

基于PMU量测数据的噪声环境下电力系统故障检测

黄 赛, 周毅博

(东北电力大学电气工程学院, 吉林 吉林 132012)

摘要: 随着广域量测系统 (Wide-Area Measurement System, WAMS) 部署的日趋完善, 为电力系统提供了海量高准确度的量测数据, 这些数据被广泛用于电力系统的故障检测。但量测数据中噪声的存在会影响故障检测的准确性, 导致漏判的发生, 使电网面临故障范围扩大的风险。因此, 提出了一种适用于噪声环境下的电网故障检测方法, 该方法源于随机矩阵理论 (Random Matrix Theory, RMT), 通过对量测数据矩阵进行增维处理以弱化噪声的影响, 并对数据源矩阵进行预处理, 从理论上推导出抗噪声性能优异的故障检测指标, 通过比较故障检测指标与阈值的大小关系实现电网的故障检测, 为调度运行人员实时监视电网运行状态提供依据。在 IEEE 39 节点系统设置算例, 验证了该方法的有效性。

关键词: 故障检测; 量测数据; 噪声; 随机矩阵理论; 最大特征值

Fault detection of power system in noise environment based on PMU measurement data

HUANG Sai, ZHOU Yibo

(School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China)

Abstract: With the increasing perfect deployment of wide-area measurement system, it provides massive high-precision measurement data for the power system, which is widely used for the fault detection of the power system. However, the existence of noise in the measurement data will affect the accuracy of fault detection, lead to the occurrence of leakage judgment, and make the power grid face the risk of expanding the fault range. Therefore, the paper proposed a grid fault detection method for noise environment, the method derived from random matrix theory, through the measurement data matrix to weaken the noise, and the matrix of data source, theoretically derived excellent fault detection index, by comparing the fault detection index and the threshold size relationship, provides the basis for dispatching operators real-time monitoring of power grid operation status. The effectiveness of the proposed method is verified in the IEEE39 node system setting examples.

key words: fault detection; measuring data; noise; random matrix theory; maximum eigenvalue

0 引言

现代电力系统规模日益庞大, 在运行过程中

不可避免地会发生各种故障^[1]。故障发生后, 及时准确的故障检测对电力系统安全稳定运行、避

吉林省科技发展计划项目 (20220208150RC)

免事故范围扩大具有重要的意义。

电网运行过程中，调度人员主要关心的三个问题分别是：电网有无事件发生；电网目前所处的运行状态是什么；如何下达操作指令保证电网的安全可靠运行。电力系统的故障检测主要解决电网调度运行人员关心的第一个问题，是调度运行人员感知电网运行状态并下达操作指令的基础。

现有的故障检测方法可分为两种：一种是基于系统模型的方法；另一种是基于数据驱动的方法。

基于模型的方法通过提前建立好的系统模型进行故障检测，文献[2]通过线路的参数计算行波的波速，利用单端行波法完成故障检测与故障测距的任务；文献[3]提出了一种基于直流脉冲信号注入的故障定位方法，通过比较注入信号后电流波形与基准电流波形的差异实现故障定位。基于模型的方法中，系统模型的建立是经过假设和简化后得到的，假设和简化过程中不可避免带来误差，故障检测的准确性依赖于模型和参数的有效性。

近年来，随着同步相量测量装置（Phasor Measurement Unit, PMU）在电网中的广泛装设，为电力系统提供了海量高准确度的电压、电流信息，也推动了基于数据驱动的电力系统故障检测研究。基于数据驱动的电力系统故障检测方法包括人工智能算法和随机矩阵理论方法。

人工智能算法在故障检测中的应用主要是机器学习，文献[4]采用基于隐马尔可夫模型的机器学习算法，利用系统频率和节点电压，通过区分故障发生前后的数据差异来检测故障的发生。但基于智能算法的故障检测阈值的选取是根据经验设置的，不同阈值的选取对训练结果造成显著的影响，且阈值的给定缺乏足够的数学解释。

随机矩阵理论起源于原子核物理领域，在金融和通信领域的研究中取得了一定的成果，是近年来兴起的对高维复杂系统进行统计分析的在线大数据分析方法之一。随机矩阵理论对测量得到的电力系统PMU数据拥有完全统计的解释，

在电力系统的故障检测中得到了广泛应用。文献[5]首次将随机矩阵理论运用到电网中，提出了一种通用的大数据分析框架，并验证了将随机矩阵理论用于电力系统的可行性。文献[6]定义平均谱半径作为故障检测指标，根据计算的平均谱半径是否越过阈值判断电网故障的发生。

受通信问题、电磁干扰等因素影响，电力系统数据采集过程中存在量测噪声，噪声的存在使得传统随机矩阵理论方法用于故障检测的准确度受到影响，导致漏判或误判的发生。为提高噪声环境下故障检测的准确率，文献[7]建立了一种比传统故障检测指标具有更强抗噪声性能的故障检测新指标，但其抗噪声能力有限，强噪声环境下故障检测准确性受到影响。因此，找到一种提高噪声环境下的故障检测方法成为亟须解决的问题。

本文提出了一种考虑PMU量测噪声的电力系统故障检测方法，该方法提高了低信噪比环境下故障检测的准确率。首先，将含噪声的电网PMU量测数据进行预处理以构建随机矩阵；其次，基于随机矩阵理论构建最大几何平均特征值（Maximum-Geometric Mean Eigenvalue, MGME）作为故障检测指标，为满足矩阵维数要求达到的渐进收敛条件，对原始数据矩阵进行增维处理；最后，通过比较实时计算的MGME与阈值的关系完成电网的实时故障检测。在IEEE 39节点系统设置算例，比较传统随机矩阵理论方法和本文所提方法在噪声环境下故障检测的效果，验证了所提方法的有效性和准确性。

1 随机矩阵理论及故障检测指标

1.1 随机矩阵理论

（1）随机矩阵理论概述

随机矩阵是元素为随机变量的一类矩阵，随机矩阵理论主要研究随机矩阵的特征值（奇异值）的统计分析性质。通过分析随机矩阵特征值统计特性的变化，表征数据波动性，进而将数据特征映射到物理系统中。

随机矩阵的谱分布函数表征了随机矩阵特征值的分布情况。假设 $\mathbf{A}$ 是一个 $n \times n$ 的随机矩阵，当随机矩阵的行数、列数很小时，其特征值收敛于以下经验谱分布函数（Empirical Spectral Distribution, ESD），即

$$F^{\mathbf{A}}(x) = \frac{1}{n} \sum_{i=1}^n I(\lambda_i^{\mathbf{A}} \leq x) \quad (1)$$

式中， $\lambda_i^{\mathbf{A}}$ ($i=1,2,\dots,n$) 为矩阵 $\mathbf{A}$ 的特征值； $I(\cdot)$ 为指示性函数； x 为随机变量； n 为矩阵的维数。

当随机矩阵的行数和列数趋于无穷大，且矩阵的行列比保持不变时，矩阵的特征值、奇异值等参数的统计分布满足一定的特性，如单环定律、M-P律等。此时矩阵的特征值、奇异值等参数的统计分布满足收敛于极限谱分布函数（Limiting Spectral Distribution, LSD）。

(2) M-P律

M-P律用于描述大维随机矩阵的协方差矩阵的特征值统计分布特性。设矩阵 $\mathbf{X}_{N \times T}$ 是维数为 $N \times T$ 的非Hermitian矩阵，当矩阵 $\mathbf{X}$ 的每一行均满足均值 $\mu(\mathbf{X}_i)=0$ 、方差 $\sigma^2(\mathbf{X}_i)=1$ 的条件时，在 $N, T \rightarrow \infty$ 和 $c=N/T \in (0, 1]$ 的条件下，矩阵的协方差矩阵 $\mathbf{R}$ 收敛于极限谱分布 $f(\lambda_R)$ ，即

$$f(\lambda_R) = \begin{cases} \frac{1}{2\pi c \lambda_R \sigma^2} \sqrt{(b-\lambda_R)(\lambda_R-a)}, & a \leq \lambda_R \leq b \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中， $a = \sigma^2(1-\sqrt{c})^2$ 为特征值的理论下限值； $b = \sigma^2(1+\sqrt{c})^2$ 为特征值的理论上限值； λ_R 为矩阵 $\mathbf{R}$ 的特征值。

当电网有故障发生时，矩阵中的元素不满足上述条件，其协方差矩阵 $\mathbf{R}$ 特征值的统计分布特性不再满足式（2）中的分布。

1.2 故障检测指标

随机矩阵有与其阶数相等个数的特征值，需要定义指标以便直观地反映矩阵众多特征值的分布情况，将这些指标称为线性特征值统计量（Linear Eigenvalue Statistic, LES）。

电力系统故障检测的任务一般通过设置相应的能反映故障信息的故障检测指标完成。应用随

机矩阵理论进行故障检测时，一般定义线性特征值统计量作为故障检测指标。

在随机矩阵理论中，平均谱半径（Mean Spectral Radius, MSR）是常用的线性特征值统计量，是矩阵 $\mathbf{Z}_{\text{std}}$ 在复平面上所有特征值到原点的距离之和的平均值。MSR的定义为

$$r_{\text{MSR}} = \frac{1}{N} \sum_{i=1}^N |\lambda_{\mathbf{Z}_{\text{std}}}^i| \quad (3)$$

式中， r_{MSR} 为随机矩阵的平均谱半径； N 为矩阵的维数； $\lambda_{\mathbf{Z}_{\text{std}}}$ 为矩阵 $\mathbf{Z}_{\text{std}}$ 的特征值。

通过比较 r_{MSR} 与内环半径的关系判断电力系统是否处于故障状态，当 r_{MSR} 小于内环半径时，判断系统发生故障。

2 基于MGME指标的故障检测方法

2.1 随机矩阵模型的构建

假设某电力系统中有 n 个母线装设有PMU，且每个母线上都有 m 个被测的电气量，构成了 N （ $N=n \times m$ ）个电气量数据。任意采样时刻 t_i 的PMU量测数据可以构成一个列向量 $\tilde{\mathbf{x}}(t_i)$ ，表达式为

$$\tilde{\mathbf{x}}(t_i) = [\tilde{x}_{1i} \quad \tilde{x}_{2i} \quad \dots \quad \tilde{x}_{Ni}]^T \quad (4)$$

将每个采样时刻的量测数据向量按时间顺序排列，可形成如下 $N \times T$ 维的PMU量测矩阵，即

$$\mathbf{X}_{N \times T} = [\tilde{\mathbf{x}}(t_1), \tilde{\mathbf{x}}(t_2), \dots, \tilde{\mathbf{x}}(t_i), \dots] \in C^{N \times T} \quad (5)$$

为了对数据进行实时分析，采用时间窗矩阵生成上述矩阵，时间窗矩阵的长度为 T_w ，宽度为 N 。时间窗矩阵包含当前时刻 t_i 的量测数据和 $T_w - 1$ 个相邻的历史数据向量，每次采样结束都会向后平移一个采样点。时间窗矩阵表示为

$$\mathbf{X}_{N \times T_w}(t_i) = [\tilde{\mathbf{x}}(t_i - T_w + 1), \tilde{\mathbf{x}}(t_i - T_w + 2), \dots, \tilde{\mathbf{x}}(t_i)] \quad (6)$$

该矩阵即为应用随机矩阵理论分析的数据源，这些数据按照时间顺序采样，通过对以上数据进行相应的变换可完成故障检测工作。

2.2 故障检测指标MGME的构建

(1) 噪声环境下MSR的有效性分析

传统的随机矩阵理论方法通常选取MSR作

为故障检测指标，下文分析MSR指标在PMU量测数据含噪声情况下的检测效果。

受通信问题、电磁干扰等因素影响，数据采集和传输过程中会存在随机量测噪声，实际PMU测量的数据矩阵可以表示为 $\mathbf{X}_s = \mathbf{X}_{N \times T_w} + \mathbf{Q}$ ，其中 $\mathbf{X}_{N \times T_w}$ 是量测数据矩阵的真值， $\mathbf{Q}$ 是噪声矩阵。

实际量测的PMU矩阵并不满足应用随机矩阵理论的条件，需要对 $\mathbf{X}_s$ 进行预处理。首先对 $\mathbf{X}_s$ 进行标准化处理，即

$$\mathbf{X}_{1,i} = \frac{(\mathbf{X}_i - \mu(\mathbf{X}_i))}{\sigma(\mathbf{X}_i)} \quad (7)$$

式中， $\mathbf{X}_1$ 为标准化处理后的矩阵； $\mu(\mathbf{X}_i)$ 为 $\mathbf{X}_s$ 第 i 行元素的均值； $\sigma(\mathbf{X}_i)$ 为 $\mathbf{X}_s$ 第 i 行元素的标准差。

标准化处理后的矩阵满足均值为0、标准差为1的分布，进一步对 $\mathbf{X}_1$ 求其协方差矩阵，即

$$\mathbf{R} = \mathbf{X}_1 \mathbf{X}_1^T \quad (8)$$

式中， $\mathbf{R}$ 为协方差矩阵； $\mathbf{X}_1^T$ 为 $\mathbf{X}_1$ 的转置。

对矩阵 $\mathbf{R}$ 的 N 个特征值按照降序进行排序 $\lambda_1 (= \lambda_{\max}) \geq \lambda_2 \geq \dots \geq \lambda_N (= \lambda_{\min})$ ，由文献[8]可知，当采样点 T_w 数值较大时，矩阵参数满足

$$\begin{cases} \lambda_{\max} = \frac{\sigma_v^2}{T_w} (\sqrt{T_w} + \sqrt{N})^2 \\ \lambda_{\min} = \frac{\sigma_v^2}{T_w} (\sqrt{T_w} - \sqrt{N})^2 \\ \prod_{i=2}^N \lambda_i \approx (\sigma_v^2)^{N-1} \end{cases} \quad (9)$$

式中， σ_v^2 为噪声矩阵 $\mathbf{Q}$ 的方差； $\lambda_{\max}$ 为矩阵 $\mathbf{R}$ 的最大特征值； $\lambda_{\min}$ 为矩阵 $\mathbf{R}$ 的最小特征值。

由式(9)可以看出，协方差矩阵 $\mathbf{R}$ 的最大特征值和最小特征值都与噪声有关，因此运用式(3)计算的MSR指标会受到噪声的影响，因此，在噪声环境下运用MSR指标进行故障检测的方法准确度会降低。

(2) 抗噪指标——MGME

定义 $\bar{\lambda}$ 为矩阵 $\mathbf{R}$ 特征值的几何平均值，计算式为

$$\bar{\lambda} = \left(\prod_{i=1}^N \lambda_i \right)^{\frac{1}{N}} \quad (10)$$

将式(9)代入式(10)中，得到 $\mathbf{R}$ 的几何平均特征值 $\bar{\lambda}$ 计算式为

$$\begin{aligned} \bar{\lambda} &= \left(\prod_{i=1}^N \lambda_i \right)^{\frac{1}{N}} = \left(\lambda_{\max} \prod_{i=2}^N \lambda_i \right)^{\frac{1}{N}} \\ &= (\lambda_{\max})^{\frac{1}{N}} \left(\sigma_v^2 \right)^{\frac{N-1}{N}} \end{aligned} \quad (11)$$

结合式(9)、式(11)，定义最大几何平均特征值(MGME)作为故障检测指标，该指标表征了矩阵最大特征值偏移平均值的程度。MGME公式推导的依据是随机矩阵理论的M-P率，当电力系统无故障发生时，时间窗矩阵计算的MGME指标低于阈值，若由于故障造成PMU量测数据波动，时间窗矩阵计算的MGME指标越过阈值。公式为

$$\text{MGME} = \frac{\lambda_{\max}}{\bar{\lambda}} = \frac{(\sqrt{T_w} + \sqrt{N})^{2-\frac{1}{N}}}{T_w^{\frac{N-1}{N}}} \quad (12)$$

由式(12)可以看出，最大特征值与特征值几何平均值的比值与噪声的方差 σ_v^2 无关，因此，当 N 和 T_w 无限大时，以MGME作为故障检测指标具有较强的抗噪声性能。

(3) 故障检测阈值的选取

在故障检测中，需要通过比较MGME指标与阈值的大小关系准确地检测出故障的发生。

由文献[9]可知，当 $0 < \lim_{T_w \rightarrow \infty} (N/T_w) < 1$ 时， $(\lambda_{\max} - \mu)/\nu$ 满足一阶Tracy-Widom分布，其中

$$\begin{cases} \mu = (\sqrt{T_w} - 1 + \sqrt{N})^2 \\ \nu = (\sqrt{T_w} - 1 + \sqrt{N}) \left(\frac{1}{\sqrt{T_w} - 1} + \frac{1}{\sqrt{N}} \right)^{\frac{1}{3}} \end{cases} \quad (13)$$

一阶Tracy-Widom函数常用的数据见表1。

表1 一阶 Tracy-Widom 函数常用数值

Tab. 1 Common numerical values of first-order Tracy Widom function

$F(t)$	0.01	0.05	0.10	0.30	0.50	0.70	0.99
t	-3.9	-3.18	-2.78	-1.91	-1.27	0.59	2.02

表1中的变量 t 即为 $(\lambda_{\max} - \mu)/\nu$ 。

假设故障检测阈值为 γ ，虚警概率为 P_{fa} ，计

算虚警概率为 P_{fa} 下的阈值 γ 。在虚警概率为 P_{fa} 时, 令 $MGME=\gamma$, 即 $\lambda_{\max}=\gamma\bar{\lambda}$, 由文献可知

$$F\left(\frac{\gamma\varphi-\mu}{v}\right)=1-P_{fa} \quad (14)$$

对式(14)进行整理, 可得到故障检测阈值 γ 的表达式为

$$\gamma=(v\cdot F^{-1}(1-P_{fa})+\mu)/\varphi \quad (15)$$

式中, $\varphi=(\sqrt{T_w}+\sqrt{N})^{2/N}\cdot T_w^{1-(1/N)}$; $F^{-1}(\cdot)$ 为一阶Tracy-Widom分布函数的逆。

当由式(12)计算的MGME指标大于阈值时, 即可判断电网故障的发生。式(15)表明, 阈值 γ 的选取同样不受噪声的影响, 其大小由 T_w 、 N 和 P_{fa} 确定, 与噪声的方差无关。

2.3 PMU量测矩阵的增维方法

回顾上一节MGME指标的推导过程, 在矩阵的维数接近无穷大时, 随机矩阵的 $\lambda_{\max}$ 、 $\lambda_{\min}$ 可由式(9)近似表示, 也即利用随机矩阵理论分析渐进收敛性要求矩阵的维数接近无穷大($N, T_w \rightarrow \infty$)。

但在实际工程中, PMU量测矩阵维数不可能达到无穷大, 一般为几十维。矩阵维数越小, 由式(9)求得特征值渐进结果误差越大。因此, 若直接运用PMU原始量测矩阵计算MGME指标进行故障检测, 在低信噪比环境下会存在检测失效的情况, 因此对原始数据矩阵进行增维处理, 以解决低信噪比环境下故障检测的漏判问题。

考虑将PMU量测矩阵的行或列依次复制相应的次数以达到增维的目的。对矩阵进行增维处理后, 弱化了噪声的存在对电网真实电气量数据的影响, 在故障检测指标的计算中更能挖掘出各节点电气量的真实信息, 使故障检测的结果更为准确。

设PMU量测矩阵的维数为 $N \times T_w$, 若将矩阵的每一行都增维为原来的 m 倍, 增维后的矩阵维数变为 $(m \times N) \times T_w$ 。同理, 对矩阵的行数据也可进行类似的增维处理。

举例说明本文所提的数据增维方法。维数为 $N \times T_w$ 的PMU量测矩阵为

$$\mathbf{X} = \begin{pmatrix} x_{11} & \cdots & x_{1T_w} \\ \vdots & & \vdots \\ x_{N1} & \cdots & x_{NT_w} \end{pmatrix} \quad (16)$$

将矩阵的行增维为原来的 m 倍, 列增维为原来的 n 倍, 处理后的矩阵维数为 $(m \times N) \times (n \times T_w)$, 增维后的矩阵 $\hat{\mathbf{X}}$ 为

$$\hat{\mathbf{X}} = \left\{ \begin{array}{cccccc} x_{11} & \cdots & x_{11} & \cdots & x_{1T_w} & \cdots & x_{1T_w} \\ \vdots & & \vdots & & \vdots & & \vdots \\ x_{11} & \cdots & x_{11} & \cdots & x_{1T_w} & \cdots & x_{1T_w} \\ \vdots & & \vdots & & \vdots & & \vdots \\ x_{N1} & \cdots & x_{N1} & \cdots & x_{NT_w} & \cdots & x_{NT_w} \\ \vdots & & \vdots & & \vdots & & \vdots \\ x_{N1} & \cdots & x_{N1} & \cdots & x_{NT_w} & \cdots & x_{NT_w} \end{array} \right\} \quad (17)$$

$\underbrace{\hspace{10em}}_n$

增维后的矩阵不破坏原本的数据结构, 在保存了原始数据时空分布特征的同时, 增加了矩阵的维数。运用式(9)计算的 $\lambda_{\max}$ 、 $\lambda_{\min}$ 渐进结果误差较原始矩阵小, 因此在MGME指标的计算过程中, 采用增维后的矩阵进行故障检测, 比采用原始数据矩阵进行检测的漏判率明显降低。

2.4 MGME指标故障检测方法

至此, 基于PMU量测数据的噪声环境下电力系统故障检测方法可总结为

- 1) PMU量测数据构建数据源矩阵 $\mathbf{X}$ 。
- 2) 确定初始时刻 t_i 和时间窗矩阵的维数, 并从 t_i 时刻开始构建时间窗矩阵。
- 3) 对数据矩阵进行增维处理, 得到增维后的矩阵 $\mathbf{X}'$ 。
- 4) 对增维后的矩阵进行标准化处理, 并求协方差矩阵 $\mathbf{R}$, 预处理后的矩阵 $\mathbf{R}$ 满足应用M-P律的条件。
- 5) 求预处理矩阵的特征值, 由式(12)计算 t_i 时刻的MGME, 并由式(15)计算阈值 γ 。
- 6) 判断MGME指标是否越过阈值 γ , 若没有越过阈值, 则返回步骤2)进行下一时刻的计算; 若越过阈值, 判定电网发生故障, 通知调度运行人员进行处理。

流程图如图1所示。




图1 故障检测流程图

Fig. 1 Flow chart of fault detection

3 算例分析

为了验证该方法在电力系统故障检测中的效果, 本文在IEEE 39标准测试系统中设置算例, 如图2所示。采用电力系统分析软件包(PSASP)作为仿真工具, 仿真时长为5 s, 采样步长为0.01 s。算例设置2 s时在母线8处发生单相接地短路故障, 故障持续时间为0.02 s。




图2 IEEE 39 标准测试系统

Fig. 2 IEEE 39 standard test system

IEEE 39标准测试系统共有39条母线, 选取仿真数据中所有母线的电压构建数据源矩阵, 仿真得到的量测矩阵维数为 39×500 。在量测矩阵中加入1%、3%和5%不同大小的高斯白噪声, 模拟PMU在数据采集传输过程中的干扰, 下面分别采用MSR指标和MGME指标进行故障检测, 比较两种方法在不同大小噪声下的故障检测效果。

(1) 基于MSR指标的故障检测

取时间窗矩阵的宽度为80进行实时分析, 即每个时间窗矩阵包含80个采样点。运用MSR指标进行故障检测, 由式(3)计算不同时刻的MSR数值, 得到不同噪声环境下的MSR曲线, 如图3所示。




图3 不同噪声幅值下的 MSR

Fig. 3 MSR under different noise amplitude

图3显示了MSR随采样时间的变化规律。可以看出, 当量测数据中包含1%噪声时, MSR指标可以检测故障的发生; 当量测噪声为3%和5%时, 由于MSR指标无法越过内环半径, MSR指标无法有效检测故障。

在大小为1%的高斯白噪声环境下, 噪声的存在不足以掩盖故障引起的数据波动, 当故障发生时系统的随机性被破坏, MSR越过内环半径以检测故障。在大小为3%和5%的高斯白噪声的环境中, 由于噪声的干扰掩盖了数据的变化, MSR方法用于故障检测失效。

(2) 基于增维矩阵的MGME故障检测

采用MGME指标计算在不同噪声大小下的故障检测效果, 在运用MGME指标进行故障检测前对量测矩阵进行增维处理, 将矩阵行列增维为原来的10倍, 增维后的矩阵维数为 $390 \times 5\,000$ 。同样, 选取时间窗矩阵的维数增维为原来的10

倍, 为 390×800 。由式(12)计算各个采样时刻的MGME, 阈值由式(15)得出, 基于MGME指标的故障检测效果如图4所示。




图4 不同噪声幅值下的MGME

Fig. 4 MGME under different noise amplitude

在不同的噪声环境下, 运用该方法计算的MGME指标均能在2 s时越过阈值, 且MGME指标曲线更为平滑, 检测结果与算例设置一致, 表明MGME指标具有较强的抗噪声性能。

综合对比不同噪声环境下图3、图4的故障检测曲线, 可以看出在较强噪声环境下, 采用MSR指标进行故障检测会出现漏检的现象, 而MGME指标在算例设置的不同噪声环境下均可以准确检测故障。因此, 相较于MSR指标的故障检测方法, 基于增维矩阵的MGME方法对噪声的耐受能力更强, 验证了本文所提方法的有效性。

4 结束语

本文提出了一种基于PMU量测数据的电力系统故障检测方法, 该方法理论严谨, 完全基于数据, 不依赖于具体模型, 故障检测指标MGME的推导经过严格的数学证明, 且对量测噪声和不良数据具有很强的鲁棒性。针对低信噪比下故障检测出现漏判的情况, 采用增维处理以满足指标推导过程中所需的渐进收敛条件, 弱化了噪声对真实数据造成的干扰。以MGME作为故障检测指标, 相较于原有的MSR指标, 解决了由于量测噪声的存在导致的漏判问题。设置仿真算例证明所提方法的有效性, 算例结果表明MGME指标的抗噪声能力明显优于MSR指标。当前的研究是针对噪声环境下电力系统故障检测, 接下来的研究中可以考虑不良数据的存在对电力系统故障检测的影响。

参考文献

- [1] 郭剑波. 我国电力科技现状与发展趋势[J]. 电网技术, 2006(18): 1-7.
- [2] 丁佳立, 王昕, 郑益慧, 等. 利用线路中点电流检测的改进单端行波故障测距方法[J]. 高电压技术, 2020, 46(5): 1814-1822.
- [3] 王鹏玮, 徐丙垠, 陈恒, 等. 基于波形比较的架空配电线路故障离线定位自动计算方法[J]. 电力自动化设备, 2021, 41(6): 73-97.
- [4] JIANG H, ZHANG J J, GAO W, et al. Fault detection, identification, and location in smart grid based on data-driven computational methods[J]. IEEE Transactions on Smart Grid, 2014, 5(6): 2947-2956.
- [5] XING H, QIAN A, QIU R C, et al. A big data architecture design for smart grids based on random matrix theory[J]. IEEE Transactions on Smart Grid, 2017, 8(2): 674-686.
- [6] 陈伟彪, 陈亦平, 姚伟, 等. 基于随机矩阵理论的故障时刻确定和故障区域定位方法[J]. 中国电机工程学报, 2018, 38(6): 1655-1664, 1902.
- [7] 张力, 张子仲, 顾建伟. 基于随机矩阵理论的电网状态分析与扰动定位方法[J]. 电力系统自动化, 2018, 42(12): 93-99, 126.
- [8] ZENG Y, LIANG Y C. Eigenvalue based spectrum sensing algorithms for cognitive radio[J]. IEEE Transactions on Communications, 2008, 57(6): 1784-1793.
- [9] PENNA F, GARELLO R, SPIRITO A M. Cooperative spectrum sensing based on the limiting eigenvalue ratio distribution in wishart matrices[J]. IEEE Communication Letters, 2009, 13(7): 507-509.

作者简介

黄赛(1999—), 男, 硕士, 研究方向为电力系统故障检测。

(收稿日期: 2022-12-26)