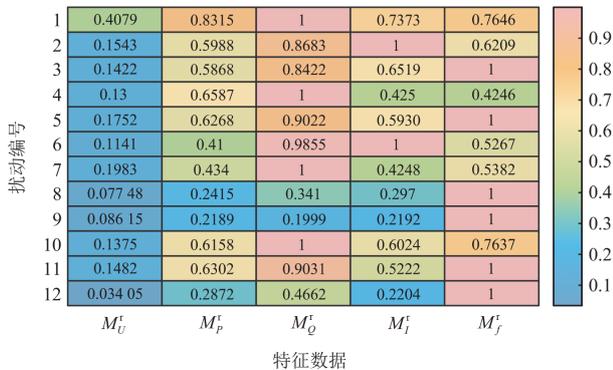


图7 仿真系统中不同扰动下各特征数据 S-Koopman 能量归一化结果

Fig. 7 S-Koopman energy normalization results of each feature data under different disturbances in simulation system

其次对扰动区域辨识进行具体分析, 根据式(23)可计算不同扰动下各 PMU 的 S-Koopman 能量, 同样为了更加直观地体现在不同扰动下各 PMU 能量大小对比, 此处也对不同扰动下的 PMU 结果进行归一化计算, 计算结果见图 8, 可以看出, 距离扰动发生节点最近的 PMU 能量最大, 这与 3.3 节的描述吻合。同时通过式(24)可计算得到各区域内

PMU 对应的 S-Koopman 能量占总能量的比例, 如图 9 所示, 进而通过式(24)计算扰动发生区域。从图 9 可以看出, 在已设置的扰动下, 本文所提方法能准确辨识扰动区域。

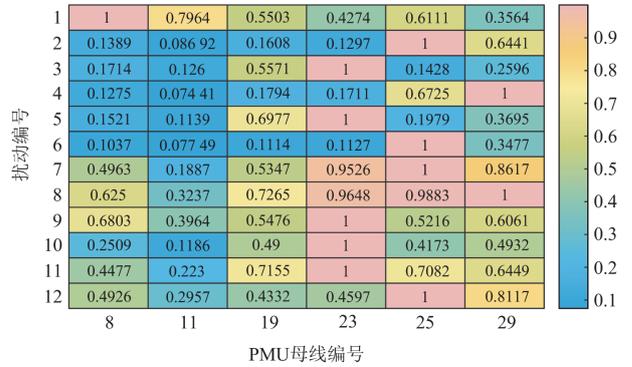


图8 仿真系统中不同扰动下 PMU 的 S-Koopman 能量归一化结果

Fig. 8 S-Koopman energy results of PMU under different disturbances in simulation system

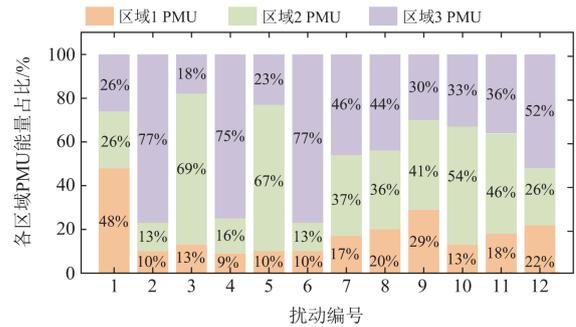


图9 仿真系统不同扰动下的扰动区域辨识结果

Fig. 9 Identification results of disturbance regions under different disturbances of simulation system

为了验证本文所提的基于 S-Koopman 算子的扰动类型及扰动区域辨识方法的优越性, 将计算结果与文献[18]、文献[24]中的非监督/统计类方法进行对比, 对比结果如表 2 所示。从表 2 中可以看出, 对比文献[18]、文献[24]中的非监督/统计类方法, 所提方法在扰动类型及扰动区域辨识的准确度更高, 能够更准确地从响应数据中提取系统特征。

此外, 由于本文引入 S-Koopman 算子来处理随机动态系统, 因此本节还分别验证了 1%、2%、3% 随机扰动下所提方法与文献[18]方法辨识的准确率, 计算结果如表 3 所示。可以看出, 不同随机扰动对两种方法的辨识结果没有影响, 因为随机扰动对系统的影响相较于故障、扰动事件很小, 并不影响对故障及扰动的辨识。

表 2 仿真系统不同方法下的辨识准确率对比

Table 2 Comparison of identification accuracy under different methods of simulation system

辨识类型	方法	准确率/%
扰动类型	本文	91.67
	文献[18]	83.33
	文献[24]	75.00
扰动区域	本文	100
	文献[18]	83.33
	文献[24]	83.33

表 3 仿真系统不同随机扰动幅值下的辨识准确率对比

Table 3 Comparison of identification accuracy under different random disturbance amplitudes of simulation system

辨识类型	随机扰动幅值/%	方法	准确率/%
扰动类型	1	本文	91.67
		文献[18]	83.33
		文献[24]	75.00
	2	本文	91.67
		文献[18]	83.33
		文献[24]	75.00
扰动区域	1	本文	100
		文献[18]	83.33
		文献[24]	75.00
	2	本文	100
		文献[18]	83.33
		文献[24]	75.00
3	本文	100	
	文献[18]	83.33	

4.2 CEPRI-SSFS 197 节点实际系统

以中国电科院发布的 197 节点实际系统 (CEPRI-SSFS) 为例, 进一步验证所提方法辨识结果的准确性。该系统可划分为 2 个区域, 详细接线图见图 10。系统中各区域选取 4 个节点的 PMU 数据用于所提算法的输入, 其中区域 A 选取节点 A-13、A-16、A-23、A-25; 区域 B 选取节点 B-6、B-8、B-12、B-17, 各节点同样均提取电压 U 、有功功率 P 、无功功率 Q 、电流 I 、频率 f 作为特征量。为了验证所提方法辨识的有效性, 本文在实际系统中不同位置设置了不同类型的扰动, 详细设置见表 4。在数据窗长度的选择方面, 与仿真系统的验证过程类似, 本文选取 0.7 s 的数据窗用于实际系统辨识。

197 节点实际系统的辨识结果见表 4。利用 Sub-OpMD 对实际系统的扰动类型进行分析, 不同扰动下的总 S-Koopman 能量值如图 11 所示。可以看出, 当系统发生短路类型的故障时, 计算得到的总 S-Koopman 能量值均较大, 通过式(21)计算 F 指标 (其中临界能量值选取直流双极闭锁下的总能量),

计算结果如图 12 所示, 可以看出该指标能准确区分故障和有功/无功扰动类型。在有功/无功扰动类型辨识方面, 同样可根据式(18)计算不同扰动下各特征数据的 S-Koopman 能量, 各特征数据能量的归一化计算结果见图 13。通过式(22)计算用于辨识有功/无功扰动类型的 D 指标。从图 12 的 D 指标可以看出, 辨识出所有扰动均为有功扰动, 辨识结果仅扰动 7 和扰动 10 与实际故障类型不符, 辨识精度仍可接受。

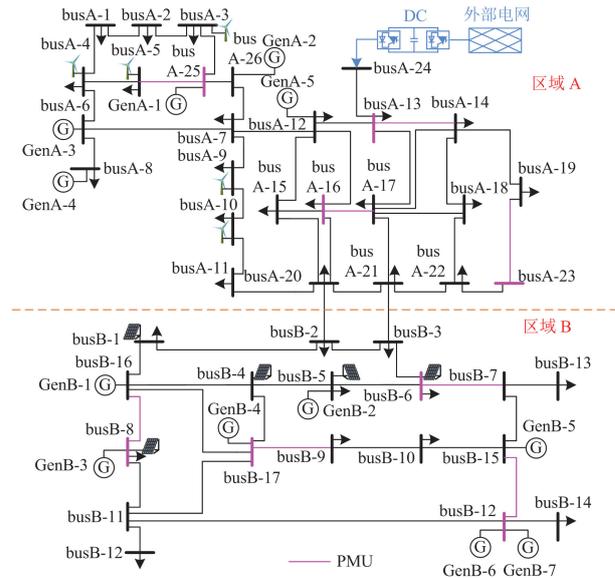


图 10 CEPRI-SSFS 197 节点实际系统

Fig. 10 CEPRI-SSFS 197-bus real system

表 4 实际系统扰动区域和扰动类型辨识结果

Table 4 Disturbance region and disturbance type identification results of real system

编号	扰动	扰动节点	扰动区域	扰动类型	辨识结果
1	三相短路	A-13	A	故障	A
2	三相短路	B-11	B	故障	B
3	两相短路	A-17	A	故障	A
4	两相短路	B-4	B	故障	B
5	单相短路接地	A-7	A	故障	A
6	单相短路接地	B-15	B	故障	B
7	负载无功增加	A-15	A	有功扰动	A
8	负载有功增加	A-15	A	有功扰动	B
9	负载有功减小	B-10	B	有功扰动	B
10	负载无功减小	B-10	B	有功扰动	B
11	同步机脱网	A-8	A	有功扰动	A
12	同步机脱网	B-15	B	有功扰动	B
13	风机脱网	A-9	A	有功扰动	A
14	光伏脱网	B-8	B	有功扰动	B
15	直流单极闭锁	A-24	A	有功扰动	A

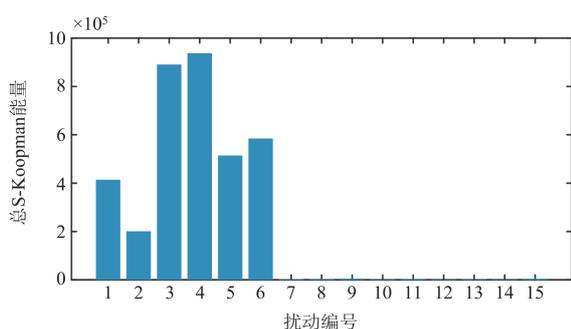


图 11 实际系统不同扰动下的总 S-Koopman 能量值

Fig. 11 Total S-Koopman transient energy values under different disturbances of real system

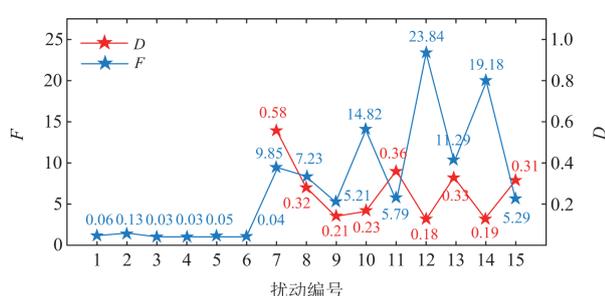


图 12 实际系统不同扰动下的扰动类型辨识结果

Fig. 12 Identification results of disturbance types under different disturbances of real system

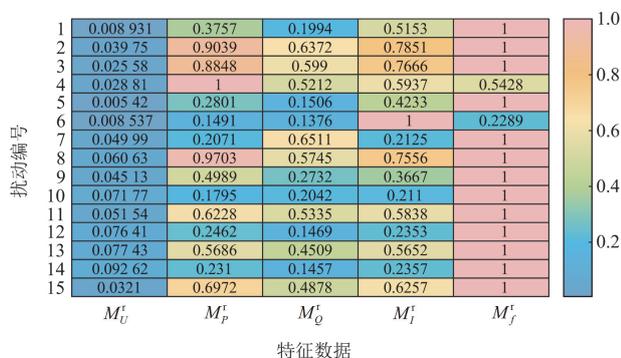


图 13 实际系统中不同扰动下各特征数据 S-Koopman 能量归一化结果

Fig. 13 S-Koopman energy normalization results of each feature data under different disturbances in real system

在扰动区域的辨识方面, 根据式(23)可计算不同扰动下各 PMU 的 S-Koopman 能量, 其中各 PMU 归一化后的能量计算结果见图 14, 并同时通过式(24)计算得到各区域内 PMU 对应的 S-Koopman 能量占总能量的比例, 如图 15 所示, 进而通过式(24)计算扰动发生区域。从图 15 可以看出, 除扰动 8 外, 本文所提方法均能准确辨识扰动区域。

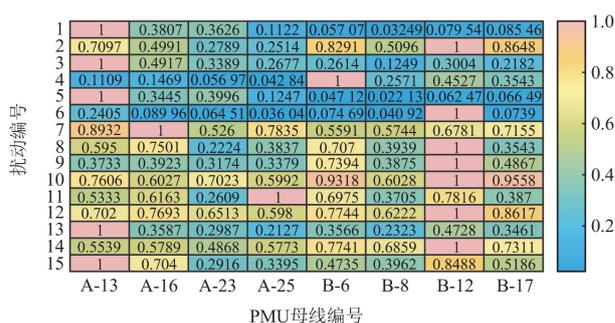


图 14 实际系统中不同扰动下 PMU 的 S-Koopman 能量归一化结果

Fig. 14 S-Koopman energy results of PMU under different disturbances in real system

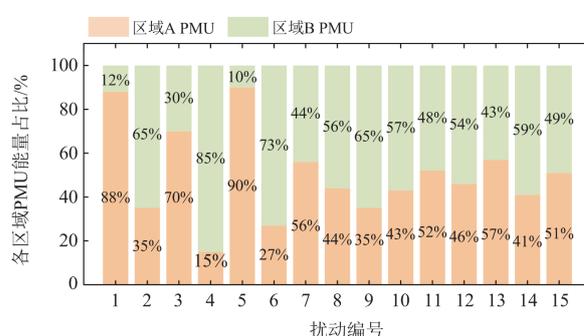


图 15 实际系统不同扰动下的扰动区域辨识结果

Fig. 15 Identification results of disturbance regions under different disturbances of real system

将本文所提方法用于实际系统扰动类型及扰动区域辨识, 并将辨识准确度统计结果与文献[18,24]中的方法进行对比验证, 对比结果如表 5 所示。可以看出, 所提方法的辨识准确度是最高的。

表 5 实际系统不同方法下的辨识准确率对比

Table 5 Comparison of identification accuracy under different methods of real system

辨识类型	方法	准确率/%
扰动类型	本文方法	86.67
	文献[18]	73.33
扰动区域	文献[24]	73.33
	本文方法	93.33
	文献[18]	80.00
	文献[24]	73.33

同样, 本节还分别验证了 1%、2%、3% 随机扰动下所提方法与文献[18]方法辨识的准确率, 计算结果见表 6。由表 6 可以看出, 不同随机扰动对两种方法的辨识结果同样没有影响。

表 6 实际系统不同随机扰动幅值下的辨识准确率对比

Table 6 Comparison of identification accuracy under different random disturbance amplitudes of real system

辨识类型	随机扰动幅值/%	方法	准确率/%
扰动类型	1	本文方法	86.67
		文献[18]	73.33
	2	本文方法	86.67
		文献[18]	73.33
	3	本文方法	86.67
		文献[18]	73.33
扰动区域	1	本文方法	93.33
		文献[18]	80.00
	2	本文方法	93.33
		文献[18]	80.00
	3	本文方法	93.33
		文献[18]	80.00

5 结论

针对多区域互联系统, 本文提出了一种基于 S-Koopman 的扰动类型及扰动区域辨识方法。该方法利用 Sub-OpMD 构建 S-Koopman 能量矩阵, 通过 S-Koopman 能量矩阵的行/列向量可以提取系统扰动事件发生后的不同特征数据以及不同位置 PMU 数据波动强弱, 并提出用于辨识扰动类型及扰动区域的量化指标。基于新英格兰 10 机 39 节点仿真系统和某地区 197 节点实际系统的辨识结果表明, 本文所提方法可以从多类型数据中辨识扰动特征及扰动区域, 且采用较短的数据窗就可以达到较高的辨识准确率。通过与基于 Koopman 分析的 DMD 以及非监督类方法的对比验证, 表明本文所提方法的辨识准确度更高, 鲁棒性更强。

本文考虑了多种扰动类型, 但由于断线故障对于系统的影响受制于故障位置及系统运行状态, 其特征难以提取, 因此在未来的研究中, 可以继续强化本文方法, 使其能够准确辨识系统断线故障。此外, 本文缺乏对更复杂电网结构、实际工况下的方法泛化能力的验证, 未来研究将针对更大型实际电网进行重点分析。

参考文献

- [1] 黄登一, 刘灏, 毕天姝, 等. 基于模型-数据联合驱动的电网扰动定位方法[J]. 电网技术, 2023, 47(3): 1206-1217. HUANG Dengyi, LIU Hao, BI Tianshu, et al. A joint model and data-driven based power system disturbance localization approach[J]. Power System Technology, 2023, 47(3): 1206-1217.
- [2] LIU Shenyuan, ZHAO Yuxuan, LIN Zhenzhi, et al. Data-driven event detection of power systems based on unequal-interval reduction of PMU data and local outlier factor[J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1630-1643.
- [3] CAICEDO J E, AGUDELO-MARTÍNEZ D, RIVAS-TRUJILLO E, et al. A systematic review of real-time detection and classification of power quality disturbances[J]. Protection and Control of Modern Power Systems, 2023, 8(1): 1-37.
- [4] 张海春, 陈望达, 沈浚, 等. 计及灵活性资源的配电网韧性研究评述[J]. 电力建设, 2023, 44(12): 66-84. ZHANG Haichun, CHEN Wangda, SHEN Jun, et al. Review of power distribution network resilience studies considering flexibility resources[J]. Electric Power Construction, 2023, 44(12): 66-84.
- [5] 谢李为, 李勇, 罗隆福, 等. 基于节点电压差值的配电网故障定位方法[J]. 电力系统保护与控制, 2023, 51(6): 106-116. XIE Liwei, LI Yong, LUO Longfu, et al. A novel fault location method employing node voltage difference value for a distribution network[J]. Power System Protection and Control, 2023, 51(6): 106-116.
- [6] ZUHAIB M, RIHAN M, SAEED M T. A novel method for locating the source of sustained oscillation in power system using synchrophasors data[J]. Protection and Control of Modern Power Systems, 2020, 5(4): 1-12.
- [7] 汪颖, 喻梦洁, 卢宏, 等. 基于最大互信息的干扰源类型识别及电能质量需求画像技术[J]. 电力系统自动化, 2022, 46(9): 171-181. WANG Ying, YU Mengjie, LU Hong, et al. Interference source type identification and power quality demand portrait technology based on maximum mutual information[J]. Automation of Electric Power Systems, 2022, 46(9): 171-181.
- [8] LI Wenting, WANG Meng. Identifying overlapping successive events using a shallow convolutional neural network[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4762-4772.
- [9] BISWAL M, BRAHMA S M, CAO Huiping. Supervisory protection and automated event diagnosis using PMU data[J]. IEEE Transactions on power Delivery, 2016, 31(4): 1855-1863.
- [10] YADAV R, RAJ S, PRADHAN A K. Real-time event classification in power system with renewables using kernel density estimation and deep neural network[J]. IEEE Transactions on Smart Grid, 2019, 10(6): 6849-6859.

- [11] 李子康, 刘灏, 毕天姝, 等. 基于数据驱动的鲁棒性电力系统扰动识别[J]. 中国电机工程学报, 2021, 41(21): 7261-7275.
LI Zikang, LIU Hao, BI Tianshu, et al. Data-driven robust power system disturbance identification[J]. Proceedings of the CSEE, 2021, 41(21): 7261-7275.
- [12] 郝琪, 刘崇茹, 王瑾媛, 等. 基于深度子领域自适应的直驱风机次/超同步振荡源定位[J]. 电力系统自动化, 2023, 47(17): 27-37.
HAO Qi, LIU Chongru, WANG Jinyuan, et al. Location of sub-super-synchronous oscillation source for direct-driven wind turbines based on deep subdomain adaptation[J]. Automation of Electric Power Systems, 2023, 47(17): 27-37.
- [13] WANG Wei, HE Li, MARKHAM P, et al. Multiple event detection and recognition through sparse unmixing for high-resolution situational awareness in power grid[J]. IEEE Transactions on Smart Grid, 2014, 5(4): 1654-1664.
- [14] RAFFERTY M, LIU Xueqin, LAVERTY D M, et al. Real-time multiple event detection and classification using moving window PCA[J]. IEEE Transactions on Smart Grid, 2016, 7(5): 2537-2548.
- [15] YANG Fan, WEI Mingjie, LING Zenan, et al. Brown measure based spectral distribution analysis for spatial-temporal localization of cascading events in power grids[J]. IEEE Transactions on Smart Grid, 2021, 12(2): 1805-1820.
- [16] YADAV R, PRADHAN A K, KAMWA I. Real-time multiple event detection and classification in power system using signal energy transformations[J]. IEEE Transactions on Industrial Informatics, 2019, 15(3): 1521-1531.
- [17] 李浩, 张禄亮, 栾云飞, 等. 基于子系统划分和注入电流比的配电网故障定位方法[J]. 电力系统保护与控制, 2023, 51(8): 63-72.
LI Hao, ZHANG Luliang, LUAN Yunfei, et al. Fault location method for a distribution network based on subsystem division and injection current ratio[J]. Power System Protection and Control, 2023, 51(8): 63-72.
- [18] VOSUGHI A, SADANANDAN S K, SRIVASTAVA A K. Synchrophasor-based event detection, classification, and localization using Koopman, transient energy matrix, best worth method, and dynamic graph[J]. IEEE Transactions on power Delivery, 2022, 37(3): 1986-1996.
- [19] 张智伟, 范新桥, 张利, 等. 基于动态模式分解的三端多段式架空线-电缆混合输电线路故障定位新方法[J]. 电力系统及其自动化学报, 2022, 34(10): 129-137.
ZHANG Zhiwei, FAN Xinqiao, ZHANG Li, et al. Novel fault location method for three-terminal multi-segment overhead-cable hybrid transmission line based on dynamic mode decomposition[J]. Proceedings of the CSU-EPSSA, 2022, 34(10): 129-137.
- [20] WILCHES-BERNAL F, RENO M J, HERNANDEZ A J. A dynamic mode decomposition scheme to analyze power quality events[J]. IEEE Access, 2021, 9: 70775-70788.
- [21] TAKEISHI N, KAWAHARA Y, YAIRI T. Subspace dynamic mode decomposition for stochastic Koopman analysis[J]. Physical Review, 2017, 96(3): 330-310.
- [22] 焦鹏悦, 杨德友, 蔡国伟. 基于 Koopman 算子与卡尔曼滤波的同步发电机动态状态估计[J]. 电力系统保护与控制, 2024, 52(9): 27-35.
JIAO Pengyue, YANG Deyou, CAI Guowei. Dynamic state estimation for a synchronous generator based on the Koopman operator and Kalman filter[J]. Power System Protection and Control, 2024, 52(9): 27-35.
- [23] 周书宇, 蔡国伟, 杨德友, 等. 随机数据驱动的电力系统小干扰稳定在线评估方法[J]. 电力系统自动化, 2022, 46(10): 94-100.
ZHOU Shuyu, CAI Guowei, YANG Deyou, et al. Ambient data-driven on-line evaluation method of power system small signal stability[J]. Automation of Electric Power Systems, 2022, 46(10): 94-100.
- [24] PANDEY S, SRIVASTAVA A K, AMIDAN B G. A real time event detection, classification and localization using synchrophasor data[J]. IEEE Transactions on Power Systems, 2020, 35(6): 4421-4431.
- [25] DUBEY R, SAMANTARAY S R, PANIGRAHI B K, et al. Koopman analysis based wide-area back-up protection and faulted line identification for series-compensated power network[J]. IEEE Systems Journal, 2018, 12(3): 2634-2644.

收稿日期: 2024-07-30; 修回日期: 2024-12-08

作者简介:

周书宇(1995—), 男, 博士, 工程师, 研究方向为电力系统稳定分析与控制; E-mail: zzhousy@163.com

杨晶莹(1976—), 女, 通信作者, 硕士, 正高级工程师, 研究方向为电力系统稳定分析与控制。

(编辑 周金梅)