

多源量测数据下基于自适应EKF的动态状态估计方法

戚振彪¹, 鲍玉莹², 范申¹, 潘敏¹, 胡朋飞³, 吴红斌³

(1. 国网安徽省电力有限公司, 安徽 合肥 230022;
2. 国网安徽省电力有限公司经济技术研究院, 安徽 合肥 230022;
3. 合肥工业大学 电气与自动化工程学院, 安徽 合肥 230009)

摘要:在配电网多源量测体系中,多源量测设备的采样频率和时间戳不同步,以及系统中的不良数据,都将导致量测数据间存在偏差,从而影响状态估计的准确性。为此,提出了一种多源量测数据下基于自适应扩展卡尔曼滤波(EKF)的动态状态估计方法。首先,针对多源量测数据的非同步问题,提出了一种基于动态时间规整(DTW)的多源数据时间戳对齐策略,实现量测数据的同步。其次,针对系统中的不良数据,提出了一种集成不良数据自适应检测和滤除环节的EKF状态估计方法,降低了不良数据对状态估计的影响。最后,在IEEE 33节点系统中进行算例测试,并与未考虑多源量测数据融合和异常值检测的传统EKF方法进行比较。结果表明,所提方法提高了估计结果的鲁棒性和可靠性。

关键词:配电网;状态估计;多源数据融合;不良数据检测;卡尔曼滤波

中图分类号:TM73 文献标识码:A DOI:10.19457/j.1001-2095.dqcd26346

Adaptive EKF-based Dynamic State Estimation Method Under Multi-source Measurement Data

QI Zhenbiao¹, BAO Yuying², FAN Shen¹, PAN Min¹, HU Pengfei³, WU Hongbin³

(1.State Grid Anhui Electric Power Co.,Ltd.,Hefei 230022,Anhui,China;2.Economic and Technological Research Institute of State Grid Anhui Electric Power Co.,Ltd.,Hefei 230022,Anhui,China;3.School of Electrical Engineering and Automation,Hefei University of Technology,Hefei 230009,Anhui,China)

Abstract: In the multi-source measurement system of distribution network, the sampling frequency and time stamp of multi-source measurement equipment are not synchronized, as well as the bad data in the system, which will lead to the bias among the measurement data, thus affecting the accuracy of state estimation. To this end, a dynamic state estimation method based on adaptive extended Kalman filtering (EKF) under multi-source measurement data was proposed. Firstly, to address the non-synchronization problem of multi-source measurement data, a multi-source data timestamp alignment strategy based on dynamic time warping (DTW) was proposed to realize the synchronization of measurement data. Secondly, for the bad data in the system, an EKF state estimation method integrating the bad data adaptive detection and filtering link was proposed to overcome the effect of bad data on state estimation. Finally, an arithmetic test was performed in an IEEE 33 node system and compared with a conventional EKF method that did not consider the fusion of multi-source metrology data and outlier detection. The results show that the proposed method improves the robustness and reliability of the estimation results.

Key words: distribution network; state estimation; multi-source data fusion; bad data detection; Kalman filtering (KF)

配电网是电力系统连接发电侧和用户侧的关键环节,其运行效率直接关系到电力供应的质量和稳定性。在现代智能电网中,配电网的作用

不仅限于电能分配,还通过集成先进的测量和通信技术实现了对网络运行状态的实时监测和智能调控。随着可再生能源和分布式发电的快速

基金项目:国网安徽省电力有限公司科技项目(521209240004)

作者简介:戚振彪(1983—),男,硕士研究生,高级工程师,主要研究方向为配用电技术、分布式光伏,Email:448560511@qq.com

发展,配电网的负荷特性和网络结构变得更加复杂,对状态估计的精度和实时性提出了更高要求。因此,研究提升配电网状态估计性能的方法,对于支持智能电网的高效运行和优化管理具有重要的现实意义^[1]。配电系统状态估计(distribution system state estimation, DSSE)技术利用网络模型和可用的测量数据来推断系统状态。然而,由于中低压馈线的测量设备数量有限,配电系统往往面临不可观测的问题,这对DSSE的研发和应用造成了障碍^[2]。近年来,各种测量传感器的安装显著增加,特别是在配电系统的二次侧,智能电表被广泛部署,并通常以15 min为间隔进行数据采集,以用于用户计费。这些智能电表的聚合测量值为主馈线的负载组成提供了关键数据,进而增加了配电系统的数据冗余^[3]。此外,微型同步相量测量装置(distribution-level phasor measurement unit, D-PMU)、数据采集与监控(supervisory control and data acquisition, SCADA)系统和高级量测体系(advanced metering infrastructure, AMI)的部署也在不断扩大^[4]。除了这些传感器和仪表外,还可以定期获取来自分布式发电(distributed generation, DG)设备的监测数据,而配电管理系统(distribution management system, DMS)则能够访问负载和DG的每日预测数据^[5]。

随着智能电网技术的发展,配电系统中部署了越来越多的传感器和智能设备,这些设备生成大量实时数据。然而,这些数据中可能存在错误、缺失或不一致性,导致决策失误和系统性能下降^[6-7]。不良数据不仅影响状态估计和故障检测的准确性,还可能引发严重的安全隐患。关键挑战是协调多个时间序列与嘈杂、异构、不完整和不均匀采样的数据,并估计配电系统的状态。

在多源量测环境下的DSSE研究中,文献[8]集中于使用基于线性插值/外推的加权最小二乘(weighted least squares, WLS)方法来协调两个时间尺度测量值。但是,这种方法没有利用时间序列数据中任何潜在的时空关系。文献[9]解决了DSSE智能电表测量的异步性问题。文献[10]提出了一种卡尔曼滤波(Kalman filtering, KF)方法来处理不规则传感器采样的问题。文献[11-12]提出了一种用于协调异构测量值的多任务高斯过程(Gaussian process, GP)框架。该框架使用所有测量值的同时进行插补。也就是说,其提出的方法涉及批处理,不能用于在测量值到达时实时

进行插补。文献[13]提出了一种适用于配电网的三相解耦状态估计算法。该方法通过对量测量进行混合变换,避免了传统电流量测变换所导致的误差。文献[14]通过根据测量误差方差分配权重矩阵、根据状态变量变换测量值来解决多源量测数据的精度和形式差异,提高了估计精度和计算效率。在不良数据检测和抑制方面,文献[15]基于配电网的网孔对其支路进行编码,构建独立回路矩阵。通过自动判断连支的测量值,利用简化蚁群算法生成新树,从而实现对配电网中不良数据的高效检测与识别。文献[16]提出了一种新的网络搜索方法,该方法考虑了不同的测量精度和方向。通过电压一致性检测、PMU/SCADA一致性检测、KCL一致性检测以及KVL一致性检测,成功实现了不良数据的识别。

针对上述问题,本文考虑多源量测环境提出了一种计及多源量测数据的配电网动态状态估计方法。首先,提出了基于动态时间规整(dynamic time warping, DTW)的多源数据时间戳对齐和融合策略,解决多源量测数据时延问题。此外,为了克服异常值对于状态估计的影响,提出一种基于自适应EKF的DSSE算法。通过建立自适应检测阈值对测量数据进行自适应预筛选,以滤除测量中的不良数据;最后,根据筛选后的测量数据进行状态估计,降低不良数据对状态估计的影响。

1 多源量测数据融合

1.1 多源量测数据时间戳对齐

1.1.1 对齐基准

由于具备外置GPS接收装置和内置脉冲每秒同步时钟接收模块,D-PMU能够精确同步测量电压和电流相量,定时精度在50 μs以内。此外,D-PMU的采样周期为毫秒级,在采集过程中包含精确的时间尺度信息^[17]。因此,选择D-PMU测量作为基准,并根据D-PMU时间尺度对SCADA和AMI测量进行对齐。

1.1.2 SCADA量测对齐

SCADA量测数据仅具有到达主站时的时间戳,而缺乏数据采样时刻的时间戳。SCADA量测装置采集数据类型主要包括支路功率、电压、电流幅值,考虑到SCADA采集的支路电流幅值与D-PMU采集的电流幅值量测呈线性关系^[18],引入DTW对齐不同时间序列的SCADA与D-PMU测量

数据。DTW是一种用于对齐不同时间序列的算法,特别适用于处理不规则时间间隔和动态变化的数据^[19]。通过计算SCADA和D-PMU数据之间的欧氏距离矩阵。利用动态规划算法找到最优对齐路径,最小化时间序列之间的累积距离。根据最优路径对齐SCADA数据和D-PMU数据。由于多个SCADA测量设备之间的采集时间不同步,因此必须单独对每个SCADA测量设备采集的数据进行对齐。

步骤1:数据预处理。假设SCADA数据和D-PMU数据的采集率分别为 f_s 和 f_p 。在量测时间窗口 T_w 内,主站接收到SCADA和D-PMU的电气参数(电流幅值)序列分别为 $Z_s = [z_{s,1}, z_{s,2}, \dots, z_{s,n}]$ 和 $Z_p = [z_{p,1}, z_{p,2}, \dots, z_{p,m}]$,其中 $n = T_w f_s, m = T_w f_p$ 。

步骤2:构建SCADA数据和D-PMU数据之间的成本矩阵 D ,其表达式如下:

$$D(i,j) = \sqrt{z_{s,i} - z_{p,j}} \quad (1)$$

式中: $z_{s,i}, z_{p,j}$ 分别为量测时间窗口 T_w 内SCADA和D-PMU量测序列的第*i*和第*j*个量测数据。

步骤3:计算累积距离矩阵。基于成本矩阵,计算累积距离矩阵 G ,其计算公式如下:

$$\begin{aligned} G(i,j) &= D(i,j) + \min \{ G(i-1,j), \\ &\quad G(i,j-1), G(i-1,j-1) \} \end{aligned} \quad (2)$$

式中: $G(i,j)$ 为累积距离矩阵 G 中的元素。

步骤4:寻找最优路径。从累积距离矩阵 G 的右下角 $G(n,m)$ 开始,沿着最小累积成本的方向回溯到左上角 $G(1,1)$,找到最优路径 W 。具体回溯规则如下:

1)从 $G(n,m)$ 开始,记录当前位置 (i,j) ,并将其加入路径 W 。

2)对当前位置的3个邻居 $(i-1,j), (i,j-1), (i-1,j-1)$,检查其对应位置的值 $G(i-1,j), G(i,j-1), G(i-1,j-1)$ 。选择其中最小的一个值,并将其对应的位置作为下一步的回溯位置。

3)重复2),直到到达左上角 $(1,1)$ 。

步骤5:对齐和同步数据。根据最优路径 $W = [(i_1, j_1), (i_2, j_2), \dots, (i_k, j_k)]$ 对齐和同步SCADA和PMU数据,并将PMU的时间戳赋予对应的SCADA数据。具体同步规则如下:

1)对每个SCADA数据点 $z_{s,i}$,根据路径 W 找到与之对齐的PMU数据点 $z_{p,j}$ 。

2)对每个SCADA数据点 $z_{s,i}$,将路径 W 中与其对齐的PMU数据点的时间戳赋值给它。

利用DTW对齐不同时间序列的SCADA与D-PMU测量数据的流程如图1所示。

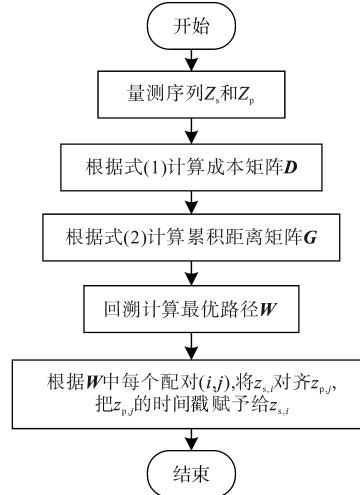


图1 SCADA和D-PMU量测数据对齐流程图

Fig.1 The flow chart of SCADA and D-PMU measurement data alignment

1.1.3 AMI测量的对齐

AMI的通信网络采用双向通信标准,主站负责将测量信息发送给用户,用户则上传所需信息(如用电数据)至主站。需要指出的是,AMI测量设备内置远程校准时钟,因此上传的数据通常附带时间戳^[4]。因此,主站在接收到AMI的测量数据后,可以直接利用这些时间戳,将数据与D-PMU的时间尺度进行对齐。

1.2 多源量测数据时延融合

尽管经过上述多源量测数据时间戳对齐处理后,测量数据已与采样时间尺度对齐,但不同于D-PMU的其他测量装置之间仍存在时间不同步的问题。因此,有必要对混合量测数据进行融合,以确保数据的一致性,进而提升状态估计的精度。

1)D-PMU测量由于其误差小、采样频率高且同步性能优异,能够作为其他测量的对齐基准,因此可以直接用于状态估计计算。

2)与PMU相比,SCADA的测量误差较大,因此直接采用最近时刻的状态估计量测值作为数据融合后的测量值。对于*t*时刻状态估计的SCADA量测,数据融合后的量测值 Z_s^{SE} 为

$$Z_s^{SE}(t) = Z_s^m(v) \quad (3)$$

式中:*v*为时间*t*之前的最后一个状态估计时刻; Z_s^m 为时刻*v*的量测值。

3)AMI测量的采样周期较长,当状态估计时刻与采样时刻相隔较远时,直接使用上一次采样

的测量值进行计算可能会导致较大的误差。为了确保测量精度,在状态估计时刻之前设置一个时间窗(T_w),作为伪测量的预测区间。时刻 t 的AMI测量融合值表示为

$$\mathbf{Z}_A^{\text{SE}}(t) = \begin{cases} \mathbf{Z}_A^M(t_{A,\text{pre}}) & t_{A,\text{pre}} \in [t - T_w, t] \\ \mathbf{Z}_{\text{Pre}}(t) & t_{A,\text{pre}} \in [t_{\text{pre}}, t - T_w] \end{cases} \quad (4)$$

式中: \mathbf{Z}_A^M 为AMI量测融合值; $t_{A,\text{pre}}$ 为AMI在 t 之前的最后一个采集时刻; $\mathbf{Z}_{\text{Pre}}(t)$ 为 t 时刻的伪量测预测值; t_{pre} 为上一次状态估计时刻。

2 考虑不良数据的自适应EKF

2.1 多源量测变换

状态估计是根据测量数据计算状态变量的过程,测量值与状态变量之间的关系可以表示为

$$\mathbf{z}^0 = \mathbf{h}(\mathbf{x}) + \boldsymbol{\varepsilon}^0 \quad (5)$$

式中: \mathbf{z}^0 为原始量测向量; \mathbf{x} 为状态向量; $\mathbf{h}(\cdot)$ 为量测向量 \mathbf{z}^0 和状态向量 \mathbf{x} 之间的非线性关系; $\boldsymbol{\varepsilon}^0$ 为原始量测误差向量。

本文选取节点电压相量的实部和虚部作为状态变量,表示为

$$\mathbf{x} = [\mathbf{e}, \mathbf{f}]^T \quad (6)$$

式中: \mathbf{e}, \mathbf{f} 分别为节点电压向量的实部向量和虚部向量。

原始量测向量 \mathbf{z}^0 可以表示为

$$\mathbf{z}^0 = [\mathbf{U}, \boldsymbol{\theta}, \mathbf{I}_b, \boldsymbol{\theta}_b, \mathbf{P}_b, \mathbf{Q}_b, \mathbf{P}_{\text{in}}, \mathbf{Q}_{\text{in}}]^T \quad (7)$$

式中: $\mathbf{U}, \boldsymbol{\theta}$ 分别为节点电压幅值和相角向量; $\mathbf{I}_b, \boldsymbol{\theta}_b$ 分别为支路电流幅值和相角向量; $\mathbf{P}_b, \mathbf{Q}_b$ 分别为支路有功功率和无功功率向量; $\mathbf{P}_{\text{in}}, \mathbf{Q}_{\text{in}}$ 分别为节点注入有功功率和无功功率向量。

多种类型的量测设备提供了原始量测向量 \mathbf{z}^0 ,但这些设备在数据形式、采样频率和量测延时方面存在显著差异。如果不对混合量测数据在计算前进行线性化处理,将会导致量测函数的复杂度增加,计算时间延长,最终影响状态估计的效率与准确性。因此,需要将多源量测数据统一转换为等效的支路电流(实部/虚部)、节点注入电流(实部/虚部)以及节点电压(实部/虚部),并根据测量不确定度传播理论来计算转换后的等效量测误差^[20]。

1) D-PMU测量的节点电压相量转换为等效的电压实部和虚部形式,计算公式为

$$\begin{cases} e_{m,i} = U_i \cos(\theta_i) \\ f_{m,i} = U_i \sin(\theta_i) \end{cases} \quad (8)$$

式中: U_i, θ_i 分别为节点*i*电压的幅值和相角量测; $e_{m,i}, f_{m,i}$ 分别为节点*i*电压的等效实部和虚部量测。

2) D-PMU测量的支路电流相量转换为等效的电流实部和虚部形式,计算公式为

$$\begin{cases} I_{b,ij}^{\text{re}} = I_{b,ij} \cos(\theta_{b,ij}) \\ I_{b,ij}^{\text{im}} = I_{b,ij} \sin(\theta_{b,ij}) \end{cases} \quad (9)$$

式中: $I_{b,ij}, \theta_{b,ij}$ 分别为支路 ij 电压的幅值量测和相角量测。

3) SCADA测量的支路潮流转换为等效支路电流的实部和虚部,计算公式为

$$\begin{cases} I_{b,ik}^{\text{re}} = \frac{P_{b,ik} e_{ic,i} + Q_{b,ik} f_{ic,i}}{e_{ic,i}^2 + f_{ic,i}^2} \\ I_{b,ik}^{\text{im}} = \frac{P_{b,ik} f_{ic,i} - Q_{b,ik} e_{ic,i}}{e_{ic,i}^2 + f_{ic,i}^2} \end{cases} \quad (10)$$

式中: $P_{b,ik}, Q_{b,ik}$ 分别为支路 ik 的有功功率和无功功率; $I_{b,ik}^{\text{re}}, I_{b,ik}^{\text{im}}$ 分别为流过支路 ik 的等效电流的实部和虚部; $e_{ic,i}, f_{ic,i}$ 分别为迭代计算过程中节点*i*处电压相量的实部和虚部。

4) 伪测量和虚拟测量的节点功率注入转换为等效节点注入电流的实部和虚部,计算公式为

$$\begin{cases} I_{\text{in},i}^{\text{re}} = \frac{P_{\text{in},i} e_{ic,i} + Q_{\text{in},i} f_{ic,i}}{e_{ic,i}^2 + f_{ic,i}^2} \\ I_{\text{in},i}^{\text{im}} = \frac{P_{\text{in},i} f_{ic,i} - Q_{\text{in},i} e_{ic,i}}{e_{ic,i}^2 + f_{ic,i}^2} \end{cases} \quad (11)$$

式中: $P_{\text{in},i}, Q_{\text{in},i}$ 分别为节点*i*的有功和无功注入功率; $I_{\text{in},i}^{\text{re}}, I_{\text{in},i}^{\text{im}}$ 分别为注入节点*i*的等效电流的实部和虚部。

经过上述量测变换后,量测数据由原始集 \mathbf{z}^0 转换为如下向量:

$$\mathbf{z} = [e_m, f_m, I_b^{\text{re}}, I_b^{\text{im}}, I_{\text{in}}^{\text{re}}, I_{\text{in}}^{\text{im}}]^T \quad (12)$$

式中: e_m, f_m 分别为电压相量测量的实部和虚部向量; $I_b^{\text{re}}, I_b^{\text{im}}$ 分别为等效支路电流相量测量的实部和虚部向量; $I_{\text{in}}^{\text{re}}, I_{\text{in}}^{\text{im}}$ 分别为等效注入电流相量测量的实部和虚部向量。

考虑到大部分配电网线路较短,其地面导纳可以忽略不计,根据基尔霍夫定律,配电网支路电流相量与节点电压相量的关系可表示为

$$\mathbf{I} = \dot{\mathbf{U}} \times \mathbf{Y} \quad (13)$$

式中: \mathbf{I} 为支路电流相量; $\dot{\mathbf{U}}$ 为节点电压相量; \mathbf{Y} 为支路导纳矩阵,其元素为 $Y_{ik} = G_{ik} + jB_{ik}$, G_{ik}, B_{ik} 分别为支路 ik 的电导和电纳。

将测量值从 \mathbf{z}^0 变换到 \mathbf{z} 后,测量向量与状态向量之间的关系为线性形式。这种线性使得量

测向量对状态向量求偏导的雅可比矩阵 \mathbf{H} 为一个常数矩阵, 其元素来自 \mathbf{z} 和 \mathbf{x} 之间的关联。根据基尔霍夫定律, \mathbf{z} 和 \mathbf{x} 元素之间的相关性可以通过以下测量函数简洁地表示:

$$\begin{cases} e_{m,i} = e_i \\ f_{m,i} = f_i \\ I_{h,ik}^{\text{re}} = G_{ik}(e_i - e_k) - B_{ik}(f_i - f_k) \\ I_{h,ik}^{\text{im}} = B_{ik}(e_i - e_k) + G_{ik}(f_i - f_k) \\ I_{\text{in},i}^{\text{re}} = \sum_{k \in \Omega_i} (G_{ik}e_k - B_{ik}f_k) \\ I_{\text{in},i}^{\text{im}} = \sum_{k \in \Omega_i} (B_{ik}e_k + G_{ik}f_k) \end{cases} \quad (14)$$

式中: e_i, f_i 分别为节点 i 处电压相量的实部和虚部; Ω_i 为节点 i 相邻的节点集合。

由此, 在所提量测变换方法下, 非线性量测方程可转化为如下线性量测方程:

$$\mathbf{z} = \mathbf{H}\mathbf{x} + \boldsymbol{\varepsilon} \quad (15)$$

式中: $\boldsymbol{\varepsilon}$ 为等效变换后的量测误差向量, 变换后的等效量测误差根据测量不确定度传播理论进行计算^[20]。

2.2 考虑不良数据检测的自适应 EKF

2.2.1 状态估计模型

配电网是一个高度多维非线性系统, 其交流潮流方程呈现非线性关系^[21]。状态估计的状态方程和测量方程分别为

$$\mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k) + \mathbf{w}_k \quad (16)$$

$$\mathbf{z}_k = \mathbf{h}(\mathbf{x}_k) + \mathbf{v}_k \quad (17)$$

式中: $\mathbf{x}_k, \mathbf{x}_{k+1}$ 分别为 k 时刻和 $k+1$ 时刻的状态向量; $\mathbf{f}(\cdot)$ 为状态向量 \mathbf{x}_k 到 \mathbf{x}_{k+1} 的状态转移方程; \mathbf{w}_k 为 k 时刻的过程误差向量; $\mathbf{z}_k, \mathbf{v}_k$ 分别为 k 时刻的测量向量和测量误差向量; $\mathbf{h}(\cdot)$ 为状态向量 \mathbf{x} 和测量向量 \mathbf{z} 之间的非线性关系。

假设 \mathbf{w}_k 和 \mathbf{v}_k 不相关并且服从零均值的高斯白噪声, 它们的误差协方差矩阵分别为 \mathbf{Q} 和 \mathbf{R} 。

卡尔曼滤波器是一种用于线性系统的最优估计方法。然而, 配电网是一个高度复杂的多维非线性系统, 因此选择使用 EKF 进行状态估计^[22]。EKF 的模型经过线性化处理, 适用于该系统的估计需求。EKF 的线性化模型为

$$\mathbf{x}_{k+1} = \mathbf{F}_k \mathbf{x}_k + \mathbf{G}_k + \mathbf{w}_k \quad (18)$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (19)$$

其中

$$\mathbf{F}_k = \partial \mathbf{f} / \partial \mathbf{x}|_{\mathbf{x}=\hat{\mathbf{x}}_k}$$

$$\mathbf{H}_k = \partial \mathbf{h} / \partial \mathbf{x}|_{\mathbf{x}=\hat{\mathbf{x}}_k}$$

式中: \mathbf{F}_k 为 k 时刻状态方程的雅可比矩阵; \mathbf{G}_k 为 k

时刻的输入矩阵; \mathbf{H}_k 为 k 时刻测量方程的雅可比矩阵。

2.2.2 不良数据的检测和校正

不良数据会导致量测序列出现突变, 使量测值与真实值之间出现显著偏差, 进而影响状态估计结果的准确性。为解决这一问题, 本文利用不良数据与正常数据在时间上相关性较弱的特性, 引入了一种自适应检测机制, 改进了 EKF 算法。通过对量测中的不良数据进行自适应在线识别与剔除, 提高了状态估计的精度。

配电网正常运行时, 相邻采样时刻间的测量值变化较小, k 时刻与 $k-1$ 时刻之间的测量值差值的绝对值 $|z_k - z_{k-1}|$ 仅包含噪声信号。如果测量集中存在不良数据, 则 $|z_k - z_{k-1}|$ 除了噪声信号外, 还会包含突变信号。据此提出了一种自适应阈值, 可以在滤除测量误差影响的同时检测出不良数据。 k 时刻的不良数据检测阈值 $\dot{\xi}_k$ 计算为

$$\dot{\xi}_k = \frac{\sigma_{e,k}^2 Z_{L_w,k}^{\text{avg}}}{\sigma_{L_w,k}^2} \quad (20)$$

式中: $\sigma_{e,k}^2$ 为等效测量噪声的方差; L_w 为滑动窗口的长度; $Z_{L_w,k}^{\text{avg}}$ 为滑动窗口内的平均测量值; $\sigma_{L_w,k}^2$ 为滑动窗口内测量差值绝对值序列的方差。

$Z_{L_w,k}^{\text{avg}}$ 和 $\sigma_{L_w,k}^2$ 的计算公式分别如下:

$$Z_{L_w,k}^{\text{avg}} = \frac{1}{L_w} \sum_{i=k+1-L_w}^k Z_{L_w,i} \quad (21)$$

$$\sigma_{L_w,k}^2 = \frac{1}{L_w - 1} \sum_{i=k+2-L_w}^k (\Delta Z_{L_w,i} - \Delta Z_{L_w}^{\text{avg}})^2 \quad (22)$$

其中

$$\begin{cases} \Delta Z_{L_w,i} = |Z_{L_w,i \in N} - Z_{L_w,i-1}| \\ \Delta Z_{L_w}^{\text{avg}} = \frac{1}{L_w - 1} \sum_{i=k+2-L_w}^k \Delta Z_{\text{avg},i} \end{cases} \quad (23)$$

式中: $Z_{L_w,i}$ 为 i 时刻的测量值; $\Delta Z_{L_w,i}$ 为滑动窗口内 $i-1$ 时刻与 i 时刻的测量数据之差的绝对值; $Z_{L_w}^{\text{avg}}$ 为 $\Delta Z_{L_w,i}$ 的平均值。

式(20)~式(23)表明, 当不存在不良数据时, 相邻时刻的测量差值绝对值中只含有噪声信号, $\sigma_{L_w}^2$ 值较小, $\dot{\xi}_k$ 值较大, 可以保证测量差值绝对值在 $\dot{\xi}_k$ 以内, 从而判定测量数据为良好数据。当存在不良数据时, 会产生测量差值绝对值, 包括突变和噪声信号, $\sigma_{L_w}^2$ 值增大, $\dot{\xi}_k$ 值减小, 导致测量差值绝对值超过 $\dot{\xi}_k$, 从而判定为不良数据。

滑动窗口 L_w 的大小是一个关键参数。如果滑动窗口太大, 测量值的平均值可能无法反映当

前的系统状态,尤其是在系统动态变化较快的情况下,可能导致估计的滞后性。如果窗口太小,平均值的计算会受到更多噪声或波动的影响,从而降低替换坏数据的准确性。

为此,本文在滑动窗口内测量值的平均计算中,提出加权平均法,对时间上更接近当前时刻的数据赋予更高的权重,而对时间较远的数据赋予较低权重。这样可以更好地反映当前系统状态,避免使用过时数据来替换坏数据。计算公式如下:

$$z_{k+1,j} = \frac{\sum_{i=k+2-L_w}^k w_i Z_{L_w,i,j}}{\sum_{i=k+2-L_w}^k w_i} \quad (24)$$

式中: w_i 为与时间相关的权重。

2.2.3 状态估计过程

KF是一种递归滤波方法,旨在对动态系统的状态进行估计。它通过结合系统模型与量测数据,递归更新状态估计,从而提升估计的精度。EKF是KF的扩展版本,适用于处理非线性系统。KF的核心思想在于结合系统模型提供的先验信息与量测数据来估计系统的当前状态。而EKF则通过对非线性系统模型和量测方程进行泰勒级数展开,并忽略二次项及更高阶项,来进行状态估计^[23]。EKF算法的基本流程为

1) 预测步:

$$\hat{x}_{k|k-1} = F_{k-1} \hat{x}_{k-1} \quad (25)$$

$$P_{k|k-1} = F_{k-1} P_{k-1} F_{k-1}^T + Q_{k-1} \quad (26)$$

2) 更新步:

$$\hat{x}_k = \hat{x}_{k|k-1} + K_k [z_k - h(\hat{x}_{k|k-1})] \quad (27)$$

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (28)$$

$$P_k = (I - K_k H_k) P_{k|k-1} \quad (29)$$

式中: $\hat{x}_{k-1}, \hat{x}_{k|k-1}$ 分别为 $k-1$ 时刻和 k 时刻的状态估计向量和预测状态向量; $P_{k|k-1}, P_k$ 分别为 k 时刻的先验估计误差的协方差矩阵和后验估计误差的协方差矩阵; K_k 为 k 时刻的卡尔曼增益。状态和估计误差协方差矩阵的初始值分别设置为 $\hat{x}_0 = \mathbf{0}$ 和 $P_0 = I$ 。

2.2.4 算法求解流程

自适应EKF的求解步骤总结如下:

1) 初始参数设置。设置初始参数 $F, Q, R, \hat{x}_0, P_0, L_w, k$ 。

2) 坏数据的自适应检测和校正。根据式(20)~式(23)计算 $k+1$ 时刻的坏数据自适应检测阈值 $\dot{\xi}_{k+1}$,并判断测量 $z_{k+1,j}$ 是否为坏数据,如果

不是,则不处理该测量数据;否则,根据式(24)替换坏数据。

3) 状态预测。根据预测步中的式(25)和式(26),计算 $k+1$ 时刻的状态预测值 $\hat{x}_{k+1|k}$ 和先验估计误差的协方差矩阵 $P_{k+1|k}$ 。

4) 状态更新。滤除不良数据后,根据式(27)~式(29)计算出更新后的状态估计向量 \hat{x}_{k+1} 和后验估计误差的协方差矩阵 P_{k+1} 。

自适应EKF的求解流程如图2所示。

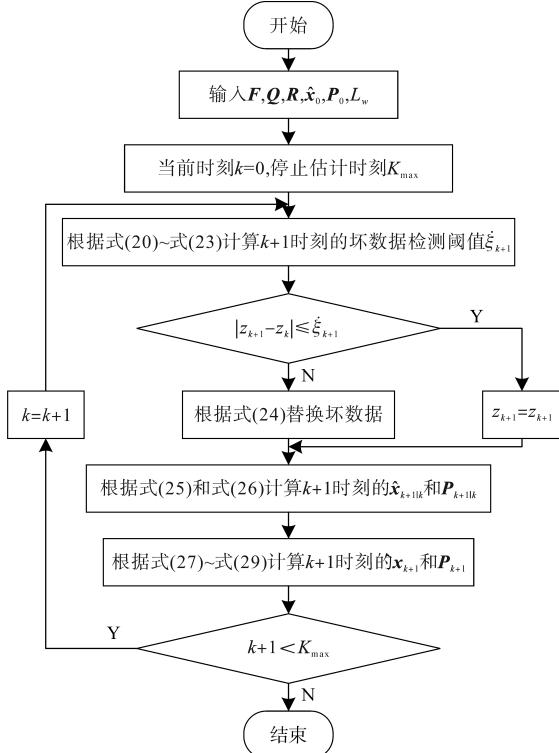


图2 基于自适应EKF的动态状态估计模型求解流程图

Fig.2 The solving flowchart of the dynamic state estimation model based on adaptive EKF

3 算例分析

3.1 测试系统

为了验证所提状态估计方法的有效性,基于IEEE 33节点配电系统进行了仿真分析。IEEE 33节点配电系统单线图如图3所示,3台DG分别安装在14,24,31节点上^[24]。通过在真实测量值中添加高斯噪声来获得实时量测值,其中SCADA数据中的支路功率服从均值为0,标准差为0.01的高斯分布,D-PMU数据服从均值为0,标准差为0.005的高斯分布,AMI数据中的节点注入功率服从均值为0,标准差为0.005的高斯分布,伪量测服从均值为0,标准差为0.3的高斯分布。设定SCADA量测类型为FTU,D-PMU和SCADA的布

局如表 1 所示, 每个节点均配置 AMI 量测。

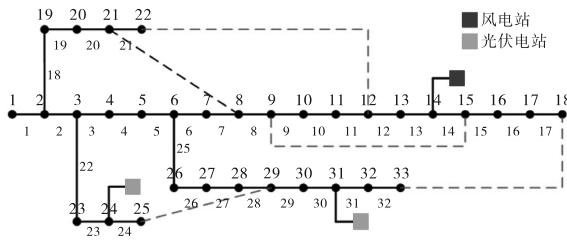


图 3 IEEE 33 节点配电网系统拓扑图

Fig.3 Topology of IEEE 33 node distribution system

表 1 IEEE 33 节点配电系统的量测布局

Tab.1 Measurement layouts of the IEEE 33 node system

量测类型	量测位置
D-PMU 电压量测	2, 3, 6, 12, 31
D-PMU 电流量测	(2), (22), (25), (12), (31)
SCADA	(7), (14), (15), (19), (21), (24)

测试系统的硬件环境为 Intel i5-12490f CPU, 内存为 16 GB, 开发环境为 Matlab R2022b。

3.2 有效性分析

状态估计周期设置为 5 min, 24 h 共执行状态估计 288 次。为验证所提融合多源数据的自适应 EKF 状态估计方法的准确性, 选取以下两种算法估计系统在 24 h 内 288 个时间断面的状态。

算法 1: 本文所提算法, 即考虑多源量测数据时延融合的自适应 EKF 方法, 设置初始状态变量初值为 $x_0 = \{[e_0, f_0]^T : e_0 = 1, f_0 = 0\}$;

算法 2: 不考虑多源数据时延融合的 EKF 估计方法, 初始状态变量与算法 1 相同^[25]。

IEEE 33 节点配电系统在第 200 时间断面通过上述算法得到的各节点电压幅值和相角误差如图 4 所示。

如图 4 所示, 在利用多源量测数据进行状态估计时, 算法 2 未考虑多源量测数据融合问题, 导致其电压幅值和电压相角的估计误差均大于考虑多源量测数据融合的算法 1。这是由于多源数据未融合导致在状态估计时刻难以获取相同时间截的量测数据, 从而导致状态估计精度降低。

为进一步定量分析不同算法的状态估计精度, 采用节点电压幅值和相角误差的均值 $e_{v,\text{mean}}/e_{\theta,\text{mean}}$ 和最大值 $e_{v,\text{max}}/e_{\theta,\text{max}}$ 作为量化指标, 计算公式如下:

$$\begin{cases} e_{v,\text{mean}} = \frac{1}{N_{\text{DSE}} M} \sum_{j=1}^{N_{\text{DSE}}} \sum_i^M e_{v,i,j} \\ e_{\theta,\text{mean}} = \frac{1}{N_{\text{DSE}} M} \sum_{j=1}^{N_{\text{DSE}}} \sum_i^M e_{\theta,i,j} \\ \text{st: } e_{v,\text{max}} = \max_{1 \leq i \leq M, 1 \leq j \leq N_{\text{DSE}}} e_{v,i,j} \\ e_{\theta,\text{max}} = \max_{1 \leq i \leq M, 1 \leq j \leq N_{\text{DSE}}} e_{\theta,i,j} \end{cases} \quad (30)$$

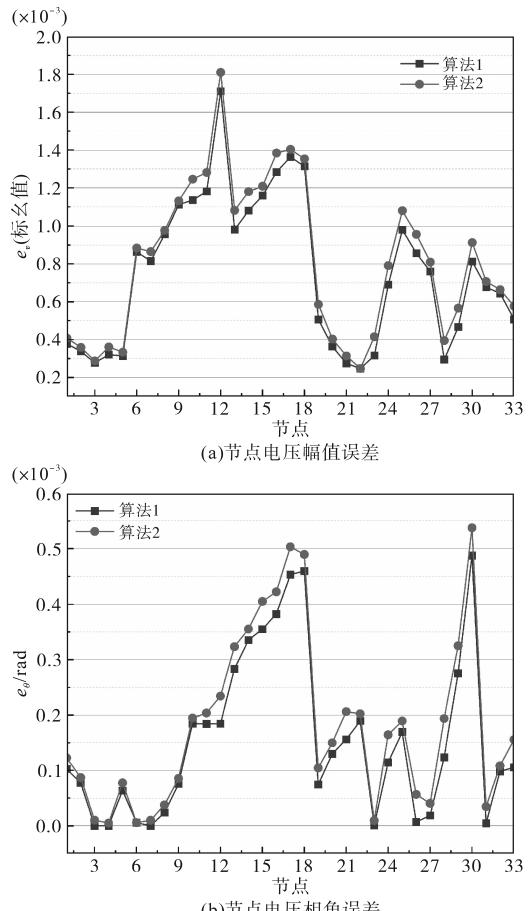


图 4 IEEE 33 配电系统中各算法的状态估计误差

Fig.4 State estimation error obtained by various algorithms in the IEEE 33 node system

表 2 列出了两种算法下的状态估计误差结果。相比算法 2 的估计误差, 算法 1 的估计误差整体偏小, 电压幅值误差均值下降了 7.64%、电压相角误差均值下降了 15.75%, 电压幅值误差最大值下降了 8.61%、电压相角误差最大值下降了 6.01%。由此可见, 在具有多源量测的配电网中, 考虑量测时延融合可在一定程度上提高状态估计精度。

表 2 IEEE 33 配电网中各算法的状态估计误差对比

Tab.2 State estimation error comparison of various algorithms in the IEEE 33 node system

状态估 计算法	电压幅值误差/1e-3 (标幺值)				电压相角误差/1e-3 rad			
	$e_{v,\text{mean}}$	$e_{v,\text{max}}$	$e_{\theta,\text{mean}}$	$e_{\theta,\text{max}}$				
算法 1	0.757 1	1.717 0	0.155 7	0.788 4				
算法 2	0.819 7	1.878 7	0.184 8	0.838 8				

3.3 不良数据的鲁棒性分析

为了验证所提算法在测量集中存在不良数据时的鲁棒性, 本文以 IEEE 33 节点配电系统为例, 在 150~155 时间断面向节点 6 的 D-PMU 测量数据注入误差为 $\pm 5\%$ 的随机不良数据。图 5 展示

了节点6在120~180时间断面的测量幅值、测量差值绝对值以及自适应阈值的变化趋势。其中,图5a展示了节点6在量测正常时的电压幅值变化,图5b展示了节点6在150~155时间断面存在误差为±5%随机不良数据时的电压幅值变化,图

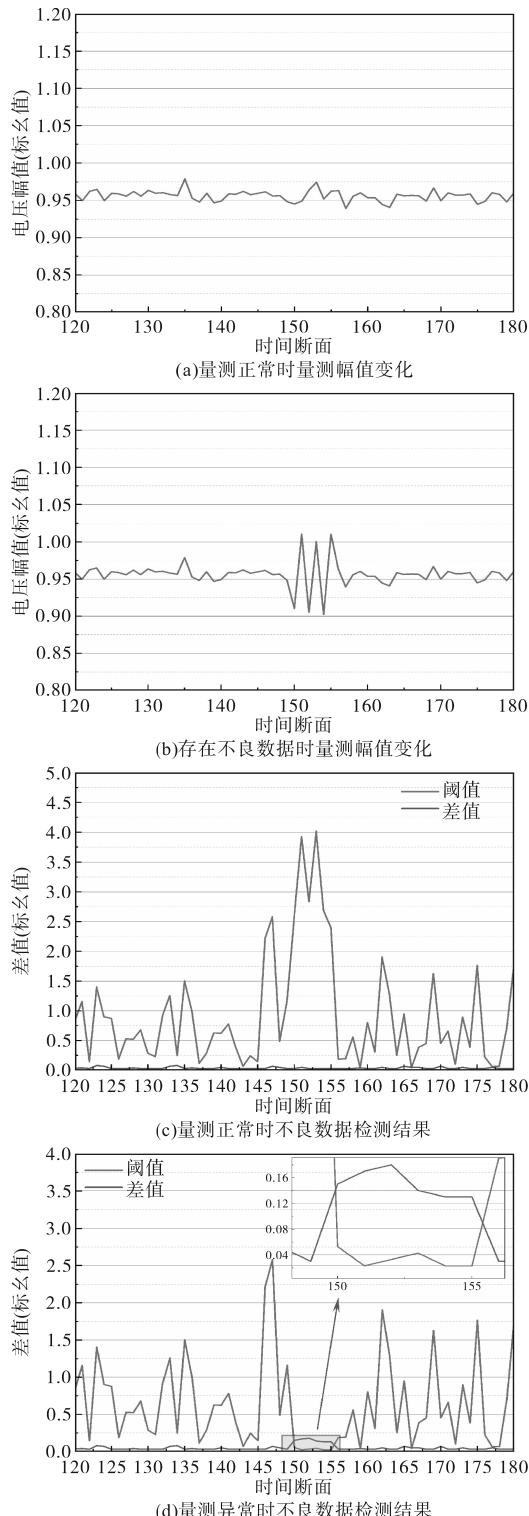


Fig.5 IEEE 33 节点系统中节点6的不良数据检测结果

5c展示了节点6在量测正常时的不良数据检测结果,图5d展示了节点6在150~155时间断面存在不良数据时的检测结果。

由图5c可见,当量测值处于正常状态时,自适应检测阈值始终高于测量差值绝对值,表明该时段内无不良数据。而在150~155时间断面,量测值含有不良数据时,自适应检测阈值和测量差值绝对值如图5d所示。此时段自适应检测阈值显著降低,测量差值绝对值超过了阈值,进而判定该时段存在不良数据。这说明所提出的基于自适应EKF的状态估计方法能够有效检测出不良测量数据。

为了进一步突出所提自适应EKF算法在不良量测数据中的鲁棒性,本文选择传统EKF算法作为对照,在不良数据误差为±5%且含量分别为0,5%和10%的量测条件下,对比分析其状态估计精度。表3展示了IEEE 33节点配电系统中在不同比例不良量测数据条件下,两种算法的状态估计误差。

表3 存在不良量测时 IEEE 33 节点系统中各算法的状态估计误差对比

Tab.3 State estimation errors comparison of various algorithms in the IEEE 33 node system with bad measurements

不良 数据 含量	算法	电压幅值误差/		电压相角误差/	
		1e-3 (标幺值)		1e-3 rad	
		$e_{v,\text{mean}}$	$e_{v,\text{max}}$	$e_{\theta,\text{mean}}$	$e_{\theta,\text{max}}$
0	自适应 EKF	0.757 1	1.717 0	0.155 7	0.788 4
	EKF	0.758 4	1.732 5	0.157 4	0.786 1
5%	自适应 EKF	0.793 4	1.808 8	0.167 5	0.847 7
	EKF	0.987 5	2.209 6	0.211 4	1.047 9
10%	自适应 EKF	0.997 0	2.535 8	0.225 6	1.108 4
	EKF	1.576 4	3.945 1	0.416 0	2.027 2

如表3所示,当量测数据正常时,自适应EKF与传统EKF的估计精度相近。当含有5%不良数据时,自适应EKF和EKF算法的 $e_{v,\text{mean}}$ 值分别比不含不良数据时上升了4.79%和30.21%;而在含有10%不良数据的情况下, $e_{v,\text{mean}}$ 值则分别提高了31.68%和107.86%。这表明不良量测数据比例的增加会导致两种算法的状态估计误差增大,但自适应EKF的误差增加幅度相对较小。

此外,与传统EKF相比,自适应EKF在不良数据含量为5%和10%时的 $e_{\theta,\text{mean}}$ 值分别下降了26.73%和119.40%。这表明,在存在不良量测数据的情况下,所提出的自适应EKF算法能够利用其他良好量测值来降低估计误差,从而有效缓解

不良数据对状态估计精度的影响,提升状态估计的鲁棒性。

4 结论

为了克服多源量测数据存在非同步和不良数据导致状态估计性能下降的问题,本文提出了一种多源量测数据融合和检测并剔除不良数据的动态状态估计方法。首先,设计了一种协调多时间尺度量测数据的融合方法。基于DTW的时间截对齐方法将PMU数据的时间截赋予SCADA数据,实现多源量测数据时标对齐。此外,通过引入自适应检测机制,利用不良数据与正常数据在时间上的弱相关性,对EKF算法进行了改进。该改进在更新步骤前实现不良数据的在线检测与滤除,从而提升了估计精度。基于IEEE 33节点系统进行算例分析,验证了相较于EKF算法,基于量测数据融合的自适应EKF的状态估计方法得到的电压幅值和电压相角的估计误差更小,不良数据的鲁棒性分析验证了所提方法在不同不良数据比例下的状态估计可靠性。

参考文献

- [1] DEHGHANPOUR K, WANG Z, WANG J, et al. A survey on state estimation techniques and challenges in smart distribution systems[J]. IEEE Transactions on Smart Grid, 2019, 10(2):2312–2322.
- [2] 魏新迟,秦龙宇,方陈,等.配电网同步相量测量技术与应用综述[J].电力建设,2023,44(5):13–22.
WEI Xinchi, QIN Longyu, FANG Chen, et al. Review of the synchronous measurement technology and its application in distribution networks[J]. Electric Power Construction, 2023, 44(5):13–22.
- [3] 周索文渊.基于智能电表和PMU混合量测的低压配电网状态估计方法研究[J].电工技术,2023(1):42–46.
ZHOU Suowenyan. Research on state estimation method of low voltage distribution network based on hybrid measurement of smart meter and PMU[J]. Electric Engineering, 2023 (1): 42–46.
- [4] 金志刚,刘凯,武晓栋.智能电网AMI领域IDS研究综述[J].信息网络安全,2023,23(1):1–8.
JIN Zhigang, LIU Kai, WU Xiaodong. A review of IDS research in smart grid AMI field[J]. Netinfo Security, 2023, 23(1):1–8.
- [5] WU D, LIN W. Efficient residential electric load forecasting via transfer learning and graph neural networks[J]. IEEE Transactions on Smart Grid, 2023, 14(3):2423–2431.
- [6] 黄佳胤,张弛,丁晓兵,等.对变电站不良数据进行检测的研究[J].计算机与数字工程,2020,48(7):1810–1817.
- [7] HUANG Jiayin, ZHANG Chi, DING Xiaobing, et al. Research on detection technology of bad quality data in digital substation [J]. Computer and Digital Engineering, 2020, 48 (7) : 1810–1817.
- [8] 黄崇鑫,洪明磊,伏帅,等.考虑虚假数据注入攻击的有源配电网分布式状态估计[J].电力工程技术,2022,41(3):22–31.
HUANG Chongxin, HONG Minglei, FU Shuai, et al. Distributed state estimation of active distribution network considering false data injection attack[J]. Electric Power Engineering Technology, 2022, 41(3):22–31.
- [9] GÓMEZ-EXPÓSITO A, GÓMEZ-QUILES C, DŽAFIĆ I. State estimation in two time scales for smart distribution systems[J]. IEEE Transactions on Smart Grid, 2015, 6(1):421–430.
- [10] ALIMARDANI A, THERRIEN F, ATANACKOVIC D, et al. Distribution system state estimation based on nonsynchronized smart meters[J]. IEEE Transactions on Smart Grid, 2015, 6(6): 2919–2928.
- [11] STANKOVIĆ A M, ŠVENDA V, SARIĆ A T, et al. Hybrid power system state estimation with irregular sampling[C]// IEEE Power and Energy Society General Meeting, Chicago, USA:2017, 1–5.
- [12] DAHALE S, NATARAJAN B. Multi time-scale imputation aided state estimation in distribution system[C]//IEEE Power and Energy Society General Meeting, Washington, USA:2021, 1–5.
- [13] 刘琳,和敬涵.广义特勒根求解的配电网混合变换三相解耦状态估计算法[J].中国电机工程学报,2016,36(14):3734–3742.
LIU Lin, HE Jinghan. A new algorithm for distribution network state estimation considering three-phase decoupling based on tellegen's theorem solving[J]. Proceedings of the CSU-EPSA, 2016,36(14):3734–3742.
- [14] WANG H, ZHANG W, LIU Y. A robust measurement placement method for active distribution system state estimation considering network reconfiguration[J]. IEEE Transactions on Smart Grid, 2018, 9(3):2108–2117.
- [15] 钟建伟,刘佳芳,倪俊,等.改进新息图法在不良数据检测与辨识中的应用[J].电力系统及其自动化学报,2018,30(9): 83–88.
ZHONG Jianwei, LIU Jiafang, NI Jun, et al. Application of improved innovation graph method in detection and identification of bad data[J]. Proceedings of the CSU-EPSA, 2018, 30 (9) : 83–88.
- [16] 杜亮.基于最优路径的电网状态计算与不良数据辨识[J].电工电气,2019 (11):25–29.
DU Liang. Power grid state calculation and outlier detection based on optimal path-finding technique[J]. Electrotechnics Electric, 2019 (11):25–29.

(下转第88页)

- LI Xueyan, GUAN Yuhang, LUO Mingtao, et al. Modal parameter identification by covariance stochastic subspace method based on Welch's method[J]. Chinese Journal of Theoretical and Applied Mechanics, 2022, 54(10): 2850–2860.
- [14] 杨婧,程乃平,倪淑燕.Welch算法在弱信号检测中的性能分析[J].计算机仿真,2020,37(5):235–240.
- YANG Jing, CHENG Naiping, NI Shuyan. Performance analysis of Welch algorithm in weak signal detection[J]. Computer Simulation, 2020, 37(5): 235–240.
- [15] 尹康达,李小军,张晓刚,等.台基噪声功率谱估计中的Welch参数选择[J].地震地磁观测与研究,2023,44(4):63–67.
- YIN Kangda, LI Xiaojun, ZHANG Xiaogang, et al. Selection of Welch parameters in seismic station noise power spectrum estimation[J]. Seismological and Geomagnetic Observation and Research, 2023, 44(4): 63–67.
- [16] 李金杰,邹国锋,魏良玉,等.基于功率谱密度与随机配置网络的低压串联电弧故障检测[J].科学技术与工程,2023,23(34):587–595.
- LI Jinjie, ZOU Guofeng, WEI Liangyu, et al. Low-voltage series arc fault detection based on power spectral density and stochastic configuration network[J]. Science Technology and Engineering, 2023, 23(34): 587–595.
- [17] 张慧彬.基于谐波合成法模拟的脉动风速功率谱密度和相关性分析[J].运输经理世界,2023(2):103–105.
- ZHANG Huibin. Power spectral density and correlation analy-
- sis of pulsating wind speed based on simulation by harmonic synthesis method[J]. Transport Business China, 2023(2): 103–105.
- [18] 栾某德,甘德强,李振垚,等.基于模型响应功率谱密度预测的强迫振荡扰动源设备定位法[J].电力系统自动化,2022,46(22):111–119.
- LUAN Moude, GAN Deqiang, LI Zhenyao, et al. Location method for forced oscillation source device based on power spectral density prediction of model responses[J]. Automation of Electric Power Systems, 2022, 46(22): 111–119.
- [19] 孟庆生,李杨,王文静,等.影响随机噪声CCA法勘探的关键因素试验研究[J].中国海洋大学学报:自然科学版,2023,53(6):134–141.
- MENG Qingsheng, LI Yang, WANG Wenjing, et al. Experimental study on key factors influencing ambient noise CCA prospecting method[J]. Periodical of Ocean University of China, 2023, 53(6): 134–141.
- [20] 孙明阳,和阳,邱先群,等.随机频率三角波注入永磁同步电机无位置传感器降噪控制[J].电工技术学报,2023,38(6):1460–1471.
- SUN Mingyang, HE Yang, QIU Xianqun, et al. Random-frequency triangular wave injection based sensorless control of PMSM drives for audible noise reduction[J]. Transactions of China Electrotechnical Society, 2023, 38(6): 1460–1471.

收稿日期:2025-03-17

修改稿日期:2025-04-11

(上接第56页)

- [17] 臧佳,田凯,曹冰.一种基于FPGA的PMU测量单元的设计[J].电工技术,2023 (21):111–112.
- ZANG Jia, TIAN Kai, CAO Bing. Design of FPGA-based phasor measurement unit[J]. Electric Engineering, 2023 (21) : 111–112.
- [18] MAO M, XU J, WU Z, et al. A multiarea state estimation for distribution networks under mixed measurement environment[J]. IEEE Transactions on Industrial Informatics, 2022, 18 (6) : 3620–3629.
- [19] 姚霆宇,余学祥,韩雨辰,等.基于改进Fast-DTW的多维地磁序列匹配算法研究[J].现代信息科技,2024,8(8):89–92, 96.
- YAO Tingyu, YU Xuexiang, HAN Yuchen, et al. Research on multidimensional geomagnetic sequence matching algorithm based on improved fast-DTW[J]. Modern Information Technology, 2024, 8(8): 89–92, 96.
- [20] FARRANCE I, FRENKEL R. Uncertainty of measurement: a review of the rules for calculating uncertainty components through functional relationships[J]. The Clinical Biochemist Reviews, 2012, 33(2):49–75.
- [21] PAU M, PEGORARO P A. WLS-based state estimation for unobservable distribution grids through allocation factors evaluation[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73:1–13.
- [22] CHUGHTAI A H, AKRAM U, TAHIR M, et al. Dynamic state estimation in the presence of sensor outliers using MAP-based EKF[J]. IEEE Sensors Letters, 2020, 4(4):1–4.
- [23] HU P, GAO W, LI Y, et al. Anomaly detection and state correction in smart grid using EKF and data compensation techniques [J]. IEEE Sensors Journal, 2024, 24(8):12995–13009.
- [24] BARAN M E, WU F F. Network reconfiguration in distribution systems for loss reduction and load balancing[J]. IEEE Transactions on Power Delivery, 1989, 4(2):1401–1407.
- [25] 王竟才,李琰,徐天奇.基于扩展卡尔曼滤波的智能电网虚假数据检测[J].智慧电力,2022,50(3):50–56.
- WANG Jingcai, LI Yan, XU Tianqi. Detection of false data in smart grid based on extended Kalman filter[J]. Smart Power, 2022, 50(3): 50–56.

收稿日期:2024-12-03

修改稿日期:2025-02-12