第49卷 第18期 2025年9月25日
DOI：10.7500/AEPS20250110002
电力系统自动化
Automation of Electric Power Systems
Vol. 49 No. 18 Sept. 25，2025

同步测量数据驱动的配电网扰动源分类方法

陈徵粼，刘 灏，毕天姝
（新能源电力系统国家重点实验室（华北电力大学），北京市 102206）

摘要：为应对大量分布式电源接入带来的挑战，同步测量技术被引入配电网，为系统的安全稳定性分析提供了更多维度的数据。为进一步增强对配电网的态势感知，文中提出了一种同步测量数据驱动的配电网扰动源分类方法。首先，提出了一种基于Granger因果分析理论的扰动源快速辨识方法，分辨扰动源位于主网侧还是配网侧。其后，提出了一种基于核支持向量机的算法误判扰动辨识方法，识别由瞬时估计算法误差引起的误判扰动，从而完成对实时配电网扰动数据的快速分类与提取。最后，基于IEEE 123节点系统仿真数据与现场同步测量数据验证了所提方法的有效性。

关键词：配电网；分布式电源；态势感知；同步测量；核支持向量机；扰动

0 引言

近年来，分布式电源（distributed generator，DG）给新型负荷的大规模接入对传统配电网的设计和运行带来了新的挑战。分布式电源的间歇性、波动性以及双向潮流特性使配电网遭遇扰动的频次和严重程度增加，且机理更为复杂。这些扰动不仅影响配电网的电能质量和设备健康，还可能对系统的安全可靠运行构成威胁[1]，亟须对配电网的扰动进行感知和辨识[2-3]。

以往，受限于测量设备的覆盖范围与性能，配网侧扰动往往难以捕捉[4-5]。但随着配电网同步测量技术的发展，对配电网进行高实时性、高精度的监测正在逐步成为可能[6-7]，研究同步测量数据驱动的配电网扰动辨识方法具有重要价值。借助如配电网同步相量测量单元[8]等设备采集的实时数据，快速提取出对电网安全运行和电能质量产生显著影响的配电网扰动，可支撑配电网的态势感知[9-10]、设备健康诊断[11-12]、状态估计[13]、扰动识别[14]及定位[15]等应用，为数据驱动研究建立数据库基础[16]。同时，为配电管理系统提供更多实时扰动信息，有助于基于响应的扰动抑制和补偿调节[17]，提高配电网的动态响应能力和自愈能力，加强分级分层控制。

本文研究聚焦于同步测量数据驱动的配电网扰动源分类问题，是配电网扰动辨识研究的重要组成部分。具体而言，配电网中的扰动不仅可能源于主网侧事件的传递，还可能源自配电网内分布式电源出力波动、联络开关操作和故障等事件。此外，同步测量单元上传的实时数据通常由瞬时估计算法计算获得，存在的估算误差会导致扰动误判。因此，实时检测的扰动数据中不可避免地混杂有主网侧扰动、配网侧扰动以及由算法误差引发的误判扰动。因此，亟须研究一种能够准确、快速分类扰动源并排除扰动误判的方法，为后续的扰动识别、抑制等应用研究奠定基础。

目前，配电网扰动源分类问题面临诸多挑战。由于配电网扰动存在多时间尺度耦合特性，物理建模与机理分析困难，须依赖数据驱动方法进行快速辨识。文献[18]通过转移熵和Copula熵分析宽频振荡事件源；文献[19]提出了基于逆信息熵的因果推理方法，揭示了电力系统运行数据中的因果关系；而文献[20]将因果分析应用于同步相量测量数据，验证了时空特性分析的有效性。但目前未见基于同步测量数据驱动的配电网扰动源辨识方法研究。

同步测量数据中的实时频率数据通过瞬时频率（instantaneous frequency，IF）估计算法获得，而IF估计误差会影响扰动检测和识别。例如，文献[21]应用Gabor-Wigner变换揭示了不同扰动对估计IF的显著影响；文献[22]中用频率质量指数表征IF估计对电力系统频率的影响。可见，IF估计误差的普遍存在为扰动的准确提取带来了额外的干扰因素。

因此，本文针对配电网扰动数据中扰动来源及其真实性辨别困难的问题，提出了一种结合自回归建模与Granger因果分析的扰动源辨识方法，实现了配电网内、外部扰动的快速区分；同时，本文分析

收稿日期：2025-01-10；修回日期：2025-04-16。
上网日期：2025-08-08。
国家自然科学基金资助项目（52377098）。

了IF估计算法误差所导致扰动的特征，提出了基于粒子群优化核支持向量机的扰动误判识别方法，有效排除了扰动误判。仿真和现场实验结果表明，该方法能够快速、准确地区分主网侧扰动、配网侧扰动以及IF估计算法误判扰动。

1　基于Granger因果分析的扰动源分类

1.1　基于BK滤波的数据预处理

BK滤波器是一种近似带通滤波模型，原用于经济学领域的经济周期分析提取[23]。为去除同步测量扰动数据中的趋势性、周期性特征，以利于进行基于自回归分析的扰动建模，本文提出一种基于BK滤波器的扰动数据预处理方法。

该方法通过构造滤波器，采用原始扰动时间序列向量$\boldsymbol{y}$产生新的扰动时间序列$\boldsymbol{y}^*$。具体地，设y_t为t时刻的原始扰动测量值，则滤波后的数据y_t^*表示为：

$$y_t^*=\sum_{k=-K}^{K}a_k y_{t-k} \tag{1}$$

$$\begin{cases}a_k=\dfrac{1}{\pi k}(\sin(\omega_2 k)-\sin(\omega_1 k))+\theta\\ a_0=\dfrac{\omega_2-\omega_1}{\pi}+\theta\end{cases} \tag{2}$$

式中：a_k为滞后系数，$a_k=a_{-k}$，$\sum_{k=-K}^{K}a_k=0$，其中，$k=0,\pm1,\pm2,\cdots,\pm K$；$\theta$为使权重总和为零的归一化常数；$\omega_1$、$\omega_2$分别为低截止频率和高截止频率。

图1所示为BK滤波预处理前后的扰动数据。

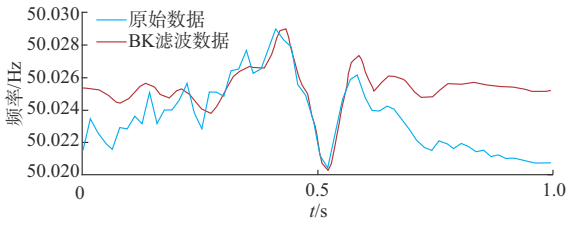

图1　BK滤波预处理前后的扰动数据
Fig. 1　Disturbance data before and after BK filtering preprocessing

从图1可以看出，所提方法通过采用对称移动平均和平滑估计的方式，消除了扰动序列中的周期分量和趋势分量。这能够有效排除电力系统中由于控制策略引发的量测数据常规趋势性和周期性变化，使得扰动特性清晰化，从而提高后续对扰动数据进行自回归分析的准确性。

1.2　自回归建模与残差计算

为进行扰动数据的因果分析，本节首先基于差分整合移动平均自回归（autoregressive integrated moving average，ARIMA）模型对滤波后的同步测量数据y^*进行自回归建模。

具体地，将序号为i的同步测量单元数据用ARIMA(p,d,q)模型表示，其中，p为自回归阶数，q为移动平均阶数，d为使之成为平稳序列所需做差分的阶数。首先，对序列向量$\boldsymbol{y}^*$进行d阶差分使时间序列平稳化，如下式所示：

$$\begin{cases}y_t^*\approx\nabla^d y_t^*\\ \nabla y_t^*=y_t^{*\prime}=y_t^*-y_{t-1}^*\end{cases} \tag{3}$$

而后，将式(3)的时间序列y_t^*的回归公式表示为：

$$y_t^*=\mu+\varepsilon_t+\sum_{i=1}^{q}\theta_i\varepsilon_t+\sum_{i=1}^{p}r_i y_{t-1}^* \tag{4}$$

式中：θ_i为滑动平均系数；r_i为自回归系数；ε_t为回归误差；μ为零均值高斯白噪声，回归过程不再添加噪声信号时μ取0。

进一步，定义式(4)中的回归误差ε_t之和为该同步测量单元i的自残差$r_i=\sum_{t=1}^{N}\varepsilon_t, t=1,2,\cdots,N$，作为对扰动数据回归效果进行评估的参数。

上述自回归模型的建立以及自残差的定义将为后续进行基于因果相关性分析的溯源方法提供基础。

1.3　基于Granger的因果相关性强度计算

Granger因果分析方法是一种基于预测对时间序列之间因果关系进行量化检验的方法。假设两台同步测量单元记录的时间序列向量为$\boldsymbol{x}$和$\boldsymbol{y}$，有以下两个回归公式：

$$y_t\approx\sum_{j'=1}^{p}b_{j'}y_{t-j'} \tag{5}$$

$$y_t\approx\sum_{j'=1}^{p}b_{j'}y_{t-j'}+\sum_{j'=1}^{p}d_{j'}x_{t-j'} \tag{6}$$

式中：x_t为t时刻$\boldsymbol{x}$对应的测量值；$b_{j'}$和$d_{j'}$分别为j'时刻$\boldsymbol{x}$和$\boldsymbol{y}$的回归系数。

若式(6)比式(5)预测准确，则时间序列$\boldsymbol{x}$对$\boldsymbol{y}$具有Granger因果相关性。换言之，若利用$\boldsymbol{y}$和$\boldsymbol{x}$的过去值预测$\boldsymbol{y}$当前的值，比仅用$\boldsymbol{y}$的过去值预测的效果更好，则$\boldsymbol{x}$对$\boldsymbol{y}$具有Granger因果相关性。

相比于传统相关性计算方法（如皮尔逊相关系数），该分析方法能够进一步揭示相关关系的方向性特征。在此理论基础上，本节提出了一种量化分析不同测量点位的同步测量数据之间的因果相关性强度的方法。

基于式(6)的Granger因果关系理论，结合ARIMA模型式(4)，将序号为i和j的同步测量单元

数据分别表示为时间序列向量$\boldsymbol{x}^*$和$\boldsymbol{y}^*$，通过以下方式构建新的回归模型：

$$y_t^*=\mu+\varepsilon_t'+\sum_{i=1}^{q}\theta_i\varepsilon_t'+\sum_{i=1}^{p}r_i y_{t-i}^*+m_j x_{t-j}^* \quad (7)$$

式中：m_j为另一自回归系数；ε_t'为式(7)的回归误差。

相似地，定义式(7)中的回归误差ε_t'之和为同步测量点i与j的互残差$r_{i,j}=\sum_{t=1}^{N}\varepsilon_t'$，$t=0,1,\cdots,N$。$r_{i,j}$用于评估同时基于两台同步测量单元的数据$\boldsymbol{x}$和$\boldsymbol{y}$的回归模型对扰动数据进行回归的效果。

由式(4)与式(7)以及计算所得的回归效果参数r_i与$r_{i,j}$，可基于信息论公式量化从同步测量单元点j到点i的Granger因果相关性强度$g_{j\to i}$：

$$g_{j\to i}=\ln\frac{r_i}{r_{i,j}} \quad (8)$$

式中：→为Granger因果方向；$j\to i$表示j处扰动为i处扰动的因。$g_{j\to i}$值越大，说明考虑i与j点的回归比只考虑i点的回归更准确。以此为基础结合同步测量单元点位即可提出扰动源分类方法。

1.4　基于因果分析的扰动源分类方法

基于安装设备的数量和点位差异，可将配电网扰动的识别情形分为两类，场景1为测量设备仅安装于同一馈线内，如图2所示。该案例中有配电网同步测量单元PMU1、PMU2和PMU3顺序安装在同一馈线内的近变电站端到远变电站端。该场景下，依据式(8)计算各点间的互因果相关性强度，即可确定扰动的传递方向。

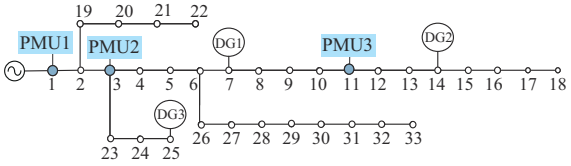

图2　场景1中的测量设备位置示意图
Fig. 2　Schematic diagram of measurement equipment location in scenario 1

图2所示案例中，若某扰动数据的因果相关性强度满足以下条件：

$$g_{2\to1}<g_{1\to2},g_{3\to2}<g_{2\to3},g_{3\to1}<g_{1\to3} \quad (9)$$

则此扰动模态的传播方向为由PMU1至PMU2至PMU3，可判断扰动源自主网侧。

该场景下，判别条件可归纳为：若正向Granger因果相关性强度均值$\bar{g}_{\to}$高于逆向的Granger因果相关性强度均值$\bar{g}_{\leftarrow}$：

$$\bar{g}_{\to}>\bar{g}_{\leftarrow} \quad (10)$$

则判断该扰动为主网侧扰动，两者差值越大，置信度越高。

场景2为存在测量设备安装于相邻馈线内，如图3所示。该案例中，同步测量单元PMU1至PMU5安装在相邻的几个变电站或馈线。该场景中，若馈线间的因果相关性强度高于馈线内部的因果相关性强度，则表明馈线存在共同的影响源，扰动来自主网侧。

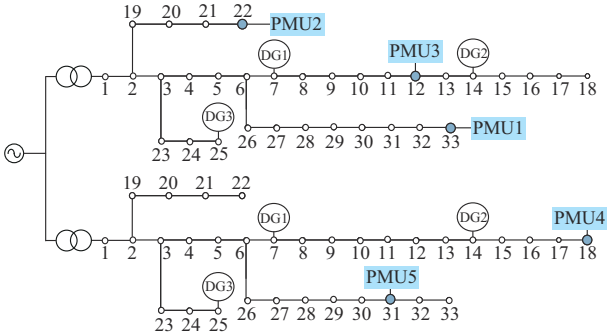

图3　场景2中的测量设备位置示意图
Fig. 3　Schematic diagram of measurement equipment location in scenario 2

由元素g组成的矩阵$\boldsymbol{G}$可表示不同地点测量值之间的因果相关性。假设一变电站或馈线下共有M个测量点位，用对角线和非对角线子矩阵$\boldsymbol{G}_{m,m}$、$\boldsymbol{G}_{m,n}$($m,n=1,2,\cdots,M,m\neq n$)分别表示馈线内的Granger因果相关性强度和馈线间的Granger因果相关性强度。若该因果相关性强度矩阵满足式(11)，则可以判定扰动来自主网侧。

$$\frac{1}{M}\sum_{m=1}^{M}\|\boldsymbol{G}_{m,m}\|_1<\frac{1}{M^2-M}\sum_{m=1}^{M}\sum_{n=1}^{M}\|\boldsymbol{G}_{m,n}\|_1 \quad (11)$$

2　基于核支持向量机的算法误判扰动辨识

2.1　IF算法误判扰动特征分析

与电压不同，同步测量频率f并非直接测量得到，而是通过IF估计算法对电压数据或电流数据相角ϕ的变化率计算获得，其定义为：

$$f=\frac{1}{2\pi}\frac{\mathrm{d}\phi(t)}{\mathrm{d}t} \quad (12)$$

递归最小二乘法(recursive least square method，RLSM)为目前应用广泛的IF估计算法。但该算法产生的频率估计误差会触发扰动检测警报，与真实的扰动事件混淆。将该算法对频率恒定为49.95 Hz的非扰动电压波动信号进行频率估计，其波形信号如图4(a)所示，其IF估计结果如图4(b)所示。

由图4(b)可见，频率估计值会受到电压变化的影响。当电压波形数据出现斜坡变化时，所估计的频率数据中会出现暂升、暂降异常，这些误差估计的频率信号会被检测算法识别为扰动，与真实扰动混

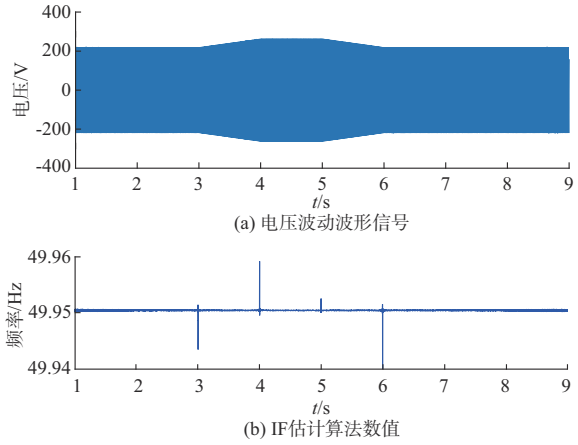

图4　IF估计算法对非扰动电压波动的响应结果
Fig. 4　Response results of IF estimation algorithm to non-disturbed voltage fluctuations

淆。因此，须将IF估计算法产生的误判事件与真实扰动进行分辨，排除IF误判对扰动源分类的干扰。

2.2　基于核支持向量机的误判扰动识别方法

设扰动混杂的训练样本集为$(\boldsymbol{x}_1, z_1),(\boldsymbol{x}_2, z_1),\cdots,(\boldsymbol{x}_h, z_h)$，其中，$h$为样本集个数，$\boldsymbol{x}_i$为各扰动样本，$z_i=\{-1,+1\}$为第$i$个样本的标签，+1代表IF算法误判扰动，−1代表真实扰动。为找到划分扰动样本所属类别的最大化间距超平面，任意超平面可写为满足$\boldsymbol{w}^{\mathrm{T}}\boldsymbol{x}-b=0$的$\boldsymbol{x}$的集合，其中，$\boldsymbol{w}$为法向量，$b$为平面偏移参数。满足条件的超平面可通过对式(13)最小化得到，有

$$\|\boldsymbol{w}\|_2^2+C\left[\frac{1}{h}\sum_{i=1}^{h}\max(0,1-z_i(\boldsymbol{w}^{\mathrm{T}}\boldsymbol{x}_i-b))\right] \tag{13}$$

式中：C为决定增加边距大小与确保位于边距正确一侧之间的权衡参数。

由于各类扰动的误判特征相异，在特征空间中并不线性可分，仅凭上述线性支持向量机难以完成分类。因此，将原方法中的点积用核函数替代，其超平面的决策函数可表示为：

$$F(\boldsymbol{x})=\mathrm{sgn}(\boldsymbol{w}^{\mathrm{T}}\varphi(\boldsymbol{x})-b)=\mathrm{sgn}\left(\left(\sum_{i=1}^{h}c_i z_i K(\boldsymbol{x}_i,\boldsymbol{x}_j)\right)-b\right) \tag{14}$$

式中：sgn(•)为阶跃函数；$\varphi(\boldsymbol{x})$为将$\boldsymbol{x}$映射后的特征空间；c_i为第i个样本的拉格朗日乘子；$K(\boldsymbol{x}_i,\boldsymbol{x}_j)$为将数据进行映射的核函数。

为将数据映射到无限维，使决策边界更灵活，且尽可能减少所需优化参数，引入径向基函数(radial basis function，RBF)核函数$K_{\mathrm{R}}(\cdot)$，其定义如下：

$$K_{\mathrm{R}}(\boldsymbol{x}_i,\boldsymbol{x}_j)=\exp\left(-\frac{\|\boldsymbol{x}_i-\boldsymbol{x}_j\|_2^2}{2\sigma^2}\right) \tag{15}$$

式中：$\|\boldsymbol{x}_i-\boldsymbol{x}_j\|_2^2$为第$i$与第$j$两个样本向量之间的平方欧几里得距离；$\sigma$为算法的自由参数。

RBF核函数的值随样本之间距离增大而减小，并介于0和1之间时，式(15)也可看作一种对两样本相似性的度量。基于RBF核函数的支持向量机决策函数则可进一步写为：

$$F(\boldsymbol{x})=\mathrm{sgn}\left(\left(\sum_{i=1}^{h}c_i z_i\exp\left(-\frac{\|\boldsymbol{x}_i-\boldsymbol{x}_j\|_2^2}{2\sigma^2}\right)\right)-b\right) \tag{16}$$

在所述场景中，分类准确性与核参数和惩罚参数的选取相关。因此，本文进一步提出一种基于粒子群优化(particle swarm optimization，PSO)算法的参数优化方法，对所述RBF核支持向量机算法中的自由参数σ与权重参数C进行寻优。

假设IF算法误判扰动样本数据集个数为D_1，真实扰动样本数据集的个数为D_2，$D=D_1+D_2$为样本数据集总个数，则总搜索空间为D维。假设在空间中有一群粒子，粒子群中的每个粒子都代表优化问题所对应的一个可能的解，则第l个粒子的位置S_l和搜寻速度V_l如式(17)所示。

$$\begin{cases}S_l=(S_{l1},S_{l2},\cdots,S_{lD})\\V_l=(V_{l1},V_{l2},\cdots,V_{lD})\end{cases} \tag{17}$$

第u维空间中粒子的位置和速度更新公式分别如式(18)、式(19)所示。

$$S_{lu,\kappa+1}=S_{lu,\kappa}+V_{lu,\kappa+1} \tag{18}$$

$$V_{lu,\kappa+1}=\omega V_{lu,\kappa+1}+c_1r_1(P_{l,u,\kappa}-S_{lu,\kappa+1})+c_2r_2(P_{g,u,\kappa}-S_{lu,\kappa}) \tag{19}$$

式中：当前时刻的迭代次数为$\kappa=1,2,\cdots,K'$；$S_{lu,\kappa}$和$V_{lu,\kappa}$分别为第l个粒子的实时位置与实时速度；ω为惯性权重；c_1和c_2分别为代表局部搜索能力与全局搜索能力的学习因子；r_1和r_2为区间[0,1]内的随机数；$P_{l,u,\kappa}$和$P_{g,u,\kappa}$分别为第l个粒子在第u维度的局部最优值和整个种群在第u维度的全局最优值。

利用式(18)和式(19)迭代更新上述粒子的位置和速度，判断参数是否满足结束迭代的准确率条件。终止迭代时的参数σ和C即为最优参数组合。

综上，本章提出基于PSO优化的RBF核支持向量机模型，快速识别数据中的IF算法误判扰动。

3　方法流程

本文所提扰动源分类方法的流程如图5所示。

步骤1：采用扰动检测算法对各同步测量单元的实时同步测量数据进行实时检测与初筛；

步骤2：提取同步测量扰动数据进行基于BK滤波和ARIMA的向量自回归分析，根据同步测量单

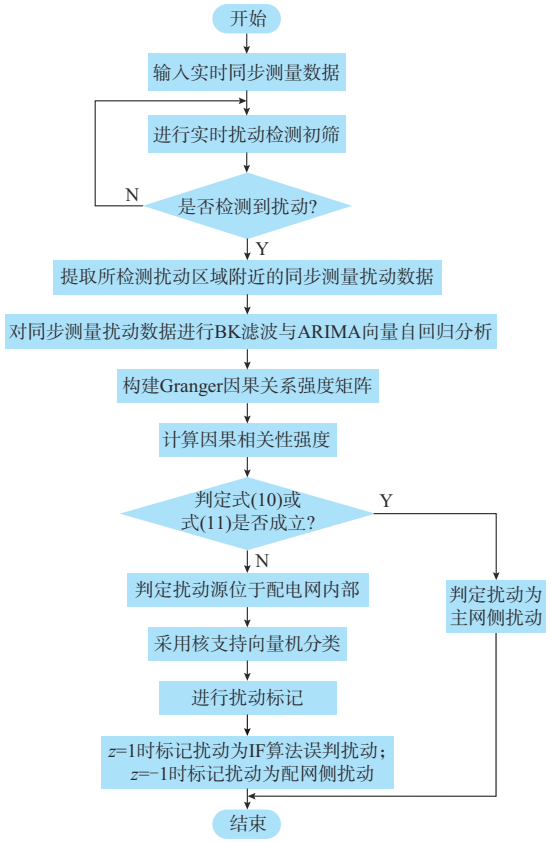

图5　扰动源分类方法流程图
Fig. 5　Flow chart of disturbance source classification method

元的数量及其拓扑结构，构建该区域内的Granger因果相关性强度矩阵，通过计算因果相关性强度进行条件判定，辨识扰动源；

步骤3：当上述N台同步测量单元的同步测量扰动数据样本被所训练的RBF核支持向量机模型标记时，排除IF估计算法导致的扰动误判，完成配电网扰动源分类。

4　算例分析

本文使用DIgSILENT软件对含分布式光伏的IEEE 123节点系统进行扰动仿真，以对所提方法的实现效果进行评估与分析。该仿真系统的拓扑及扰动案例见附录A。为模拟真实同步测量数据，仿真实验时间步长设置为1 ms，并通过20倍降采样处理生成与现场数据上传频率（50 Hz）一致的仿真结果，并在仿真数据中混入60 dB的高斯白噪声。在不同的光伏出力与负荷条件下共得到3 584组扰动数据，其中包括多组馈线内外发生的故障、联络开关操作以及负荷投切事件。基于对该仿真数据的IF估计，另提取1 800组触发扰动检测算法警报的IF误判扰动数据进一步验证误判扰动的识别效果。

4.1　扰动源分类结果

为验证所提扰动源分类方法的有效性，使用该方法对仿真扰动数据中的馈线内、外扰动进行辨识。同步测量单元依次位于节点8、57、67与95。

对馈线外发生的一个三相故障进行辨识的案例中，对多组扰动数据进行BK滤波与ARIMA处理后，计算多个同步测量单元的Granger因果相关性强度值并汇总，如表1所示。

表1　多个同步测量单元的Granger因果强度值
Table 1　Granger causality intensity values for multiple synchronous measurement units

测量节点	正向因果相关性强度	逆向因果相关性强度
8→57	0.029 5	0.021 1
8→67	0.028 8	0.010 5
8→95	0.012 5	0.008 2
57→67	0.011 7	0.018 8
57→95	0.021 3	0.017 2
67→95	0.030 9	0.028 9
平均值	0.022 6	0.017 5

利用表1数据可依据式（10）判断所测试扰动为主网侧扰动。在距离较近的节点之间，偶发正向因果与逆向因果相关性强度接近的现象，但并不影响扰动源识别结果。例如，表中节点57→67之间的正向因果相关性强度小于逆向因果相关性强度。这种现象可能是由于环境噪声的干扰，或是采样率限制导致无法准确反映距离较近节点间的扰动传播。

为进一步验证所提扰动源辨识方法的有效性，将所提方法与包括基于Copula熵的方法、基于逆信息熵的方法、传统Granger因果分析方法在内的其他方法进行对比实验。各方法的扰动源识别结果如表2所示。扰动源辨识方法的性能通过命中率（hits rate，HR）和遗漏率（miss rate，MR）两种指标评估。HR为样本中真实馈线外扰动的数量占被辨识为馈线外扰动数量的比例；MR为样本中被辨识为馈线内扰动的数量占真实馈线外扰动数量的比例。

由表2可看出，基于Granger因果分析的方法与基于熵的方法相比，具有较高的命中率与较低的遗漏率。而所提方法显著提高了传统Granger因果分析方法的辨识命中率，其原因是BK滤波与ARIMA的结合让回归函数更准确、更适应同步测量的扰动数据特性，进而使得Granger因果相关性强度值计算更加精确。

4.2　IF算法误判扰动识别结果

为验证所提IF算法误判扰动识别方法的优越性，在对仿真获得的扰动和非扰动波形数据进行基

表2　基于不同溯源方法的扰动源识别结果
Table 2　Identification results of disturbance sources based on various traceability methods

方法	HR/%	MR/%
Copula熵	90.7	8.19
逆信息熵	87.2	12.37
传统Granger因果分析	94.8	5.37
本文方法	96.4	4.19

于IF算法的频率估计后，将触发扰动检测警报的扰动样本与误判样本以3∶1的数据比例构成训练集与测试集。对不同模型进行了测试，并将结果与使用其他参数优化算法的核支持向量机及其他适用于二分类的经典机器学习方法进行了对比。基于不同模型的识别方法对比结果见表3。类别1为真实扰动事件，类别2为IF算法误判扰动。

表3　基于不同模型的IF误判扰动识别方法对比结果
Table 3　Comparison results of IF misjudgment disturbance identification methods based on various models

方法	类别	性能指标			
		精确率/%	召回率/%	F1分数	准确率/%
支持向量机	1	80.2	78.4	79.3	81.3
	2	82.2	83.4	82.7	
模拟退火-支持向量机	1	90.0	94.7	92.3	91.3
	2	87.0	95.2	90.9	
网格搜索-支持向量机	1	98.7	97.0	97.8	96.1
	2	95.8	89.6	92.6	
遗传算法-支持向量机	1	94.4	94.4	94.4	94.2
	2	94.7	93.5	94.1	
决策树	1	62.0	100.0	77.0	72.0
	2	100.0	48.0	65.0	
随机森林	1	80.5	91.7	85.7	87.8
	2	85.5	94.7	90.0	
k最近邻	1	82.1	82.1	82.1	82.4
	2	76.0	90.5	82.6	
本文方法	1	97.6	100.0	98.8	98.9
	2	100.0	97.6	98.8	

由表3的识别统计结果可知，在传统机器学习算法中，随机森林比决策树具有更好的性能和鲁棒性，但总体识别准确率较低。线性支持向量机在该任务中，由于超平面的维度较低，4项评估指标都不理想，与前文分析一致。与上述机器学习方法相比，使用参数优化算法的方法在平均准确率上更具优势。其中，本文方法的4项评估指标均优于其他模型，识别准确率达98.9%，具有优越性。

4.3　综合扰动源分类结果

为分析所提方法的整体识别性能，选取25%的总仿真样本作为所提扰动源分类方法的验证集，包括：224个馈线外部扰动样本、672个馈线内扰动样本和450个IF误判扰动。所提扰动源分类方法的总分类准确率汇总见图6。图6(a)为验证集的辨识混淆矩阵，图6(b)为相应的标准化混淆矩阵。

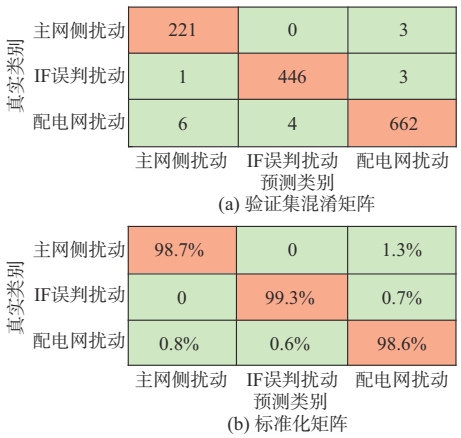

图6　所提方法的分类准确率
Fig. 6　Classification accuracy rate of proposed method

由图6识别结果可知，所提方法能够对含有噪声和IF误判事件的同步测量数据中存在的3种异常事件以较高的平均准确率(98.87%)完成分类。

4.4　计算时间结果

在配置为NVIDA RTX3080 GPU、i9-9900k 3.6 GHz CPU、16 GB内存的计算机上进行测试，方法各阶段的平均计算时间统计见表4。所提方法总耗时为0.146 s，可满足实时性需求。

表4　各阶段计算时间
Table 4　Computational time of various stages

阶段	计算时间/s
扰动检测	0.022
扰动源识别	0.095
IF误判识别	0.020
总计	0.146

4.5　抗噪性实验结果

为验证算法抗噪性，在仿真数据中分别混入40、50、60 dB的高斯白噪声以模拟真实配电网测量环境，测试算法的分类准确率。不同噪声环境下的分类准确率如表5所示。

实验结果表明，随着噪声水平的增加，分类准确率略有下降，但该方法仍然表现出较高有效性，即使在极端噪声(40 dB)下，算法仍能保持较高的分类准确率(>85%)。

表5　不同噪声条件下的分类效果
Table 5　Classification effects in various noise conditions

噪声等级/dB	准确率/%
60	98.87
50	92.75
40	86.26

5　实测数据验证

为进一步验证所提方法在实际场景中的适用性，利用全景同步测量系统（full-view synchronous measurement system，SYMS）[7]中配电网同步测量装置（synchronous measurement device，SMD）采集的实测数据，对所提方法进行基于真实案例的分析。

中国冀北电网发生主网侧连续跳闸事件，该扰动导致某配电网低压侧的两条馈线A、B的同步测量数据出现异常波动，触发扰动警报。分别使用A1、A2和B1、B2代表A、B两条馈线上的4台同步测量单元，扰动发生时的同步测量数据可见图7。

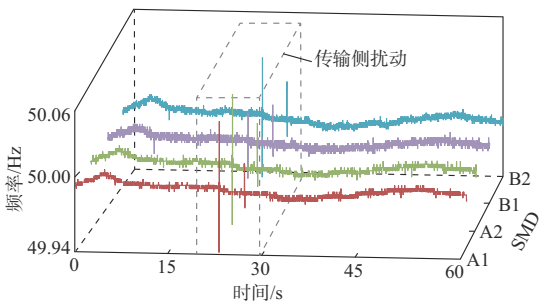

图7　主网侧发生连续跳闸时的同步测量数据
Fig. 7　Synchronous measurement data during continuous tripping on main grid side

将来自同馈线的A1、A2测量的同步测量数据定义为馈线内测量，来自不同馈线的A1、B1测量的同步测量数据定义为馈线间测量。为建立扰动分析基准，须对比扰动发生时的情况，本文基于所提方法对未发生扰动时的正常工况数据也进行了分析。未发生主网侧扰动情况下的同步测量数据见图8。

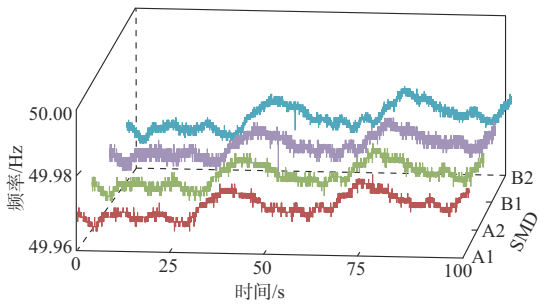

图8　主网侧未发生扰动时的同步测量数据
Fig. 8　Synchronous measurement data when no disturbance occurs on main grid side

基于图7和图8的实测数据，各监测点间的电气量变化特征差异度较低，难以通过传统方法直观辨识扰动源。本研究提出的Granger因果相关性强度分析方法为配电系统扰动溯源提供了新的技术路径。

采用所提方法计算主网侧扰动发生时，A1、A2与B1、B2组成的馈线内及馈线间的因果相关性强度矩阵结果，如图9(a)所示；同时，在主网侧未发生扰动的情况下，相应的因果相关性强度矩阵计算结果如图9(b)所示。

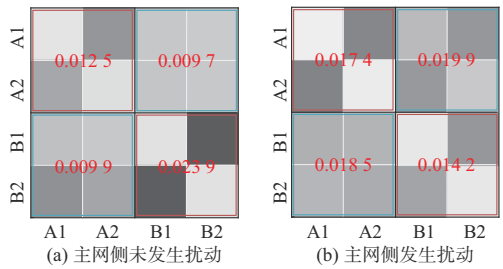

图9　同步测量单元之间的Granger因果相关性强度矩阵
Fig. 9　Granger causality intensity matrices between SMDs

在图9中，两个位于相同馈线的同步测量单元之间的Granger因果关系被视为馈线内因果关系，矩阵中用红框标出；不同馈线之间的Granger因果关系被视为馈线间因果关系，矩阵中用蓝框标出。以馈线内因果相关性强度的平均值作为基准，当馈线间因果相关性强度的平均值高于此基准时，可识别为主网侧扰动。图10为在该案例中有主网侧扰动与无主网侧扰动时Granger因果相关性强度的对比。

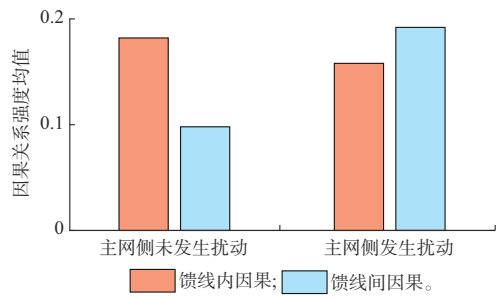

图10　馈线间与馈线内的Granger因果相关性强度比较
Fig. 10　Comparison of Granger causality intensities between feeder lines and within feeder

由图10可看出，当数据中存在主网侧扰动时，馈线内的平均Granger因果相关性强度低于馈线间的因果相关性强度；而在没有任何主网侧扰动的情况下，情况则相反。该结果表明，在主网侧扰动发生与未发生时，馈线内外的因果相关性强度矩阵存在

显著差异。这一现象验证了所提基于Granger因果相关性强度计算方法在现场扰动数据来源分析中的有效性。

6 结语

本文提出了一种数据驱动的扰动源快速分类方法，该方法基于同步测量数据有效值动态，结合因果相关性分析与核支持向量机模型，能快速识别现场数据中的主网侧扰动、配网侧扰动及算法误判扰动。IEEE 123节点系统仿真与现场测试结果表明，所提方法具有较高的分类准确性和实时性。

目前，新型配电网建设仍面临数据稀缺与测量覆盖不足等问题。本文研究依赖仿真与部分现场数据，未来需进一步提升模型在实际场景下的泛化能力，优化测量单元部署，构建基于分层采集与处理的扰动源识别方法。

附录见本刊网络版，点击 http://www.aeps-info.com/aeps/article/abstract/20250110002，或扫描英文摘要后二维码，可阅读全文。

参考文献

[1] 王伟胜，林伟芳，何国庆，等.美国得州2021年大停电事故对我国新能源发展的启示[J].中国电机工程学报，2021，41(12)：4033-4043.
WANG Weisheng, LIN Weifang, HE Guoqing, et al. Enlightenment of 2021 Texas blackout to the renewable energy development in China[J]. Proceedings of the CSEE, 2021, 41(12): 4033-4043.

[2] 钟剑，陈晨，张昊辰，等.极端天气下配电网信息物理耦合故障快速恢复策略[J/OL].电力系统自动化：1-23[2025-04-16]. https://link.cnki.net/urlid/32.1180.tp.20241008.1649.004.
ZHONG Jian, CHEN Chen, ZHANG Haochen, et al. Rapid restoration strategy for cyber-physical integrated failures in distribution systems under extreme weather conditions[J/OL]. Automation of Electric Power Systems: 1-23[2025-04-16]. https://link.cnki.net/urlid/32.1180.tp.20241008.1649.004.

[3] DUAN N, STEWART E M. Frequency event categorization in power distribution systems using micro PMU measurements[J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3043-3053.

[4] ARANA A, BANK J, GARDNER R, et al. Estimating speed of frequency disturbance propagation through transmission and distribution systems[C]// 2006 IEEE PES Power Systems Conference and Exposition, October 29-November 1, 2006, Atlanta, USA: 1286-1290.

[5] 王宾，孙华东，张道农.配电网信息共享与同步相量测量应用技术评述[J].中国电机工程学报，2015，35(增刊1)：1-7.
WANG Bin, SUN Huadong, ZHANG Daonong. Review on application technology of information sharing and synchronous phasor measurement in distribution network[J]. Proceedings of the CSEE, 2015, 35(S1): 1-7.

[6] VON MEIER A, STEWART E, MCEACHERN A, et al. Precision micro-synchrophasors for distribution systems: a summary of applications[J]. IEEE Transactions on Smart Grid, 2017, 8(6): 2926-2936.

[7] LIU H, BI T S, XU S D, et al. A full-view synchronized measurement system for the renewables, controls, loads, and waveforms of power-electronics-enabled power distribution grids[J]. IEEE Transactions on Smart Grid, 2022, 13(5): 3879-3890.

[8] 张琳，任双雪，惠子珈，等.实现配电网PMU频率测量的数字微分器研究[J].中国电机工程学报，2021，41(22)：7640-7648.
ZHANG Lin, REN Shuangxue, HUI Zijia, et al. Design of digital differentiator for frequency measurement in distribution grid PMU[J]. Proceedings of the CSEE, 2021, 41(22): 7640-7648.

[9] SHAHSAVARI A, FARAJOLLAHI M, STEWART E M, et al. Situational awareness in distribution grid using micro-PMU data: a machine learning approach[J]. IEEE Transactions on Smart Grid, 2019, 10(6): 6167-6177.

[10] APPASANI B, JHA A V, MISHRA S K, et al. Communication infrastructure for situational awareness enhancement in WAMS with optimal PMU placement[J]. Protection and Control of Modern Power Systems, 2021, 6(1): 9.

[11] SEYEDI Y, KARIMI H, GRIJALVA S. Irregularity detection in output power of distributed energy resources using PMU data analytics in smart grids[J]. IEEE Transactions on Industrial Informatics, 2018, 15(4): 2222-2232.

[12] SHAHSAVARI A, FARAJOLLAHI M, STEWART E, et al. A data-driven analysis of capacitor bank operation at a distribution feeder using micro-PMU data[C]// 2017 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT), April 23-26, 2017, Washington, USA: 1-5.

[13] AKRAMI A, ASIF M S, MOHSENIAN-RAD H. Sparse distribution system state estimation: an approximate solution against low observability[C]// 2020 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT), February 17-20, 2020, Washington, USA.

[14] SHAHSAVARI A, FARAJOLLAHI M, STEWART E, et al. A machine learning approach to event analysis in distribution feeders using distribution synchrophasors [C]// 2019 International Conference on Smart Grid Synchronized Measurements and Analytics (SGSMA), May 21-23, 2019, College Station, USA: 1-7.

[15] FARAJOLLAHI M. Locating the source of events in power distribution systems using micro-PMU data [J]. IEEE Transactions on Power Systems, 2018, 33(6): 6343-6354.

[16] ZHOU X, WANG Y H, SHI Y X, et al. Deep reinforcement learning-based optimal PMU placement considering the degree of power system observability [J]. IEEE Transactions on Industrial Informatics, 2024, 20(6): 8949-8960.

[17] CHEN G, LI Z Y, ZHAO Z Y. Event-triggered optimal active power control in islanded microgrid with variable demand and time-varying communication topology [J]. IEEE Transactions

on Smart Grid, 2019, 10(4): 4015-4025.

[18] 冯双,杨浩,崔昊,等.基于Copula传递熵的设备级和网络级宽频振荡传播路径分析及振荡源定位方法[J].电工技术学报,2024,39(16):4996-5010.
FENG Shuang, YANG Hao, CUI Hao, et al. Propagation path analysis and oscillation source location method of device-level and network-level broadband oscillation based on Copula transfer entropy [J]. China Industrial Economics, 2024, 39(16): 4996-5010.

[19] 穆钢,陈奇,刘洪波,等.揭示电力系统运行数据中因果关系的逆信息熵因果推理方法[J].中国电机工程学报,2022,42(15):5406-5417.
MU Gang, CHEN Qi, LIU Hongbo, et al. Power system disturbance detection method considering PMU data quality problems[J]. Proceedings of the CSEE, 2022, 42(15): 5406-5417.

[20] JIANG H G, DAI X X, GAO D W, et al. Spatial-temporal synchrophasor data characterization and analytics in smart grid fault detection, identification, and impact causal analysis [J]. IEEE Transactions on Smart Grid, 2016, 7(5): 2525-2536.

[21] CHO S H, JANG G, KWON S H. Time-frequency analysis of power-quality disturbances via the Gabor-Wigner transform[J]. IEEE Transactions on Power Delivery, 2010, 25(1): 494-499.

[22] CHASSIN D P, SCHNEIDER K, GERKENSMEYER C. GridLAB-D: an open-source power systems modeling and simulation environment[C]// Proceedings of the 2008 Power & Energy Society Transmission and Distribution Conference and Exposition, April 21-24, 2008, Chicago, USA: 1-5.

[23] BAXTER M, KING R G. Measuring business cycles: approximate band pass filters economic time series [J]. Review of Economics and Statistics, 1999, 81(4): 575-593.

陈徵鄰(1996—),女,博士研究生,主要研究方向:数据驱动电网扰动辨识。E-mail:chzc@ncepu.edu.cn

刘　灏(1985—),男,通信作者,副教授,博士生导师,主要研究方向:电力系统同步相量测量技术及应用。E-mail:hliu@ncepu.edu.cn

毕天姝(1973—),女,教授,博士生导师,主要研究方向:电力系统保护与控制。E-mail:tsbi@ncepu.edu.cn

(编辑　代长振)

Synchronous Measurement Data-driven Classification Method for Disturbance Sources in Distribution Networks

CHEN Zhilin, LIU Hao, BI Tianshu

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources (North China Electric Power University), Beijing 102206, China)

Abstract: To address the challenges brought by the integration of a large number of distributed generators, the synchronous measurement technology has been introduced into the distribution network to provide more-dimensional data for the safety and stability analysis of the system. To further enhance the situational awareness of the distribution network, a synchronous measurement data-driven classification method for disturbance sources in the distribution network is proposed in this paper. Firstly, a fast identification method for disturbance sources based on Granger causality analysis theory is proposed to identify if the disturbance source is from the main grid side or the distribution network side. Subsequently, a misjudged disturbance identification method based on kernel support vector machine algorithm is proposed to identify misjudged disturbances caused by errors in instantaneous estimation algorithms, thus achieving the rapid classification and extraction of real-time distribution network disturbance data. Finally, the effectiveness of the proposed method is verified based on IEEE 123-bus system simulation data and on-site synchronous measurement data.

This work is supported by National Natural Science Foundation of China (No. 52377098).

Key words: distribution network; distributed generator; situational awareness; synchronous measurement; kernel support vector machine; disturbance