

考虑 PMU 数据特征的新能源场站扰动检测方法

廖梦竹, 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 昌平区 102206)

Disturbance Detection Method for Renewable Generation Resources Considering the Characteristics of PMU Data

LIAO Mengzhu, LIU Hao*, BI Tianshu

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources

(North China Electric Power University), Changping District, Beijing 102206, China)

ABSTRACT: The Phasor Measurement Unit provides data support for dynamic analysis and power fluctuation monitoring in renewable energy stations. Due to harsh operating environments, deployed PMUs often exhibit measurement anomalies, and continuous faulty data can impact the detection of real disturbances. Based on measurement data from a renewable energy demonstration base, this paper proposes a disturbance detection method for renewable energy stations considering PMU data characteristics. The method analyzes four types of PMU frequency anomalies in renewable energy stations and reveals the differences in spatiotemporal similarity between faulty data and disturbances across different PMUs. Considering both point and sequence anomalies' local and global features, this paper proposes an improved Local Outlier Factor algorithm for point anomaly detection, which effectively reduces false alarm rate by incorporating clustering algorithms to compare the differences in point density. An improved denoising variational autoencoder model is introduced for sequence anomaly detection, enhancing feature extraction and setting dynamic thresholds, which improves detection accuracy. To further distinguish faulty data from disturbances, this paper develops an improved dynamic kernel correlation disturbance detection method, which calculates a spatiotemporal similarity matrix to measure feature differences, ensuring accurate disturbance event detection. Simulation and real data confirm the effectiveness of the proposed method.

KEY WORDS: disturbance detection; synchronous phasor measurement; local outlier factor; denoising variational autoencoder; dynamic kernel correlation

摘要: 相量测量单元(phasor measurement unit, PMU)可为新

能源场站的动态特性分析和功率波动监测提供数据支撑。由于场站的运行环境恶劣,现场已部署的PMU易出现量测数据异常现象,连续的不良数据将影响真实扰动的检测。基于某新能源示范基地现场的量测数据,文中提出一种考虑PMU数据特征的新能源场站扰动检测方法。首先,分析新能源场站中4种PMU频率不良数据的现象,揭示异常时刻不良数据与扰动在不同PMU量测时空相似性方面的特征差异;其次,考虑点异常和序列异常的局部和全局特征,提出改进局部离群因子算法的点异常检测方法,改进过程结合聚类算法全面比较点的密度差异,有效降低了虚警率;然后,提出改进去噪变分自编码器模型的序列异常检测方法,该方法对原始数据进行特征增强,提取信息最丰富的特征向量输入模型,同时引入加权重构误差并设定动态阈值,有效提升了检测精度;为进一步区分不良数据和扰动,提出改进动态核相关的扰动检测方法,通过计算时空相似性矩阵以度量不良数据和扰动在时空维度的特征差异性,进而实现扰动事件的准确检测;最后,通过仿真和实测数据验证所提方法可有效检测扰动并滤除不良数据,保障了PMU数据的可靠性。

关键词: 扰动检测; 同步相量测量; 局部离群因子; 去噪变分自编码器; 动态核相关

0 引言

新能源场站在实现碳中和目标、推动能源可持续发展方面发挥着重要作用。为实现场站的实时态势感知和故障预警,风电场安装箱变测控装置、光伏场站安装逆变器监控装置。然而,上述传统监测设备无法高精度地实时监测电压、电流、频率等相量数据,同步相量测量单元(phasor measurement unit, PMU)凭借其实时性、准确性等优势在现场得到了广泛部署^[1-3]。

然而,PMU数据质量下降成为限制其发展和应用的重要原因。一方面,由于现场测量环境恶劣,

基金项目: 国家自然科学基金项目(52377098)。

Project Supported by National Natural Science Foundation of China (52377098).

传感器误差、通信堵塞、噪声干扰等因素引起 PMU 数据出现跳变、丢失、偏差等异常现象^[4-5]。据统计,中国某新能源示范基地现场部署的 PMU 不良数据比例高达 12.66%。另一方面,新能源场站运行环境复杂,不良数据与扰动的特征复杂性显著增加,连续的不良数据会干扰真实扰动信号的辨识,影响调度员对扰动的及时响应^[6]。综上所述,亟需提出一种剔除不良数据、考虑数据复杂特征的适用于新能源场站的扰动检测方法。

基于 PMU 量测数据驱动的电力系统扰动检测已有广泛研究,现有文献的研究方法可划分为统计学方法^[7-10]、传统机器学习方法^[11-14]以及深度学习方法^[15-18] 3 类。文献[7]提出了差分 Teager-Kaiser 能量算子与 3σ 准则相结合的方法以检测 PMU 异常数据;文献[8]利用逻辑回归算法实现了异常辨识;文献[9]提出了方差变化率和四分位法结合的方法辨识风机功率异常数据;文献[10]提出应用随机矩阵和奇异值(singular value decomposition, SVD)分解理论的异常检测方法,利用随机矩阵技术构建特征矩阵, SVD 对矩阵降维后通过融合指标识别了异常点。上述基于统计学的异常检测研究大多假设数据呈现某种特定分布,往往难以捕捉非线性数据间的复杂相关性,并且难以高效处理大规模数据。

为了克服统计学方法的局限性,传统机器学习方法被引入。文献[11]提出基于线性回归、切比雪夫、基于密度的带噪声应用聚类(density-based spatial clustering of applications with noise, DBSCAN)方法的基础检测器,利用最大似然估计技术的集成学习模型提升检测准确率;文献[12]计算每台 PMU 的局部离群因子数值(local outlier factor, LOF),与基于箱线图确定的阈值进行比较,实现连续不良数据的在线检测;文献[13]提出 3 种无监督算法组合分析以选定数据点窗口,进而用堆叠的集成学习模型实现对异常数据的检测;文献[14]将原始数据转化为二值图像,通过数学形态学基本运算自适应识别异常数据。上述基于传统机器学习方法的异常数据检测研究大多没有兼顾数据特征的局部性和全局性,在应对新能源场站中噪声干扰等复杂的动态环境时其存在一定的限制,自适应性较差。

为了克服传统机器学习方法的局限性,在处理新能源场站中高维、非线性数据时,基于深度学习的检测方法被用于自动学习数据的时序特征。文献[15]提出了一种基于双向异常生成对抗网络的电

力系统事件检测算法,实现了在线事件的高准确率检测;文献[16]通过 Hessian 局部线性嵌入技术提取特征,基于嵌入坐标的特征空间,采用 T 方统计量实现在线故障检测;文献[17]提出了一种基于图边缘条件卷积网络的不良数据检测框架;文献[18]利用长短期记忆网络(long short-term memory, LSTM)对 PMU 原始数据进行重构,基于决策树算法确定阈值,有效检测了不良数据。上述基于深度学习方法的异常数据检测研究大多没有考虑数据的复杂性和时间依赖性,未能高效利用所提取的特征,在处理大规模数据时实时性较差。并且现有文献中尚未涉及使用实际新能源场站的 PMU 海量数据进行测试的相关研究。

为了充分捕捉新能源场站 PMU 量测数据的特征、避免不良数据的干扰,基于某示范基地现场的 PMU 量测数据,本文提出考虑 PMU 数据特征的新能源场站扰动检测方法。首先,提出基于密度的局部离群因子的点异常检测方法,对计算的离群因子值升序排列,并利用四分位法设定阈值检测点异常;然后,提出基于改进自编码器的序列异常检测方法,结合差分 and 滑窗方差实现时序数据的特征增强,送入去噪变分自编码器中计算滑窗内加权重构误差,并和动态阈值 3σ 进行比较以检测序列异常,为降低扰动检测的虚警率和漏检率奠定基础;在此基础上,提出基于改进动态核相关算法的扰动检测方法,引入时空权重系数以兼顾多台 PMU 间电气联系和时间连续性,并依据时空相关性矩阵成功区分扰动数据和不良数据;最后,通过仿真和实测算例计算异常检测和扰动检测漏检率、虚警率等指标,完成算法鲁棒性和方法有效性的验证。

1 新能源场站 PMU 异常数据特性分析

经研究发现,在实际新能源场站中,现场 PMU 的测量环境受电力电子器件频繁的开关动作、新能源固有的波动性随机性、通讯堵塞、数字信号采集设备采样精度和延时等影响,导致 PMU 出现跳变、偏差、缺失等异常情况的概率显著增加,本文将这些跳变数据统称为不良数据。通过对海量数据分析可知,点异常的持续时间小于 0.1 s,序列异常的持续时间大于 0.1 s,根据不良数据的时间连续性,本文将现场实测不良数据分为单峰单点、双峰单点、单峰序列、双峰序列 4 类,对应的曲线如图 1 所示。

新能源场站中的不良数据在同一时空中往往只




图 1 4 种 PMU 不良数据曲线

Fig. 1 Curves of four PMU bad data

存在于单台 PMU 之中,现场不良数据曲线如图 2(a)、(b)所示;当真实扰动发生时,多台 PMU 在同一时空表现出高度相似性,场站内部的储能切除导致风电场失去调节功率的支撑,风机出力下降导致频率下降,现场扰动曲线如图 2(c)、(d)所示。本文将不良数据和扰动统称为异常数据,不良数据与真实扰动的曲线对比图如图 2 所示。




图 2 不良数据与扰动曲线对比图

Fig. 2 Comparison of bad data and disturbed curves

基于上述对 PMU 异常数据特征的分析,为准确识别场站中真实发生的扰动,2 节根据点异常和时序异常的特征选择相应算法检测所有异常数据;3 节根据不良数据和扰动的时空相似性特征检测真实扰动,同时滤除不良数据。

2 基于改进局部离群因子与改进自编码器的异常检测方法

2.1 基于改进局部离群因子的点异常检测方法

LOF 凭借局部性和适应性广泛用于电力系统的同步电机故障检测和频率数据异常检测^[19]。但 LOF 获取离群因子时需要计算一个点与其邻域内所有点的距离,计算成本较高;同时,由于 LOF 的计算完全基于局部密度,其在处理分布不均或者具有噪声的数据集时,容易造成较高的虚警率。对此,本文采用基于聚类的局部异常因子(cluster-based local outlier factor, CBLOF)进行点异常检测^[20],在保留对于短时异常数据的高敏感性优势外,利用 DBSCAN 算法聚类,在无需事先指定簇个数的前提下,算法直接根据点的密度进行簇的划分,聚类过程使得 CBLOF 能够更全面地比较数据点的密度差异,从而增加全局性的判断能力,有效降低虚警率;同时,只需计算该点和簇内点的距离,有效降低计算成本。

对于每个频率量测数据点, CBLOF 的离群因子值 p 可表示为两部分的加权和,大小因子指的是若一个点所属聚类规模很小,该点可能是异常点;密度因子指的是若一个点距离其聚类中心较远,可能是异常点,离群因子值 p 和聚类中心 M_k 的计算公式为:

$$p = \alpha \times \frac{\text{CSize}(x_t)}{\text{CSize}(C_k)} + \beta \times \frac{D(x_t, M_k)}{\text{Max } D(x_t, M_k)} \quad (1)$$

$$M_k = \frac{1}{\text{CSize}(x_t)} \sum_{x_t \in C_k} x_t \quad (2)$$

式中: x_t 为时间点 t 对应的频率量测数据; k 为 DBSCAN 聚类簇数; α 、 β 为权重系数,控制大小因子和密度因子的相对影响; $\text{CSize}(x_t)$ 为频率量测数据点 x 所属聚类中数据点的个数; $\text{CSize}(C_k)$ 为属于该聚类的所有频率量测数据点个数; M_k 为聚类中心; $D(x_t, M_k)$ 为 x_t 到其所在聚类 C_k 的聚类中心的距离; $\text{Max } D(x_t, M_k)$ 为聚类 C_k 中各频率量测数据点到聚类中心的最大距离; $\sum_{x_t \in C_k} x_t$ 为簇中各频率量测数据点坐标之和。

计算得到的离群因子值 p 自身无法实现对于异常数据点的检测,本节将通过式(1)计算得到的 p 升序排序,利用不依赖于数据分布的四分位法设定阈值实现点异常检测^[21]。四分位算法的核心思想是大部分数据集中在第 1 四分位数 Q_1 和第 3 四分位数

Q_3 之间,基于 Q_1 和 Q_3 计算出上、下界阈值,进而识别异常值。四分位距(interquartile range, I_{QR})为 Q_1 和 Q_3 之间的差距,计算公式为

$$I_{QR} = Q_3 - Q_1 \quad (3)$$

下界阈值和上界阈值的计算公式为

$$\begin{cases} b_L = Q_1 - 1.5I_{QR} \\ b_U = Q_3 + 1.5I_{QR} \end{cases} \quad (4)$$

当一个离群因子值 $p < b_L$ 或者 $p > b_U$,则判定为频率量测异常点。

2.2 基于改进自编码器的序列异常检测方法

点异常检测通常仅关注单一数据点的短时异常,而序列数据具有时间依赖性和动态变化性,因此,对其进行异常检测时需捕捉相邻数据点间的关联性。新能源场站序列数据具备特殊的时空特性和多维度的动态特性^[22],模型仅依赖原始数据时会出现误判、漏检等情况,因此,需在检测前对序列数据进行特征增强和特征提取,这一关键性步骤使得模型能更好地提取原始数据隐藏的趋势性和关联性特征,进而提升异常检测的准确率。

一阶差分^[23]和二阶差分^[24]是常用的数据处理方法,一阶差分的计算公式为

$$\Delta x_t = x_t - x_{t-1} \quad (5)$$

式中: x_t 为时间点 t 对应的频率量测数据; x_{t-1} 为时间点 $t-1$ 对应的频率量测数据。

二阶差分的计算公式为

$$(\Delta x_t)^2 = \Delta x_t - \Delta x_{t-1} = (x_t - x_{t-1}) - (x_{t-1} - x_{t-2}) = x_t - 2x_{t-1} + x_{t-2} \quad (6)$$

式中: Δx_t 、 Δx_{t-1} 分别为时间点 t 和 $t-1$ 对应频率量测数据的一阶差分; x_{t-2} 为时间点 $t-2$ 对应的频率量测数据。

文献[7]提出了差分 Teager-Kaiser 能量算子(differential Teager-Kaiser energy operator, dTKEO)进行特征增强,其计算公式为

$$\zeta_{dTKEO}(x_t) = (\Delta x_t)^2 - \Delta x_{t-1} \Delta x_{t+1} = (x_t - x_{t-1})^2 - (x_{t-1} - x_{t-2})(x_{t+1} - x_t) \quad (7)$$

式中: Δx_{t+1} 为时间点 $t+1$ 对应频率量测数据的一阶差分; x_{t+1} 为时间点 $t+1$ 对应频率数据。

滑窗方差通过窗口形式计算数据方差^[25],如果滑动数据窗口内的时序数据为 $x_\omega = (x_i, x_{i+1}, \dots, x_{i+\omega-1})$,窗口方差的计算公式为

$$\psi_\omega(i) = \frac{1}{\omega} \sum_{j=0}^{\omega-1} (x_{i+j} - \bar{x}_\omega(i))^2 \quad (8)$$

式中: ω 为窗口大小; $\bar{x}_\omega(i)$ 为窗口 ω 内时序数据的均值,均值的计算公式为

$$\bar{x}_\omega(i) = \frac{1}{\omega} \sum_{j=0}^{\omega-1} x_{i+j} \quad (9)$$

本文利用上述方法对原始序列数据进行特征增强以降低异常漏检率。具体地,将一阶差分、二阶差分、dTKEO、滑窗方差的计算结果作为每段频率量测序列数据的4个特征向量,这4个方法的选择是为了多维度、全面地刻画时序数据的不同特征,优势互补地为序列异常检测模型提供丰富的特征,帮助其更准确地识别异常序列。通过补零的方式保证特征向量的维度一致,同时将这些特征向量合并为一个特征增强矩阵,作为深度学习神经网络改进自编码器的输入,为异常检测的准确性和高效性奠定基础。

自编码器(autoencoder, AE)通过学习正常数据的分布并对输入序列进行重构,计算重构误差后与阈值比较以判定异常序列。AE 凭借无监督学习和高效特征学习的能力,在电力系统的异常检测和数据降维等方面得到广泛应用^[26-27]。堆叠两层稀疏收缩自编码器检测管理系统的健康状态^[26],卷积自编码器用以辨识电力变压器的故障声纹^[27]。本节从模型结构、重构误差、阈值设定3个方面对传统AE加以改进以实现新能源场站中序列异常的检测。

模型结构结合了变分自编码器和去噪自编码器的优势,采用去噪变分自编码器^[28](denoising variational autoencoder, DVAE),DVAE在传统AE的基础上加入了噪声扰动和潜在变量的生成模型,提升模型处理复杂且具有噪声的输入数据的能力,适用于新能源场站现场存在的不同来源的噪声干扰。

为了凸显输入特征向量的不同重要性和变化规律,模型引入了加权重构误差的计算,由此可根据不同特征对异常检测的贡献程度进行调整。dTKEO和滑窗方差输入的特征能够更加敏感地全面地捕捉序列的突变和局部波动,因此赋予较高的权重系数,加权重构误差的计算公式为

$$\eta_{\text{weighted}}(\mathbf{x}, \hat{\mathbf{x}}) = w_1 |x_1 - \hat{x}_1|^2 + w_2 |x_2 - \hat{x}_2|^2 + w_3 |x_3 - \hat{x}_3|^2 + w_4 |x_4 - \hat{x}_4|^2 \quad (10)$$

式中: $\mathbf{x} = [x_1, x_2, x_3, x_4]$ 为输入特征向量,对应一阶差

分、二阶差分、dTKEO、滑窗方差的计算结果； $\hat{x}=[\hat{x}_1, \hat{x}_2, \hat{x}_3, \hat{x}_4]$ 为各输入特征对应的重构误差； w_i 为权重系数， $i=1, 2, 3, 4$ 。

根据窗内数据更新均值和标准差，模型通过滑窗的方式设定动态阈值，阈值的计算公式为

$$T_e = \mu_e + 3\sigma_e \quad (11)$$

式中： μ_e 为当前窗口加权重构误差的均值； σ_e 为当前窗口加权重构误差的标准差。当前窗口的加权重构误差 $\eta_{\text{weighted}}(x, \hat{x}) > T_e$ 时，判定为频率量测异常序列。

经过上述改进后的 DVAE 模型能够更好地适应新能源场站中复杂的、噪声干扰较多的环境，可有效地处理带噪声的输入数据，并通过学习潜在变量捕捉复杂的异常模式；通过加权重构误差，其能够更好地关注与异常检测相关的重要特征；动态阈值的设定使得模型能够根据实时数据变化进行适应性调整，提高了异常检测的灵活性和精度。

2.3 基于改进局部离群因子与改进自编码器的异常检测流程

基于改进局部离群因子的点异常检测与改进自编码器的序列异常检测的流程图如图 3 所示。CBLOF 适用于检测独立的异常点，尤其是在整体数据分布中处于边缘的点；改进 DVAE 适用于检测异常序列，尤其是存在复杂时序模式或长期依赖关系的序列数据。在针对不同类型的异常时，二者采用独立的检测逻辑，从而保障了精准检测结果。




图 3 异常检测流程图

Fig. 3 Flow chart of anomaly detection

异常检测过程中模型参数设置如表 1 所示。

表 1 模型的参数设置

Table 1 Parameter setting of model

模型结构名称	参数	模型结构名称	参数
DBSCAN 聚类簇数 k	3	稀疏性正则化项的权重	4
大小因子权重系数 α	0.3	稀疏性比例	0.1
密度因子权重系数 β	0.7	动态阈值窗口大小	20
滑窗方差的窗口大小	25	潜在空间神经元个数	2
四分位距系数	1.5	Dropout	0.2
DVAE 的噪声因子	0.05	权重系数 w_1 、 w_2	0.2
最大训练轮数	200	权重系数 w_3 、 w_4	0.3
L_2 正则化项的权重	0.01	—	—

3 基于改进动态核相关的扰动检测方法

3.1 基于改进动态核相关的时空相似性分析方法

有效检测 PMU 异常数据后，进一步，为了准确识别场站中真实发生的扰动，需要区分异常数据中的扰动数据和不良数据，排除不良数据的干扰，快速高效地检测扰动并滤除不良数据。

基于 1 节对于扰动和不良数据的差异性分析可知，当真实扰动发生时，多台 PMU 会在扰动时刻附近展现时间同步性和空间一致性，在扰动位置周围多台 PMU 会记录下频率相同的变化趋势。而不良数据的变化模式更为随机和孤立，其往往在同一时空仅存于单台 PMU 中，也不能反映系统的整体行为，因此，不同 PMU 间时空相似性成为区分扰动和不良数据的重要依据。

动态核相关(dynamic kernel correlation, DKC)算法具备良好的非线性映射能力和强大的灵活性^[29]，是能够评估时空相似性的合适度量指标。DKC 适用于处理新能源场站中高维动态数据的时空依赖关系，相较于皮尔逊相关系数算法，DKC 能够有效处理非线性关系、捕捉更为复杂的数据模式；相较于动态时间规整和曼哈顿距离算法，DKC 将数据映射至高维特征空间，能够提供更加准确和有效的相似性度量。

将 2.3 节经过时间定位的异常标记数据进行整合，选取异常点附近窗长为 T 的时间窗口和 N 台 PMU 的频率量测数据进行分析。为了统一尺度和保证核函数计算的有效性，首先将数据进行标准化处理，标准化公式为

$$f_i = \frac{X_i - \mu_i}{\sigma_i} \quad (12)$$

式中： f_i 为标准化处理后的第 i 台 PMU 的频率量测数据， $i=1, 2, \dots, N$ ； $X \in \mathbf{R}^{T \times N}$ ， X_i 为当前窗口第 i 台

PMU 异常检测的频率量测数据; μ_i 为窗口内第 i 台 PMU 异常数据的均值; σ_i 为窗口内第 i 台 PMU 异常数据的标准差。

DKC 通过高斯核函数计算每一对点的相似度, 并对整个窗内的时间序列进行核函数的加权积分, 高斯核的核函数计算表达式为

$$K(f_i, f_j) = \exp\left[-\frac{(f_i - f_j)^2}{2\sigma^2}\right] \quad (13)$$

式中: f_i, f_j 分别为第 i 台和第 j 台 PMU 的标准化后对应时刻的频率量测数据; σ 为核带宽, 控制着高斯核的宽度。

对于频率数据 f_i 和 f_j , 自核矩阵 K_{fi} 、 K_{fj} 表征单台 PMU 不同时间数据点之间的相似度, 交叉核矩阵 K_{fij} 表征相邻 PMU 间同一时间不同数据点之间的相似度。通过计算这些矩阵, DKC 能够同时量化 PMU 类内和类间的相似度, 自核矩阵与交叉核矩阵的计算公式为

$$\begin{cases} K_{fi}(m, n) = \exp\left[-\frac{(f_{im} - f_{in})^2}{2\sigma^2}\right] \\ K_{fj}(m, n) = \exp\left[-\frac{(f_{jm} - f_{jn})^2}{2\sigma^2}\right] \\ K_{fij}(m, m) = \exp\left[-\frac{(f_{im} - f_{jm})^2}{2\sigma^2}\right] \end{cases} \quad (14)$$

式中: f_{im}, f_{in} 分别为第 i 台 PMU 对应 m 和 n 时刻标准化后的频率量测数据; $m \in T, n \in T$; f_{jm}, f_{jn} 分别为第 j 台 PMU 对应 m 和 n 时刻标准化后的频率量测数据。

为了在计算过程中兼顾 PMU 配置的物理位置和天气变化引起的时间连续性等影响, 本节提出一

种基于时空相关性加权的改进 DKC 方法, 改进后计算的最终结果以 $N \times N$ 维对称相似度矩阵表示。基于式(14)的计算结果, 相似度矩阵中每个元素的计算公式为

$$D(f_i, f_j) = \left(\frac{1}{a} \sum_m K_{fij}(m, m)\right) W_S(m, m) + \sqrt{\left(\frac{1}{b} \sum_{m,n} K_{fi}(m, n)\right) W_T(m) \left(\frac{1}{b} \sum_{m,n} K_{fj}(m, n)\right) W_T(n)} \quad (15)$$

式中: $W_S(m, m)$ 为空间距离的加权系数, 考虑不同 PMU 之间的电气联系; $W_T(m), W_T(n)$ 为时间窗加权系数, 考虑单台 PMU 序列数据间的时间相关性; a, b 分别为当前时间窗内计算交叉核矩阵和自核矩阵的次数。考虑到新能源场站中 PMU 配置均匀, 且动态行为和突发事件频繁发生, 为有效捕捉到时变效应, 设置 $W_S(m, m) = 0.4, W_T(m) = W_T(n) = 0.6$ 。

时空相似性越高, PMU 类内和类间的数据差值越小, 积分核函数越趋近于 1, $D(f_i, f_j)$ 越趋近于 1。为了更直观地判定扰动, 计算 DKC 相似度对称矩阵上三角元素的均值和方差。经过多次统计性实验和显著性检验后可知, 均值得分在 $[0.8, 1]$ 、方差得分在 $[0, 10^{-3}]$ 时, 说明 N 台 PMU 异常数据之间存在较高的时空相似性且波动平稳, 此时的异常数据判定为扰动。

标记检测到的扰动, 利用维纳滤波器在窗口内保留扰动的情况下滤除不良数据^[30], 最终得到平滑的扰动曲线供后续扰动分类等研究分析。

3.2 扰动检测模型结构与辨识流程

本文所提扰动检测的 CBLOF-DVAE-DKC 模型结构图如图 4 所示。具体实现步骤为:




图4 检测模型结构框图

Fig. 4 Block diagram of detection model structure

1) 获取新能源场站现场实测 PMU 频率数据, 进行数据清洗, 利用均值填补缺失值。

2) 利用 CBLOF 对输入频率数据的异常点进行检测, 将计算得到的离群因子值 p 升序排列, 利用四分位法检测异常点。同时, 对原始数据进行特征增强, 提取一阶差分、二阶差分、dTKEO、滑窗方差的特征向量, 并将其整合为维度一致的特征增强矩阵输入改进的去噪变分自编码器中; 模型利用滑窗方式计算当前窗口内的加权重构误差并和窗内实时更新的 3σ 动态阈值比较以检测异常序列。记录下所有异常点和异常序列的时标和数值。

3) 利用时空加权的动态核相关算法区分不良数据和扰动数据。结合场站内实际情况, 设置空间距离权重系数以考虑 PMU 之间电气联系, 设置时间窗权重系数以考虑时间的连续性。首先, 取第 2 步记录下的异常数据附近窗长为 0.5 s 的窗口和相邻的 N 台 PMU 进行相似度矩阵的计算。考虑到线路发生真实扰动时两端 PMU 会发生不同变化方向的响应, 所以通过绝对变化幅度计算其相关性; 进而, 计算相似度矩阵上三角元素的均值和方差; 最后, 设定均值得分区间为 $[0.8, 1]$ 、方差得分区间为 $[0, 10^{-3}]$, 若落在设定范围之内则判定为扰动, 反之视为不良数据。

4) 保留时间窗内的扰动, 利用维纳滤波器滤除不良数据, 得到场站内真实发生扰动的 PMU 平滑频率数据曲线。

漏检率和虚警率通常用来评估检测方法的优劣性。本文针对异常检测和扰动检测两个过程采用异常漏检率(anomaly miss rate, AM)、异常虚警率(anomaly false alarm, AFA)、扰动漏检率(disturbance miss rate, DM)、扰动虚警率(disturbance false alarm, DFA)、扰动检测总时长(disturbance time, DT) 5 个指标进行算法的评估^[7]。

4 仿真算例验证与分析

4.1 IEEE 39 节点仿真算例的数据集构成

为了验证所提模型对于扰动辨识的泛化性, 利用 PSCAD 平台对 IEEE 39 节点进行仿真, PMU 上送频率为 50 Hz, 仿真步长为 0.02 s。考虑新能源风电渗透率为 58.21%条件下对扰动检测的影响, 将 31、34、35、38 和 39 节点的火电机组替换为同容量的双馈风电机组。仿真生成了和有功功率相关的三相短路(three-phase short-circuit fault, 3- ϕ FIt)、单

相接地短路(single-phase ground fault, ϕ -g FIt)、发电机出力降低(generation loss, GL)、负荷投入(load switch on, L-on)、负荷切除(load switch off, L-off)、线路跳闸(line trip, LT)共 6 类扰动, 一共 6000 个扰动事件, 每类扰动各 1000 个, 以 7:3 的比例构造训练集和测试集。

4.2 异常检测与扰动检测结果分析

选取扰动数据和不良数据混合的仿真案例以验证方法的可行性, 仿真事件及其对应触发时间如表 2 所示, 仿真事件包含了三相短路(3- ϕ FIt)、发电机出力降低(GL)、负荷切除(L-off)、线路跳闸(LT)等扰动和随机出现的 PMU 不良数据。

表 2 仿真事件设置

Table 2 Settings of simulation event

窗口	仿真事件	时间段/s
1	线路 T5_8 三相短路	0—0.5
2	PMU1 出现不良数据	0.5—1
3	线路 T6_7 线路跳闸	1—1.5
4	PMU2 和 PMU5 出现不良数据	1.5—2
5	节点 36 的发电机出力降低 500 MW	2—2.5
6	切除节点 39 的负荷	2.5—3

仿真事件的异常检测结果如图 5 所示, 由图可知, 所提方法可有效检测出异常数据。




图 5 异常检测结果图

Fig. 5 Graph of anomaly detection result

仿真事件的扰动检测相似度矩阵结果如图 6 所示。




图 6 扰动检测结果图
Fig. 6 Graph of disturbance detection result
检测窗口计算的均值和方差如表 3 所示。

表 3 窗口计算结果 Table 3 Calculation result of window		
窗口	均值	方差/($\times 10^{-3}$)
1	0.978 36	0.178 9
2	0.242 59	70.551 1
3	0.980 24	0.129 3
4	0.186 99	47.128 3
5	0.988 75	0.135 9
6	0.980 88	0.226 7

从图 6 所示的相似度矩阵和表 3 计算的均值和方差可知，所提方法有效避免了不良数据对扰动的干扰，准确检测出窗口 1、3、5 和 6 为扰动事件。

4.3 不同模型的检测结果对比

为验证所提方法的可行性，在不同不良数据比例的场景下对仿真生成的 6 类扰动进行检测，将本文所提方法与现有检测方法进行评估指标的比较。

其中，LOF-Boxplot 为局部离群因子与箱线图结合的算法^[12]，MMDT 为数学形态学去噪的算法^[14]，GECNN 为基于图边缘条件卷积网络的检测方法^[17]，LSTM-DT 为长短期记忆网络与决策树结合的算法^[18]，异常检测的各指标比较结果如表 4 所示，扰动检测的各指标比较结果如表 5 所示。

表 4 异常检测评估对比

Table 4 Comparison of anomaly detection evaluation

方法	指标/%					
	不良比例 0%		不良比例 10%		不良比例 20%	
	AM	AFA	AM	AFA	AM	AFA
本文方法	0.23	0.43	0.34	0.52	0.42	0.55
LOF	0.58	0.74	0.66	0.79	0.75	0.85
MMDT	1.27	1.51	1.36	1.56	1.44	1.60
GECNN	1.61	1.62	1.69	1.66	1.75	1.84
LSTM	0.64	0.71	0.72	0.84	0.80	0.98

表 5 扰动检测评估对比

Table 5 Comparison of disturbance detection evaluation

方法	指标/%					
	不良比例 0%		不良比例 10%		不良比例 20%	
	DM	DFA	DM	DFA	DM	DFA
本文方法	1.52	2.03	2.08	2.44	2.94	3.03
LOF	1.28	2.56	4.53	7.43	7.98	12.66
MMDT	1.96	3.87	5.87	8.72	11.14	15.03
GECNN	3.04	4.22	7.42	9.53	15.94	17.45
LSTM	2.88	3.29	5.33	7.83	12.36	12.49

由表 4、5 可知，在不良数据比例为 20% 的场景下，所提方法的异常检测漏检率为 0.42%，异常检测虚警率为 0.55%。扰动检测漏检率为 2.94%，相比列举的其他方法最多可降低 13%；扰动检测虚警率为 3.03%，相比列举的其他方法最多可降低 14.42%。表明所提方法的鲁棒性和泛化性，其能够在含较高比例不良数据的情况下准确检测扰动事件。

为了验证所提方法的实时性，在 i7-12700HX 2.10 GHz CPU、NVIDA RTX3080 Ti GPU 和 64 GB 内存的计算机上进行了仿真。

表 6 给出不同方法的运行时间，所提方法处理海量数据时实时性较好，平均用时仅需 0.206 s。

表 6 不同方法的运行时间			
Table 6 Runtime of different methods			
方法	DT/s	方法	DT/s
LOF	0.196	MMDT	0.258
GECNN	0.397	LSTM	0.265
本文方法	0.206	—	—

5 基于实测数据的验证与分析

5.1 基于新能源场站的异常检测算例验证与分析

为了验证所提方法在新能源场站中进行异常检测的有效性,选择中国某新能源示范基地的风电场 2023 年 6 月 10 日 18:00—2023 年 6 月 11 日 18:00 共 24 h 79 台 PMU 现场量测频率数据进行分析,异常次数共计 3 079 次。

通过单峰单点和双峰单点数据验证 CBLOF 的性能, LOF 和 CBLOF 的点异常检测效果对比图如图 7 所示。图 7(a)为两种方法在单峰单点场景下的检测结果, LOF 和 CBLOF 均可以准确识别异常点;图 7(b)为两种方法在双峰单点场景下的检测结果, CBLOF 结合聚类信息将数据分簇,有效地识别在局部区域内看似异常但实际上属于稀少的、正常簇的点,进而降低了异常点的虚警率。




图 7 LOF 和 CBLOF 的检测效果对比图

Fig. 7 Comparison of the detection effect of LOF and CBLOF

通过单峰序列和双峰序列数据验证改进 DVAE 的性能, AE 和改进 DVAE 的序列异常检测效果对比图如图 8 所示。图 8(a)为两种方法在单峰序列场景下的检测结果, 图 8(b)为两种方法在双峰序列场景下的检测结果, 与 AE 相比, 改进后的 DVAE 可以有效检测出异常序列, 同时也降低了异常检测的漏检率和虚警率。




图 8 AE 和 DVAE 的检测效果对比图


Fig. 8 Comparison of the detection effect of AE and DVAE

分析可视化后的频率量测数据,验证了所提方法能够对时序数据的异常进行准确检测。


5.2 基于新能源场站的扰动检测算例验证与分析

本文所提方法在 24 h 内检测出 3 次扰动事件,以测风塔附近的 10 台 PMU 为例。

案例 1: 2023 年 6 月 10 日 23:58:57, PMU 同时发生频率暂降现象,扰动检测结果 1 如图 9 所示,均值为 0.983 5, 方差为 6.29×10^{-5} 。



(a) 频率量测曲线




(b) 相似度矩阵

图 9 扰动检测结果 1


Fig. 9 Result 1 of disturbance detection

案例 2: 2023 年 6 月 11 日 03:06:40, PMU 同时发生频率暂升现象,扰动检测结果 2 如图 10 所示,均值为 0.996 8, 方差为 1.16×10^{-5} 。

案例 3: 2023 年 6 月 11 日 03:04:41, PMU 同时发生频率暂降现象,扰动检测结果 3 如图 11 所




(a) 频率量测曲线




(b) 相似度矩阵

图 10 扰动检测结果 2

Fig. 10 Result II of disturbance detection



(a) 频率量测曲线



(b) 相似度矩阵

图 11 扰动检测结果 3

Fig. 11 Result III of disturbance detection

示, 均值为 0.9976, 方差为 5.7×10^{-6} 。

分析上述对应时间段内风机出力的变化曲线和风电场监测系统中储能的运行状态可知, 储能的投入和切除可引起风机有功功率对应上升和下降, 进而引起场站内部频率的上升和下降, 验证了所提方法进行扰动检测的准确性和有效性。

鉴于所提方法的特征分析全面、实时性强、占用内存小、可处理大规模复杂数据等优势, 程序将

以算子的形式被写入主站^[31], 实时监测并检测 PMU 在线数据的异常情况, 对扰动事件进行告警。

6 结论

基于示范性工程实际现场 PMU 频率量测数据出现的跳变现象, 本文提出了一种适用于新能源场站的扰动检测方法。

1) 该方法提出了改进局部离群因子算法的点异常检测方法和改进去噪变分自编码器模型的序列异常检测方法, 这一过程充分利用了现场 PMU 的数据特征, 并对原始数据进行特征增强, 提升了模型对异常数据的敏感性。

2) 提出了改进动态核相关算法的扰动检测方法, 引入了时空权重系数计算相似度矩阵, 充分考虑了现场 PMU 配置的物理位置和时间连续性的特征, 显著放大了不良数据和扰动在不同 PMU 间时空相似性方面的差异性, 降低了扰动检测的漏检率和虚警率。

3) 在仿真算例中与其他模型的对比结果表明了所提方法的优势, 在不良数据比例为 20% 的情况下, 所提方法的扰动漏检率和扰动虚警率分别为 2.94% 和 3.03%, 计算速度仅需 0.206 s, 并有效检测工程现场发生的真实扰动, 为 PMU 在新能源场站中的数据支撑应用提供了保障。

参考文献

- [1] 徐飞阳, 薛安成, 常乃超, 等. 电力系统同步相量异常数据检测与修复研究现状与展望[J]. 中国电机工程学报, 2021, 41(20): 6869-6885.
XU Feiyang, XUE Ancheng, CHANG Naichao, et al. Research status and prospects of detection, correction and recovery for abnormal synchrophasor data in power system[J]. Proceedings of the CSEE, 2021, 41(20): 6869-6885(in Chinese).
- [2] 林俊杰, 涂明权, 朱利鹏, 等. 基于时空多视图学习算法的 PMU 电压数据重构方法[J]. 中国电机工程学报, 2024, 44(24): 9533-9545.
LIN Junjie, TU Mingquan, ZHU Lipeng, et al. PMU voltage data reconstruction method based on spatiotemporal multi-view learning algorithm[J]. Proceedings of the CSEE, 2024, 44(24): 9533-9545(in Chinese).
- [3] WANG Jingyu, SHI Dongyuan, LI Yinhong, et al. Distributed framework for detecting PMU data manipulation attacks with deep autoencoders[J]. IEEE Transactions on Smart Grid, 2019, 10(4): 4401-4410.

- [4] YANG Zhiwei, LIU Hao, BI Tianshu, et al. Bad data detection algorithm for PMU based on spectral clustering[J]. *Journal of Modern Power Systems and Clean Energy*, 2020, 8(3): 473-483.
- [5] 黄子蒙, 余娟, 向明旭, 等. 基于改进动态时间弯曲的 PMU 频率异常检测及类型识别[J]. *电力系统自动化*, 2022, 46(24): 104-112.
- HUANG Zimeng, YU Juan, XIANG Mingxu, et al. Frequency anomaly detection and type identification of PMU based on improved dynamic time warping[J]. *Automation of Electric Power Systems*, 2022, 46(24): 104-112(in Chinese).
- [6] 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): 7261-7274.
- LI Zikang, LIU Hao, BI Tianshu, et al. Data-driven robust power system disturbance identification[J]. *Proceedings of the CSEE*, 2019, 41(21): 7261-7274(in Chinese).
- [7] 李子康, 刘灏, 毕天姝, 等. 考虑 PMU 数据质量问题的电力系统扰动检测方法[J]. *中国电机工程学报*, 2024, 44(2): 451-463.
- LI Zikang, LIU Hao, BI Tianshu, et al. Power system disturbance detection method considering PMU data quality problem[J]. *Proceedings of the CSEE*, 2024, 44(2): 451-463(in Chinese).
- [8] 袁翔宇, 张蓬鹤, 熊素琴, 等. 基于逻辑回归算法的异常用电辨识方法研究[J]. *电测与仪表*, 2021, 58(12): 81-87.
- YUAN Xiangyu, ZHANG Penghe, XIONG Suqin, et al. Research on identification method of abnormal power consumption based on logistic regression algorithm[J]. *Electrical Measurement & Instrumentation*, 2021, 58(12): 81-87(in Chinese).
- [9] 吴永斌, 张建忠, 邓富金, 等. 基于方差变化率判断四分位的风电场功率异常数据识别[J]. *电力工程技术*, 2023, 42(4): 141-148.
- WU Yongbin, ZHANG Jianzhong, DENG Fujin, et al. Anomaly data identification of wind power in wind farm with the criterion of variance change rate and quartile[J]. *Electric Power Engineering Technology*, 2023, 42(4): 141-148(in Chinese).
- [10] 段晨东, 张伟, 代杰. 基于随机矩阵理论的地下电缆异常检测方法研究[J]. *电气自动化*, 2021, 43(5): 115-118.
- DUAN Chendong, ZHANG Wei, DAI Jie. Research on underground cable anomaly detection method based on Random Matrix theory[J]. *Electrical Automation*, 2021, 43(5): 115-118(in Chinese).
- [11] PANDEY P, 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.
- [12] 刘灏, 朱世佳, 毕天姝. 基于局部离群因子的 PMU 连续坏数据检测方法[J]. *电力系统自动化*, 2022, 46(1): 25-32.
- LIU Hao, ZHU Shijia, BI Tianshu. Continuous bad data detection method for PMU based on local outlier factor [J]. *Automation of Electric Power Systems*, 2022, 46(1): 25-32(in Chinese).
- [13] KHALEDIAN E, PANDEY S, KUNDU P, et al. Real-time synchrophasor data anomaly detection and classification using isolation forest, Kmeans, and LoOP[J]. *IEEE Transactions on Smart Grid*, 2021, 12(3): 2378-2388.
- [14] 郝颖, 冬雷, 王丽婕, 等. 基于数学形态学去噪的光伏发电电异常数据识别算法[J]. *中国电机工程学报*, 2022, 42(21): 7843-7854.
- HAO Ying, DONG Lei, WANG Lijie, et al. An abnormal data recognition algorithm based on mathematical morphology denoising theory for PV power generation[J]. *Proceedings of the CSEE*, 2022, 42(21): 7843-7854(in Chinese).
- [15] CHENG Yuanbin, YU Nanpeng, FOGGO B, et al. Online power system event detection via bidirectional generative adversarial networks[J]. *IEEE Transactions on Power Systems*, 2022, 37(6): 4807-4818.
- [16] LIU Guohong, LI Xiaomeng, WANG Cong, et al. Hessian locally linear embedding of PMU data for efficient fault detection in power systems[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3502704.
- [17] CHEN Bairen, WU Q H, LI Mengshi, et al. Detection of false data injection attacks on power systems using graph edge-conditioned convolutional networks[J]. *Protection and Control of Modern Power Systems*, 2023, 8(2): 1-12.
- [18] 杨智伟, 刘灏, 毕天姝, 等. 基于长短期记忆网络的 PMU 不良数据检测方法[J]. *电力系统保护与控制*, 2020, 48(7): 1-9.
- YANG Zhiwei, LIU Hao, BI Tianshu, et al. PMU bad data detection method based on long short-term memory network[J]. *Power System Protection and Control*, 2020, 48(7): 1-9(in Chinese).
- [19] ATTESTOG S, SENANAYAKA J S L, VAN KHANG H, et al. Robust active learning multiple fault diagnosis of PMSM drives with sensorless control under dynamic operations and imbalanced datasets[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(9): 9291-9301.
- [20] LIU Jie, CAO Yijia, LI Yong, et al. Big data cleaning based on improved CLOF and random forest for distribution networks[J]. *CSEE Journal of Power and Energy Systems*, 2024, 10(6): 2528-2538.
- [21] 杨锡运, 刘玉奇, 李建林. 基于四分位法的含储能光伏电站可靠性置信区间计算方法[J]. *电工技术学报*, 2017,

- 32(15): 136-144.
- YANG Xiyun, LIU Yuqi, LI Jianlin. Reliability confidence interval calculation method for photovoltaic power station with energy storage based on quartile method[J]. Transactions of China Electrotechnical Society, 2017, 32(15): 136-144(in Chinese).
- [22] FAN Miao, LI Zhengshuo, DING Tao, et al. Uncertainty evaluation algorithm in power system dynamic analysis with correlated renewable energy sources[J]. IEEE Transactions on Power Systems, 2021, 36(6): 5602-5611.
- [23] 邢超, 王朋林, 赵四洪, 等. 基于线模反行波一阶差分的多端柔性直流线路单端方向保护[J/OL]. 电网技术, 2025[2025-04-13]. <http://kns.cnki.net/kcms/detail/11.2410.TM.20250314.1502.002.html>.
- XING Chao, WANG Penglin, ZHAO Sihong, et al. Single-ended directional protection of multi-terminal flexible DC lines based on first-order difference of linear mode inverse traveling wave[J/OL]. Power System Technology, 2025[2025-04-13]. <http://kns.cnki.net/kcms/detail/11.2410.TM.20250314.1502.002.html>(in Chinese).
- [24] 王程, 吴科宏, 贾起越, 等. 基于显式差分的区域电气综合能源系统动态能流计算方法[J]. 中国电机工程学报, 2022, 42(16): 5775-5785.
- WANG Cheng, WU Kehong, JIA Qiyue, et al. An explicit difference based calculation method for dynamic energy flow of integrated electric-gas systems[J]. Proceedings of the CSEE, 2022, 42(16): 5775-5785(in Chinese).
- [25] LIU Decheng, WANG Min, CHEN Maoyin. Feature ensemble net: a deep framework for detecting incipient faults in dynamical processes[J]. IEEE Transactions on Industrial Informatics, 2022, 18(12): 8618-8628.
- [26] 张译丹, 李奇, 尹良震, 等. 引入自监督机制的燃料电池水管理系统健康状态检测方法[J]. 中国电机工程学报, 2023, 43(13): 5025-5036.
- ZHANG Yidan, LI Qi, YIN Liangzhen, et al. A health state detection method of fuel cell water management system with the introduction of self-supervision mechanism[J]. Proceedings of the CSEE, 2023, 43(13): 5025-5036(in Chinese).
- [27] 齐子豪, 仝杰, 张中浩, 等. 基于多粒度知识特征和Transformer网络的电力变压器故障声纹辨识方法[J]. 中国电机工程学报, 2025, 45(4): 1311-1322.
- QI Zihao, TONG Jie, ZHANG Zhonghao, et al. A voiceprint classification method for power transformer fault identification based on multi-granularity knowledge features and transformer network[J]. Proceedings of the CSEE, 2025, 45(4): 1311-1322(in Chinese).
- [28] 黄南天, 王文婷, 蔡国伟, 等. 计及复杂气象耦合特性的模块化去噪变分自编码器多源-荷联合场景生成[J]. 中国电机工程学报, 2019, 39(10): 2924-2933.
- HUANG Nantian, WANG Wenting, CAI Guowei, et al. The joint scenario generation of multi source-load by modular denoising variational autoencoder considering the complex coupling characteristics of meteorology[J]. Proceedings of the CSEE, 2019, 39(10): 2924-2933(in Chinese).
- [29] 郑天, 李峰, 罗印升, 等. 基于高斯核函数的Hammerstein非线性系统辨识[J]. 控制工程, 2022, 29(11): 2034-2041.
- ZHENG Tian, LI Feng, LUO Yinsheng, et al. Identification of Hammerstein nonlinear system based on Gaussian kernel functions[J]. Control Engineering of China, 2022, 29(11): 2034-2041(in Chinese).
- [30] YUAN Hai, LU Lu, ZHU Guangya, et al. Bias-compensated normalized iterative wiener filter algorithm with noisy input[J]. IEEE Signal Processing Letters, 2025, 32: 1445-1449.
- [31] LIU Hao, BI Tianshu, XU Sudi, 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.



廖梦竹

在线出版日期: 2025-09-05.

收稿日期: 2025-06-16.

作者简介:

廖梦竹(2001), 女, 硕士研究生, 研究方向为基于数据驱动的电力系统扰动辨识, mzliao15395310095@163.com;

*通信作者, 刘灏(1985), 男, 教授, 博士生导师, 研究方向为同步相量测量技术及其应用等, hliu@ncepu.edu.cn;

毕天姝(1973), 女, 教授, 博士生导师, 研究方向为电力系统保护与控制、广域同步相量测量技术及应用等, tsbi@ncepu.edu.cn.

(责任编辑 吕鲜艳)