

基于时空多视图学习算法的 PMU 电压数据重构方法

林俊杰¹, 涂明权¹, 朱利鹏², 宋文超³, 陆超^{3*}

- (1. 福州大学电气工程与自动化学院, 福建省福州市 350108; 2. 湖南大学电气与信息工程学院, 湖南省长沙市 410082; 3. 新型电力系统运行与控制全国重点实验室(清华大学电机工程与应用电子技术系), 北京市海淀区 100086)

PMU Voltage Data Reconstruction Method Based on Spatiotemporal Multi-view Learning Algorithm

LIN Junjie¹, TU Mingquan¹, ZHU Lipeng², SONG Wenchao³, LU Chao^{3*}

- (1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, Fujian Province, China;
2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, Hunan Province, China;
3. State Key Laboratory of Power System Operation and Control (Department of Electrical Engineering, Tsinghua University), Haidian District, Beijing 100086, China)

ABSTRACT: Phasor measurement units (PMU) have the advantages of good synchronization, high resolution, direct phase angle measurement, etc. It is an important information source for realizing on-line real-time state perception of power systems. However, due to the influence of equipment failure, climate interference, communication problems and other factors, PMU data in the actual power grid are prone to data loss and anomalies, which will interfere with the subsequent advanced power grid applications based on PMU data, thereby affecting the reliability of power grid state perception and operation scheduling. Four kinds of low-quality data are summarized by analyzing the PMU data measured in the field, and the operating state of the system is identified by using mechanism analysis and correlation analysis methods. Then, combining the multi-view learning method with the power grid operation mechanism, a preliminary multi-view data reconstruction algorithm based on spatio-temporal information feature fusion is proposed to reconstruct the low-quality and missing PMU data. Finally, according to the characteristics of different running states of the system, the low quality data are identified by using different views to generate data, and an adaptive weighted missing data reconstruction method based on historical data is proposed. Simulation and measured data show that this method can effectively identify and reconstruct

PMU low quality data in real time, which provides effective guarantee for the application of PMU data in power systems.

KEY WORDS: phasor measurement unit data; low quality data; system running status identification; multi-view-based learning method; data reconstruction

摘要: 同步相量测量装置(phasor measurement unit, PMU)具有同步性好、分辨率高、相角直接可测等优点,是实现电力系统在线实时状态感知的重要信息源。然而,由于受到设备故障、气候干扰、通信问题等因素影响,实际电网中的PMU数据容易出现数据缺失和异常等情况,这将干扰后续基于PMU数据的电网高级应用,进而影响电网状态感知和运行调度的可靠性。首先,通过分析现场实测的PMU数据,归纳出4种低质量数据情况,并且利用机理分析和相关性分析方法对系统运行状态进行辨识;然后,将多视图学习方法与电网运行机理相结合,提出基于时空信息特征融合的多视图数据初步重构算法,对PMU低质量和缺失数据进行重构;最后,结合系统不同运行状态特点,利用不同视图生成数据进行低质量数据的辨识,并提出一种基于历史数据的自适应加权的缺失数据重构方法。仿真和实测数据表明该方法能有效对PMU低质量数据进行辨识并实时重构生成,为PMU数据在电力系统中的应用提供有效保障。

关键词: 同步相量测量数据; 低质量数据; 系统运行状态辨识; 多视图学习法; 数据重构

基金项目: 福建省自然科学基金项目(2021J05134); 新型电力系统运行与控制全国重点实验室开放基金课题(SKLD23KZ06)。

Natural Science Foundation of Fujian Province (2021J05134); State Key Laboratory of Power System Operation and Control (SKLD23KZ06).

0 引言

近年来,同步相量测量装置(phasor

measurement unit, PMU)在实际电网中得到了广泛的部署和应用,较之传统的数据采集与监视控制系统(supervisory control and data acquisition, SCADA)它具有精度高、全网严格同步、更新周期短等优点,能够实现节点状态的直接测量^[1],为实现十毫秒级别的电力系统实时全局状态感知和运行控制分析提供了基础支撑。以我国电网为例,各电网公司已部署超过4000套PMU装置,覆盖500kV及以上主干输电网及重要的220kV厂站和线路^[2],同时也逐步在配电网中应用^[3]。虽然PMU已经得到了广泛部署,但是PMU的数据质量问题制约着PMU的进一步应用。同步相量测量值受电压/电流互感器(PT/CT)误差以及PMU本身测量影响,存在着一定的测量误差。在实际电网中,PMU数据的现场测量环境往往比室内仿真/试验条件复杂恶劣,同时现场PMU的运行和维护状况往往不尽如人意,导致PMU测量经常不可避免地会出现较大的测量误差和不良数据。相关的测试结果表明,部分PMU对于包含动态信息的复杂信号不能准确进行相量计算,有可能产生大误差或者不良数据^[4],而现场PMU的稳态测量准确度测试也发现幅值和相角误差可能分别高达2%和 1.5° ^[5],远超过国标所规定的标准范围^[6-7]。由于缺乏基于PMU的系统级功能,在实际电网中应用场景较少,缺乏有效的维护,导致现有PMU测量数据的准确性、可靠性和完备性不足。若无法改善其数据质量问题,PMU可能边缘化为高级的电网“记录仪”,甚至是不准确的记录仪,如何提升PMU的数据质量已经成为了PMU进一步推广应用待解决的重要问题。

目前对PMU测量数据质量提升也有较多的研究,最为普遍的是传统的状态估计类方法,其代表性算法是最小二乘类算法^[8],通过电力系统的网络模型约束,利用测量的冗余提升数据质量,但是其对可观性要求高,容易受到网络模型参数不确定的影响,且对不良数据也较为敏感,因此在复杂情况下,状态估计的效果有效^[9]。另一方面,基于数据驱动的数据辨识与重构,以提升数据质量的方法也被广泛研究。对在稳态下的坏数据,许多研究采取插值法进行数据重构。文献[10]基于拉格朗日插值进行PMU数据重构;文献[11]通过改进三次样条插值函数,利用插值区间动态变化的优先级分配策略来对不同类型的缺失数据进行重建。上述两种方法仅需单通道设备数据,但是由于蕴含信息有限,不

适用于暂态情况和长时间的连续低质量数据重构。为此,学者们提出了在区域层级的低质量数据重构研究,现有的研究方法多集中于矩阵低秩特性和机器学习方向^[12]。文献[13]基于PMU量测矩阵低秩特性,通过低秩矩阵中的奇异值阈值法进行数据重构;文献[14]对其改进,可以对长时间连续低质量PMU量测进行实时在线数据重构。但上述方法无法在全部通道数据丢失的情况下进行PMU数据重构。对此,文献[15]基于交替方向乘子法的恢复方法来对全部通道PMU数据进行数据重构,缺点是计算时间较长,难以应用于实时态势感知。除此之外,机器学习方法中的神经网络和集成学习在PMU量测数据重构中也得到了广泛研究。文献[16]基于图卷积递归神经网络方法,通过训练挖掘数据的时空关联来恢复和预测PMU量测;文献[17-18]则基于改进生成式对抗网络方法进行PMU数据重构,通过对区域量测数据训练挖掘得到时空信息来实现。然而机器学习方法需要大量的离线训练,并且对PMU实时量测数据蕴含的时空信息提取得不够充分,容易出现过拟合、泛化能力不足等问题。此外,文献[19]基于鲁棒主成分分析法来实现数据重构,但异常事件产生的干扰数据会被误判为低质量数据而被错误重构;对此,文献[20]基于核主成分分析法,通过对扰动事件进行检测从而避免误判。

为了充分利用电力系统量测数据本身所蕴含的时序性、空间性信息,提升PMU测量数据质量,本文提出了基于时空多视图学习算法的PMU电压数据重构方法:首先,提出基于时空信息特征的多维视图学习方法,构建时空的全局与局部多维视图算法生成初步的重构值;此外,结合系统不同运行状态特点对4种具有时空信息特征视图的方法进行融合,在对低质量数据辨识的基础上,实现对PMU量测缺失数据准确可靠的重构生成。

1 PMU低质量数据分类

在实际电力系统中,由于设备故障、通信阻塞、气候变化等因素的影响下,导致PMU数据出现缺失或异常情况频发,产生跳变、偏差等不良数据,本文将这些缺失数据跟不良数据点统称为低质量数据。PMU数据中大部分低质量数据为单点随机情况,偶尔会发生长时间连续低质量数据的情况^[21]。针对于不同数据低质量情况,如图1所示,归分为以下4种:单点稳态、单点暂态、连续多点

稳态和连续多点暂态。为了使依赖于 PMU 量测数据的电力系统高级应用可以安全可靠地运行，有必要辨识并剔除量测数据中的低质量数据，同时为了保证测量集的完备性，需要进一步对缺失的测量数据进行重构，以弥补缺失的测量数据。

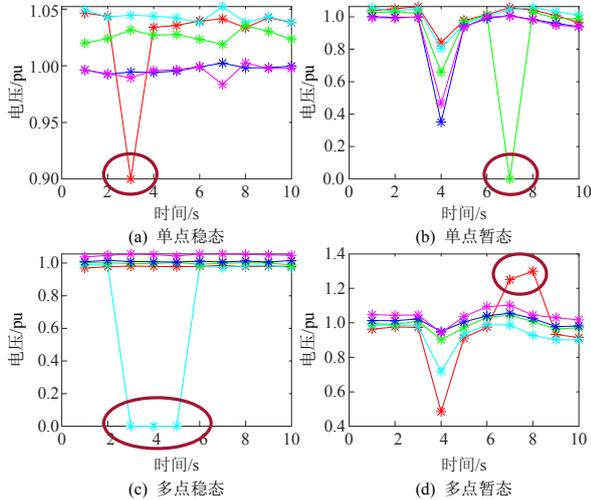


图 1 4 种 PMU 低质量数据情况图

Fig. 1 Four PMU low quality data situation graph

2 系统运行状态辨识

在对低质量数据进行重构之前，为避免系统突变影响低质量数据的辨识与重构，需要对电力系统的运行进行辨识分析。系统在发生突变后，会经过一段时间的暂态，才可以过渡到稳态阶段。在暂态阶段，数据波动性大，为此通过系统暂稳态辨识来判别出低质量数据所处运行阶段，针对性地进行数据重构。因此，本文首先提出基于机理分析与数据相关性分析的系统突变与暂稳态辨识方法。

2.1 系统突变辨识(系统由稳态进入暂态)

假设在区域电网的 n 个节点上装配有 PMU，其中某个节点最新时刻 t 的数据 y_t ，与上一时刻的数据 y_{t-1} 之间差值的绝对值为 ε ：

$$\varepsilon = |y_t - y_{t-1}| \quad (1)$$

当差值 ε 超过正常范围，意味着系统发生异常事件或者出现低质量数据。当系统发生异常事件时，配有 PMU 的 n 个节点差值的平均数和中位数都会发生显著改变；当出现低质量数据时，仅有平均数会发生显著改变。因此，得出系统突变检测公式如下：

$$\theta_t = \begin{cases} 1, & \varepsilon_{\text{mean}} > E_{\text{mean}} \text{ 且 } \varepsilon_{\text{median}} > E_{\text{median}} \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中：当 $\theta=1$ 时表示系统在 t 时刻发生突变， $\theta=0$

时不发生； $\varepsilon_{\text{mean}}$ 与 $\varepsilon_{\text{median}}$ 表示 n 个节点差值的平均数和中位数； E_{mean} 与 E_{median} 表示差值平均数与中位数的阈值，其是结合电网的实际情况和充分仿真验证后确定的经验性参数，并且由于电力系统中标幺值的使用和对电压波动容忍度的一致性，使得其具有较好的泛用性。

2.2 系统暂稳态辨识法(系统由暂态回到稳态)

暂态阶段相邻节点测量值会出现同向波动，此时两节点测量值相关性大幅提高，随着向稳态过渡，相关性下降；当暂态波动结束，不再出现同向波动，仅存在不确定误差，此时两节点测量值相关性降至最低。斯皮尔曼等级相关系数法对于带有异常值的数据具有较强的鲁棒性^[22]，为此运用以下公式来计算相邻节点间的相关性系数 ρ ：

$$\rho = 1 - (6 \sum_{t=j-T}^j r_t^2) / [T(T^2 - 1)] \quad (3)$$

式中： T 为选取的数据长度； r_t 为在 t 时刻相邻节点两端测量值的等级差，其中等级指变量按大小顺序排列后的位置。

同时，为了减小随机性，将区域内的各支路两端间的相关性系数 ρ 累加后求平均值：

$$\rho_{\text{mean}} = (\sum_{H=1}^h \rho_H) / h \quad (4)$$

式中： ρ_{mean} 为 h 个支路的平均相关系数； ρ_H 为第 H 个支路两端间的相关性系数。

对于 ρ_{mean} ，0~0.09 为没有相关性，0.1~0.3 为弱相关，0.3~0.5 为中等相关，0.5~1.0 为强相关^[23]。为此，设置如下判别式：

$$S_t = \begin{cases} 1, & \rho_{\text{mean}} \geq 0.1 \\ 0, & \rho_{\text{mean}} < 0.1 \end{cases} \quad (5)$$

式中 S_t 为 t 时刻系统运行所处状态，当 $S_t=1$ 时为系统暂态过渡阶段；当 $S_t=0$ 时为系统稳定阶段。

3 时空多视图学习算法

电力系统网络中，不同厂站之间通过输电线路传送功率，存在着电气的直接连接，使得电力系统的节点状态与相邻节点存在着显著的相关性，因此电力系统的空间相关性主要是由输电线路的电气耦合关系和特征参数所决定。如图 1 的单点暂态图，在时间 $t=4\text{s}$ 时，系统发生了暂态过程，可以看到所有节点在该阶段都产生了极其一致的凹陷变化，表明在区域电网中各节点存在着较强的空间相关性。同时也可以直接通过输电线路的正弦稳态二端口

网络方程来表达出相邻节点空间上的联系^[24]:

$$\begin{bmatrix} \dot{U}_1(t) \\ \dot{I}_1(t) \end{bmatrix} = \begin{bmatrix} \text{ch}\gamma l & Z_c \text{sh}\gamma l \\ (1/Z_c) \text{sh}\gamma l & \text{ch}\gamma l \end{bmatrix} \begin{bmatrix} \dot{U}_2(t) \\ \dot{I}_2(t) \end{bmatrix} \quad (6)$$

式中: γ 为传输线的传播常数; l 为传输线的线长; Z_c 为传输线的特性阻抗。式(6)表明,在任意时刻 t ,电力系统中任意相邻节点的量测数据存在线性关系,具有空间上的相关性。

同时,由于电力系统是带有强惯性的动态系统,电力系统中以发电机为代表的众多元件都是动态元件,这些元件根据输入和历史状态做出响应,使得电力系统的当前时刻的状态与之前时刻的状态紧密相关,系统状态存在着强烈的时间相关性。在一定的时间窗口 T_{win} 内,单通道 PMU 设备上输出的连续量测数据具有时间上的相关性。给定采样时间间隔 ΔT ,利用 x 来替代诸如节点电压幅值 V 、节点电压相角 θ 等特定类型的测量数据,其在时间窗口 T_{win} 内的量测矩阵 \mathbf{X} 表示为:

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_n]^T, 1 \leq i \leq n \quad (7)$$

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad (8)$$

式中: $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{im}]$ 为有关节点 i 的连续测量数据; $m = T_{\text{win}}/\Delta T$ 为在滑动时间窗口中的采样点总数。

因此,文中提出基于多视图学习(multi-view-based learning, MVL)的基本思想实现 PMU 低质量量测的数据重构^[25]。利用各节点 PMU 最新测量数据以及其前面一定时间窗口 T_{win} 内的量测数据来生成 4 个互补的时空信息视图,接下来将对所提方法展开详细介绍。

3.1 全局时间视图(global temporal view, GTV)

GTV 数据重构法提取量测上的时序性,基于指数平滑法进行构建^[26]。如图 2 所示, x_{ij} 为在 \mathbf{X} 中 i 节点、 j 时刻上的低质量目标数据,挑选其之前 m_{gt} 个连续时间节点数据组成一个时间长序列 \mathbf{x}_i^G :

$$\mathbf{x}_i^G = [x_{i(j-m_{\text{gt}})}, x_{i(j-m_{\text{gt}}+1)}, \dots, x_{i(j-1)}] \quad (9)$$

基于该时间长序列,对 x_{ij} 计算得到 GTV 重构值 x_{ij}^{gtv} :

$$x_{ij}^{\text{gtv}} = \left[\sum_{t=j-m_{\text{gt}}}^{j-1} x_{it} \alpha (1-\alpha)^{j-t-1} \right] / \left[\sum_{t=j-m_{\text{gt}}}^{j-1} \alpha (1-\alpha)^{j-t-1} \right] \quad (10)$$

式中: x_{it} 为在节点 i 的 t 时刻的数据; $\alpha \in (0,1)$ 为指

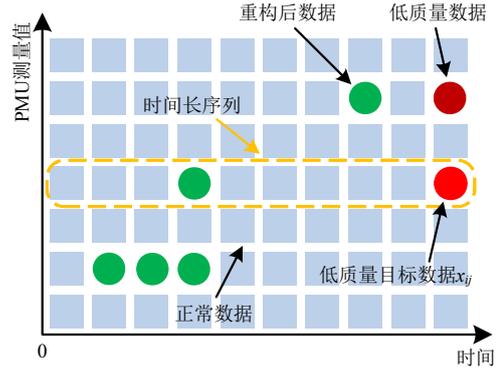


图2 全局时间视图

Fig. 2 Global temporal view

数平滑法里的平滑参数,在 GTV 法中基于 x_{it} 与目标数据 x_{ij} 的距离大小,通过 $\alpha(1-\alpha)^{j-t-1}$ 分配权重。

为保证 GTV 法能够依据时间序列的阶段性特点实时变化,设置 α 为自适应选取^[27]。通过利用 j 时刻之前的一系列预测值与量测值的综合预测误差 E_j 来决定 α :

$$E_j = \beta e_{j-1} + (1-\beta)E_{j-1} \quad (11)$$

式中: β 设置为 0.1,作为 α 的初值; e_{j-1} 为在 $j-1$ 时刻的预测误差。同时,由于 $\alpha \in (0,1)$,故需要对 E_j 做归一化处理:

$$M_j = \beta |e_{j-1}| + (1-\beta)M_{j-1} \quad (12)$$

$$\alpha_j = |E_j| / M_j \quad (13)$$

式中 M_j 为绝对平滑误差。

3.2 全局空间视图(global spatial view, GSV)

GSV 数据重构法受到地理科学中空间内插法的启发,基于反距离加权法(inverse distance weight, IDW)实现的^[28]。由于电网各节点之间的电气距离是通过等效阻抗作为量化参数,因此通过给定的整个区域系统的导纳矩阵 \mathbf{Y}_{all} 来得到阻抗矩阵 $\mathbf{Z}_{\text{all}} = \mathbf{Y}_{\text{all}}^{-1}$ ^[29]。再从中挑选出装有 PMU 的 n 个相关节点的行与列,组成较小的阻抗矩阵 $\mathbf{Z}_{n \times n}^{\text{PMU}}$ 。利用 $\mathbf{Z}_{n \times n}^{\text{PMU}}$ 计算出各节点之间的电气距离:

$$d_{ik} = |(z_{ii} - z_{ik}) - (z_{ki} - z_{kk})|^2, 1 \leq i, k \leq n \quad (14)$$

式中: d_{ik} 为节点 i 与节点 k 之间的电气距离; z_{ik} 为在 $\mathbf{Z}_{n \times n}^{\text{PMU}}$ 里节点 i 与节点 k 之间的阻抗。接着进行归一化处理:

$$D_{ik} = \frac{d_{ik}}{\max_{1 \leq u, v \leq n} d_{uv}} \quad (15)$$

式中 D_{ik} 为归一化后的节点 i 与节点 k 之间的电气距离。 n 个节点之间可以两两计算出 D 值,组成一个空间距离矩阵 $\mathbf{D} = [D_{ik}]_{n \times n}$ 。

如图 3 所示, 利用低质量目标数据 x_{ij} 同一时刻 j 上的其他节点数据, 组成一个空间长序列 \mathbf{x}_j^G :

$$\mathbf{x}_j^G = [x_{1j}, x_{2j}, \dots, x_{(i-1)j}, x_{(i+1)j}, \dots, x_{nj}] \quad (16)$$

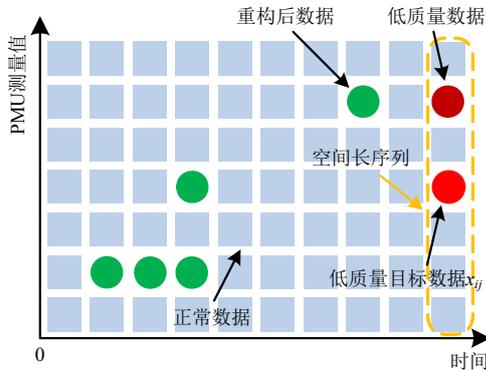


图 3 全局空间视图

Fig. 3 Global spatial view

基于该空间长序列, 对 x_{ij} 计算得到 GSV 重构值 x_{ij}^{GSV} :

$$x_{ij}^{\text{GSV}} = \frac{1}{\sum_{k=1}^n (D_{ki})^{-1}} \sum_{k=1}^n x_{kj} (x_{i(j-1)} / x_{k(j-1)}) (D_{ki})^{-1} \quad (17)$$

式中利用 $j-1$ 时刻 $x_{i(j-1)} / x_{k(j-1)}$ 得到的比值对 x_{kj} 进行调整, 得到 x_{ij} 的预估值, 接着基于 IDW 方法, 通过 D 来分配权重。在同一时刻多个节点上可能同时出现低质量数据, 对此, 可先将所有 t 时刻上的低质量数据用上一刻的数据进行代替, 再使用 GSV 法结果进行逐一替换。

3.3 局部时间视图(local temporal view, LTV)

LTV 数据重构法是基于相关相似性方法建立的^[30]。即某区域内的节点 k 在 $t \in (j-m_{lt}, j-1)$ 时刻得到的测量值 x_{kt} 与其在 j 时刻得到的测量值 x_{kj} 之间的相似度 s_{kt}^k , 跟同区域内的节点 i 在 t 时刻的测量值 x_{it} 与其在 j 时刻得到的测量值 x_{ij} 之间的相似度 s_{jt}^i 是具有相关相似性的。对此, 如图 4 设置局部时空

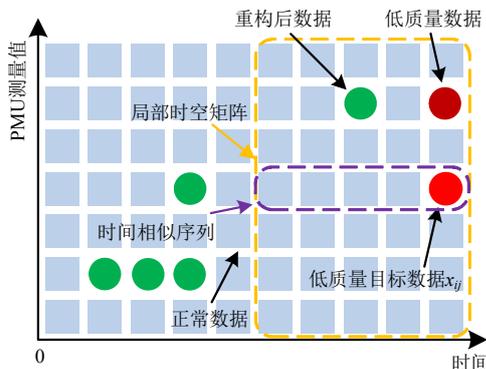


图 4 局部时间视图

Fig. 4 Local temporal view

矩阵 \mathbf{X}_L :

$$\mathbf{X}_L = \begin{bmatrix} x_{1(j-m_{lt})} & x_{1(j-m_{lt}+1)} & \cdots & x_{1j} \\ x_{2(j-m_{lt})} & x_{2(j-m_{lt}+1)} & \cdots & x_{2j} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n(j-m_{lt})} & x_{n(j-m_{lt}+1)} & \cdots & x_{nj} \end{bmatrix} \quad (18)$$

为重构低质量目标数据 x_{ij} , 利用 \mathbf{X}_L 中其他节点在 t 时刻对于 j 时刻的测量值相似度 s_{jt}^k , 在 i 节点上生成平均相似度 S_{jt}^i :

$$S_{jt}^i = 1 / \sqrt{\frac{\sum_{k=1, k \neq i}^n s_{jt}^k}{n-1}} = 1 / \sqrt{\frac{\sum_{k=1, k \neq i}^n (x_{kj} - x_{kt})^2 (x_{it} / x_{kt})^2}{n-1}} \quad (19)$$

如图 4 所示, 在 x_{ij} 前的 m_{lt} 个连续时间节点数据处各自生成 S_{jt}^i , 组合形成一个时间相似序列, 用于为 x_{it} 赋权重值, 借此对 x_{ij} 计算得到 LTV 重构值 x_{ij}^{LTV} :

$$x_{ij}^{\text{LTV}} = \left(\sum_{t=j-m_{lt}}^{j-1} x_{it} S_{jt}^i \right) / \left(\sum_{t=j-m_{lt}}^{j-1} S_{jt}^i \right) \quad (20)$$

3.4 局部空间视图(local spatial view, LSV)

LSV 数据重构法的推算方法与 LTV 相似, 利用在 $t \in (j-m_{lt}, j-1)$ 时刻里, 节点 k 对于节点 i 上测量值的相似度 s_{ik}^t , 在 j 时刻上生成平均相似度 S_{ik}^j :

$$S_{ik}^j = 1 / \sqrt{\frac{\sum_{t=j-m_{lt}}^{j-1} s_{ik}^t}{m_{lt}}} = 1 / \sqrt{\frac{\sum_{t=j-m_{lt}}^{j-1} (x_{kj} - x_{kt})^2}{m_{lt}}} \quad (21)$$

如图 5 所示, 在 x_{ij} 同一时刻 j 上的其他节点数据处各自生成 S_{ik}^j , 组合形成一个空间相似序列, 用于为 x_{kj} 赋权重值, 借此对 x_{ij} 计算得到 LSV 重构值 x_{ij}^{LSV} :

$$x_{ij}^{\text{LSV}} = \left[\sum_{k=1, k \neq i}^n x_{kj} (x_{i(j-1)} / x_{k(j-1)}) S_{ik}^j \right] / \left(\sum_{k=1, k \neq i}^n S_{ik}^j \right) \quad (22)$$

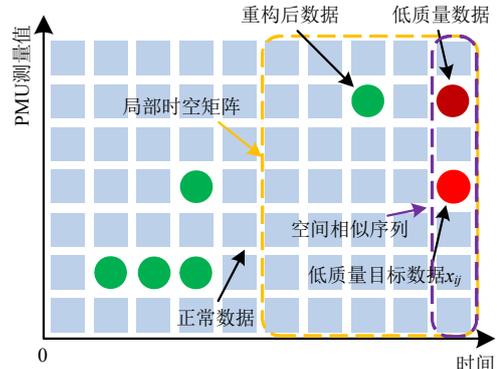


图 5 局部空间视图

Fig. 5 Local spatial view

4 PMU量测数据辨识与重构方法

本文所提的多视图学习方法能基于区域内的各PMU设备量测数据在一定时间范围内表现出来的时空相关性,通过对量测数据时空信息特征的提取实现缺失数据的初步重构。利用数据重构值,可以对量测进行低质量数据检测与辨识,并且构建时空信息特征融合的全局与局部多维视角下的时空MVL数据重构方法。

4.1 低质量数据辨识

由于系统暂稳态阶段下的数据波动性的不同,因此针对不同系统运行状态下的测量数据采用不同的低质量数据辨识方法。

PMU数据分辨率高,其采样时间短,因此需要快速准确地进行低质量数据的检测与辨识。而在所提的4种时空MVL算法中,GTV法以及GSV法分别对于稳态阶段和暂态阶段下的预测效果良好。因此,当对PMU测量数据进行实时低质量数据检测时,可利用GTV法和GSV法分别在稳态阶段和暂态阶段下的预测值 x_{ij}^{gtv} 、 x_{ij}^{gsv} 与测量值 x_{ij} 之间的误差大小进行检测,具体如下:

$$\phi_{ij} = \begin{cases} 1, & \text{当 } S_t = 0 \text{ 且 } |x_{ij}^{gtv} - x_{ij}| > \varphi_{gtv} \text{ 时,} \\ & \text{或者 } S_t = 1 \text{ 且 } |x_{ij}^{gsv} - x_{ij}| > \varphi_{gsv} \text{ 时} \\ 0, & \text{当 } S_t = 0 \text{ 且 } |x_{ij}^{gtv} - x_{ij}| < \varphi_{gtv} \text{ 时,} \\ & \text{或者 } S_t = 1 \text{ 且 } |x_{ij}^{gsv} - x_{ij}| < \varphi_{gsv} \text{ 时} \end{cases} \quad (23)$$

式中: $\phi_{ij}=1$ 时表示在 j 时刻 i 节点上出现低质量数据, $\phi_{ij}=0$ 时表示数据正常; φ_{gtv} 与 φ_{gsv} 分别表示GTV法与GSV法预测结果与测量值残差的阈值,通过对量测数据充分仿真验证得出。

4.2 时空信息特征融合模型

电力系统由于电气连接的约束以及元件的特性,存在着显著的时间和空间分别性,只利用单独断面的测量信息和线路参数线性无法充分表征电力系统的全局时空信息特征。为此,本文利用线性组合的方法整合所提时空MVL方法生成的4种初步重构值,完成基于时空信息特征融合模型(spatial and temporal information feature fusion model, STIFFM)的低质量数据精确重构方法。

为了保证对误差绝对值较小即预测精度较高的方法赋予较大的权重,采用了误差倒数变权组合预测方法来确定4种时空MVL算法各自的权重 $w^{[31]}$ 。具体地,通过周期性的抓取一段时间窗口内

的非低质量数据进行在线计算,求出4种时空MVL算法在暂稳态阶段下各自的总体误差 L ,再对 L 取倒数后进行归一化处理,用以自适应更新4种算法初步重构值各自的权重 w :

$$L = \sum_{s=1}^S |\tilde{x}_s - x_s| \quad (24)$$

$$w_i = \frac{L_i^{-1}}{L_1^{-1} + L_2^{-1} + \dots + L_n^{-1}} \quad (25)$$

式中: \tilde{x} 为4种算法重构值; x 为非低质量数据; S 为抓取的数据个数。

电力系统不同运行状态下的PMU测量值具有各自的数据特点,因此需要分别对暂稳态两种阶段下时空MVL中的4种算法重构值的权重进行计算更新。当电网整体出现连续剧烈变化时,如发生短路故障,PMU量测数据时间上的关联性会变得很低,基于时间相关性的GTV、LTV重构效果会变差,但是基于空间上的GSV、LSV方法可以正常运行,在整体重构效果略微降低的情况下,仍然可以有效地实现低质量数据的准确重构。为此在系统处于暂态过程中仅采取空间法GSV、LSV来进行组合重构。

因此,本文所构建的STIFFM精确数据重构公式如下:

$$\hat{x}_{ij} = \begin{cases} x_{ij}^{gsv} w_{gsv1} + x_{ij}^{lsv} w_{lsv1} & , S_t = 1 \\ x_{ij}^{gtv} w_{gtv0} + x_{ij}^{gsv} w_{gsv0} + x_{ij}^{ltv} w_{ltv0} + x_{ij}^{lsv} w_{lsv0} & , S_t = 0 \end{cases} \quad (26)$$

式中: \hat{x}_{ij} 为STIFFM得出的精确数据重构值; w_{gsv1} 、 w_{lsv1} 分别为GSV、LSV法在 $S_t=1$ 系统暂态过渡阶段下各自的权重; w_{gtv0} 、 w_{gsv0} 、 w_{ltv0} 、 w_{lsv0} 分别为GTV、GSV、LTV、LSV法在 $S_t=0$ 系统稳定阶段下各自的权重。

4.3 算法架构以及讨论

综上所述,对PMU低质量量测数据进行辨识与重构的算法具体流程如图6所示,该算法的具体步骤如下:

- 1) 输入历史测量数据对GTV、GSV、LTV、LSV在暂稳态下的权重值 w 进行初始化;
- 2) 输入最新时刻的PMU量测数据,以及该时刻之前一段时间内的数据,用于计算差值平均数 $\varepsilon_{\text{mean}}$ 和中位数 $\varepsilon_{\text{median}}$,以及计算出区域内的各支路的平均相关系数 ρ_{mean} ,用于对系统运行状态的辨识;
- 3) 输入GTV法里的时间长序列 x_i^G 和GSV法

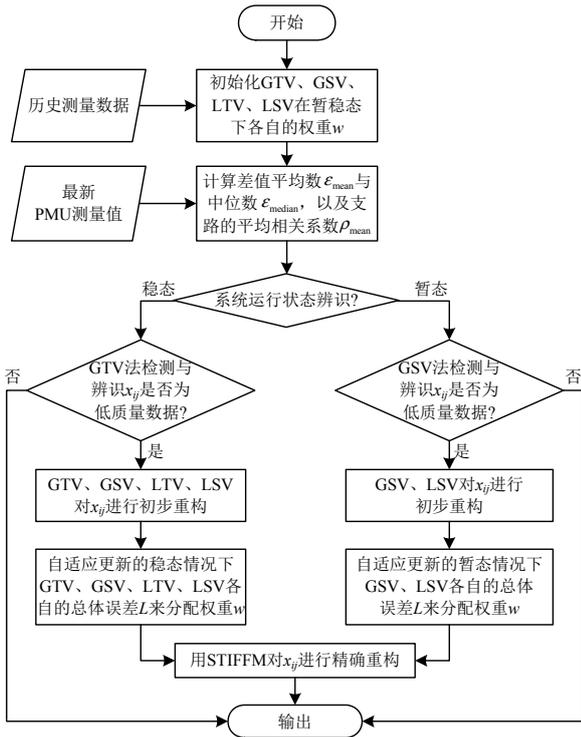


图 6 PMU 低质量数据重构算法流程图

Fig. 6 Flowchart of

PMU low-quality data reconstruction algorithm

里的空间长序列 x_j^G 上的量测数据, 用于检测在暂稳态情况下 x_{ij} 是否为低质量数据;

4) 在检测出 x_{ij} 为低质量数据后, 需要利用时空 MVL 算法中的 GTV、GSV、LTV、LSV 对 x_{ij} 进行初步重构。输入 GTV 法里的时间长序列 x_i^G 、GSV 法里的空间长序列 x_j^G 、LTV 和 LSV 法里的局部时空矩阵 X_L 上的量测数据, 计算得到 4 种算法的初步重构值 x_{ij}^{gtv} 、 x_{ij}^{gsv} 、 x_{ij}^{ltv} 、 x_{ij}^{lsv} ;

5) 在得到初步重构值后, 通过输入周期性抓取的一段时间窗口内的非低质量数据用于计算在暂稳态阶段下 4 种时空 MVL 算法各自总体误差 L , 自适应更新计算出 4 个初步重构值 x_{ij}^{gtv} 、 x_{ij}^{gsv} 、 x_{ij}^{ltv} 、 x_{ij}^{lsv} 各自的权重 w , 对 x_{ij} 进行精确重构计算得到输出结果 \hat{x}_{ij} 。

STIFFM 方法区别于现有方法, 通过结合 MVL 算法的基本思想, 对 PMU 量测数据的时空信息特征更有效地进行提取融合, 因此在实际应用中的各种情况下都具有很强的适应能力, 可以对低质量数据进行精准重构。除了在面对大量节点数据长时间缺失的极端情况下, 由于无法获取到准确的时空信息而导致失效; 在面对大量节点数据短时间缺失和少量节点数据长时间缺失的情况下, 依然可以有效

地进行数据重构。此外, STIFFM 算法在对 4 种时空 MVL 法各自的权值初始化过程中需要调用历史量测数据外, 无需进行大量的离线训练。

5 算例分析

本节采用仿真测试和现场实际数据对所提方法进行测试与验证。所提算法在 MATLAB 2020a 实现并运行。

为了评估 STIFFM 算法的在线性能, 采用两个评价预测精度常用的误差评价指标, 即平均绝对相对误差(mean absolute relative error, MARE)和均方差(mean squared error, MSE)。利用 STIFFM 算法在线实时计算得出的估计值 $\hat{x} = \{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_N\}$, 将其与对应的真值 $x = \{x_1, x_2, \dots, x_N\}$ 代入下式进行计算:

$$\delta_{MARE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{x}_i - x_i}{x_i} \right| \quad (27)$$

$$\delta_{MSE} = \frac{1}{N} \sum_{i=1}^N (\hat{x}_i - x_i)^2 \quad (28)$$

同时为了证明所提算法的优越性, 本文将所提算法在相同测试案例下与埃尔米特插值法(Hermite interpolation, HI)^[32]、拉格朗日插值法(Lagrange interpolation, LI)^[8]、阿克玛插值(Akima interpolation, AI)^[33]、人工神经网络(artificial neural network, ANN)^[34]、长短期记忆网络(long short-term memory, LSTM)^[35]进行对比分析。

5.1 仿真测试

首先采用 IEEE39 节点系统进行仿真验证。IEEE39 节点系统的网络结构如图 7 所示, 在系统

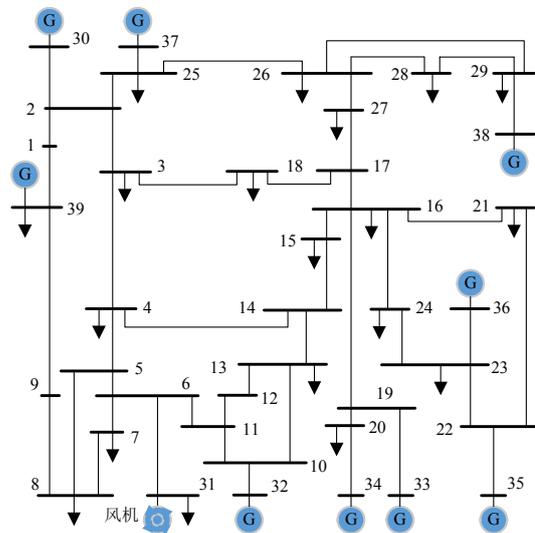


图 7 IEEE39 节点系统拓扑图

Fig. 7 IEEE39 node system topology

的39个节点上都部署了PMU设备用于在线监测。设置采样时间间隔 $\Delta T=0.01\text{ s}$ ，在稳态仿真数据上添加 $\sigma=0.005\text{ pu}$ 的高斯分布噪声^[36]，在暂态过渡阶段仿真数据上添加 $\sigma=0.007\text{ pu}$ 的高斯分布噪声。为了模拟网络模型和参数的实际误差，对空间距离矩阵 D 添加 $\sigma=0.02\text{ pu}$ 的高斯分布噪声。对于时空MVL算法，其视图大小设置为 $m_{gt}=30$ 、 $m_{lt}=5$ 。

为了模拟实际电网中高比例新能源接入和可能出现的各种异常情况，在仿真中添加了风机模型和新能源扰动数据^[37]，并且系统中设置了短路、开路、大小扰动等各种暂态情景，同时随机在每个节点处设置不良数据和缺失值。

5.1.1 系统运行状态判断

基于2.1节中建立的系统突变检测法，可实现系统扰动数据和低质量数据的辨别；基于2.2节中建立的系统暂稳态辨识法，可实现对系统稳定阶段和暂态过渡阶段的区分。仿真结果如图8所示。

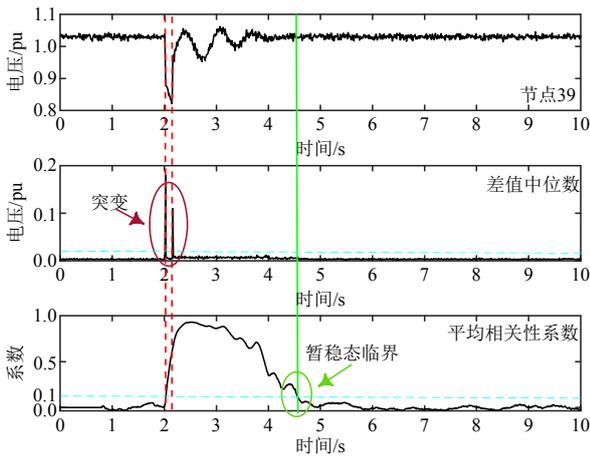


图8 系统运行状态辨识结果图

Fig. 8 System running state identification results

在图8中，2.0s处发生了短路故障，2.1s处进行重合闸。这两处的差值中位数发生明显变化，因此为系统干扰数据。从4.6s处平均相关性系数开始低于0.1，故系统由暂态阶段过渡到稳定阶段。系统发生突变起到暂稳态临界处之间的时刻，即2.0~4.6s为暂态过渡阶段。

5.1.2 系统稳定阶段仿真

稳态下系统的扰动主要来源于新能源波动和系统噪声。在系统稳定阶段下，对于单点低质量数据、非连续低质量数据和连续低质量数据情况进行实验，得到的结果分别如图9、10和表1所示。

从表1可得，在测量值含有噪声并且仅利用低质量目标值 x_{ij} 当前时刻及其之前量测数据的情况

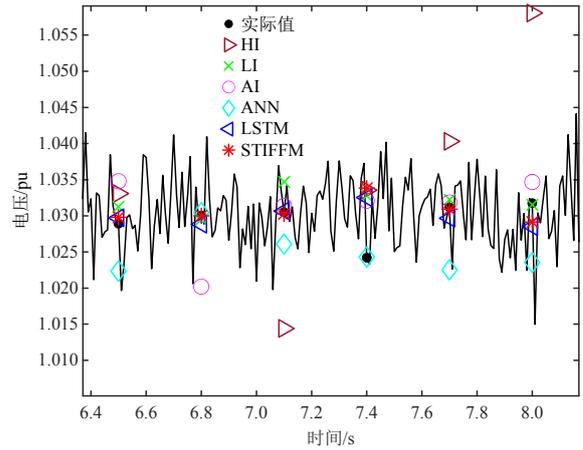


图9 稳态下单点低质量数据重构对比

Fig. 9 Reconstruction and comparison of discontinuous low-quality data under steady state

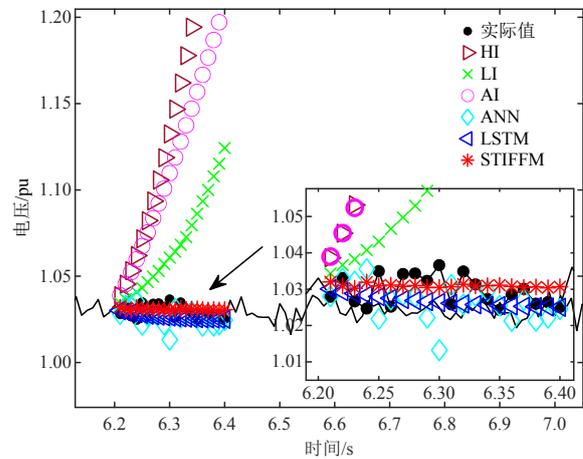


图10 稳态下连续低质量数据重构对比

Fig. 10 Reconstruction and comparison of continuous low-quality data under steady state

表1 6种方法在稳态下的数据重构结果

Table 1 Data reconstruction results of 6 methods under steady state

数据重构方法	单点低质量数据		非连续低质量 (20%坏数据)		连续低质量 (连续20个)	
	$\delta_{MARE}/\%$	$\delta_{MSE}/\%$	$\delta_{MARE}/\%$	$\delta_{MSE}/\%$	$\delta_{MARE}/\%$	$\delta_{MSE}/\%$
HI	1.9811	0.0481	1.8635	0.0681	11.8784	2.2003
LI	0.4081	0.0022	0.4860	0.0042	3.8034	0.2356
AI	0.5755	0.0052	0.8141	0.0101	8.5508	1.0548
ANN	0.3268	0.0014	0.4819	0.0044	0.5739	0.0064
LSTM	0.3038	0.0015	0.4085	0.0028	0.3848	0.0024
STIFFM	0.2392	0.0011	0.4172	0.0027	0.3787	0.0019

下，除开其中的HI，其他5种数据恢复法都可以有效地重构稳定阶段下的单点低质量数据。在非连续多点数据低质量的情况下，误差均有所增大，其中HI、AI增加较多。并且由于HI、LI、AI均为线性插值法，当出现连续多点数据低质量的情况后，其误差大幅度增加。而从图10中可以看出，STIFFM、

LSTM、ANN 在多点连续低质量的情况下误差基本保持不变，文中提出的 STIFFM 方法和 LSTM 在稳态下都可以有效地进行数据重构。

5.1.3 系统暂态过渡阶段仿真

当系统处于暂态，分别采用 6 种方法对 PMU 低质量数据进行重构。对于单点低质量数据、非连续低质量数据和连续低质量数据情况进行实验，得到的结果分别如图 11、12 和表 2 所示。

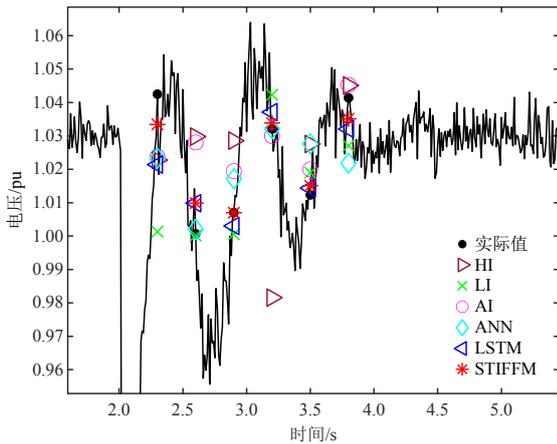


图 11 暂态下单点低质量数据重构对比

Fig. 11 Comparison of discontinuous low-quality data reconstruction under transient state

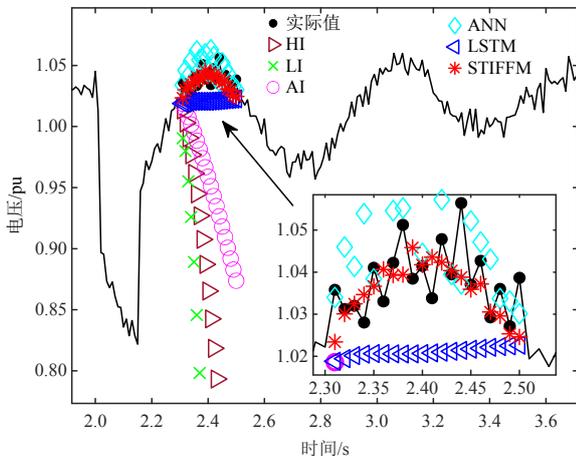


图 12 暂态下连续低质量数据重构对比

Fig. 12 Comparison of continuous low-quality data reconstruction under transient state

由表 2 可得，在暂态过渡阶段下，各种低质量情况下的误差均有所增加。其中 HI、LI、AI 这 3 种插值方法，在面对连续低质量数据情况时，出现的偏差过大。而在稳态下表现良好的 LSTM、ANN，在面对暂态阶段下的连续多点数据低质量情况下，从图 12 中可以看出也无法有效地进行数据重构。并且，LSTM、ANN 是在经过了针对性的训练后的结果，在面对实际电网中的各种异常事件下，其数据重构结果将更加难以采用。如表 2 所示，文中提

表 2 6 种方法在暂态下的数据重构结果

Table 2 Data reconstruction results of 6 methods under transient state

数据 重构 方法	单点低质量数据		非连续低质量 (20%坏数据)		连续低质量 (连续 20 个)	
	$\delta_{MARE}/\%$	$\delta_{MSE}/\%$	$\delta_{MARE}/\%$	$\delta_{MSE}/\%$	$\delta_{MARE}/\%$	$\delta_{MSE}/\%$
HI	2.5179	0.0767	2.4466	0.0859	19.5870	5.8715
LI	0.9083	0.0215	1.1817	0.0222	55.1331	53.5151
AI	1.0742	0.0161	1.1993	0.0216	8.2964	0.9519
ANN	0.6883	0.0077	1.2607	0.0242	1.1151	0.0214
LSTM	0.8197	0.0110	1.0599	0.0181	1.6440	0.0349
STIFFM	0.4730	0.0036	0.6856	0.0071	0.5713	0.0059

出的 STIFFM 方法在面对各种暂态低质量情况，得出的重构效果最优。并且该方法不需要对其进行大量离线训练，在面对各种异常事件产生的暂态过程，可以有效准确地重构非连续与连续 PMU 低质量量测数据。

5.2 PMU 实测数据验证

为了进一步验证文中 STIFFM 算法在实际大规模电网上的有效性和准确性，采用中国南方电网广东 500kV 输电网的案例进行仿真验证，共有 80 个厂站，185 个输电线路，采用某次发生短路故障情况时的 PMU 监测所得的数据进行了数据重构验证。

利用文中方法得出的系统运行状态如图 13 所示。可以判定系统在 2.60s 处发生了异常事件，并且在 3.91s 处转入稳定阶段。

利用 PMU 实测数据进行系统暂稳态下的多种低质量情况测试，利用 6 种方法对非连续与连续低质量情况进行数据重构，得到的结果分别如图 14、15 和表 3 所示。

由图 14、15 可得，由于 PMU 实测数据的噪声

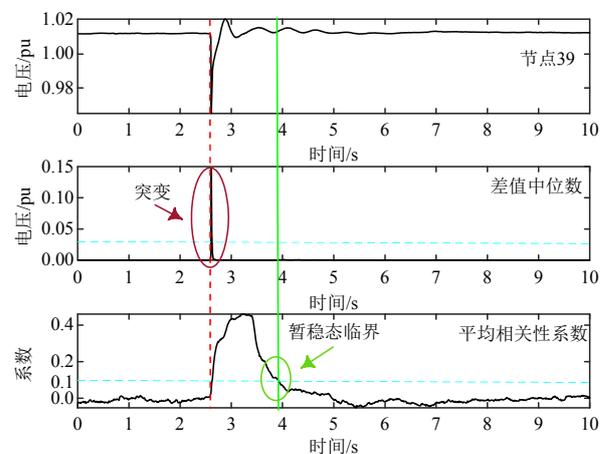


图 13 实测系统运行状态辨识结果图

Fig. 13 Identification result of the operating state of the actual measured system

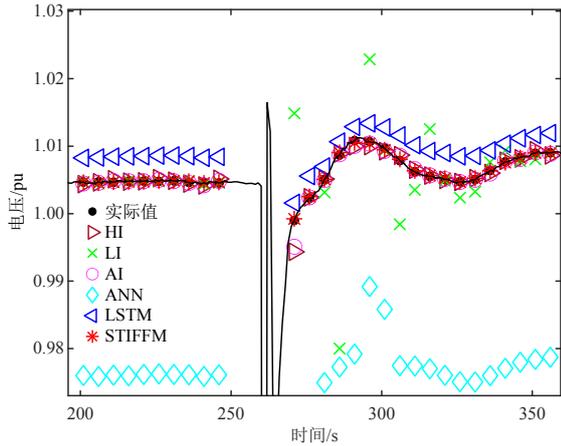


图 14 PMU 实测数据下非连续低质量数据重构对比

Fig. 14 Reconstruction and comparison of discontinuous low-quality data under PMU actual measured data

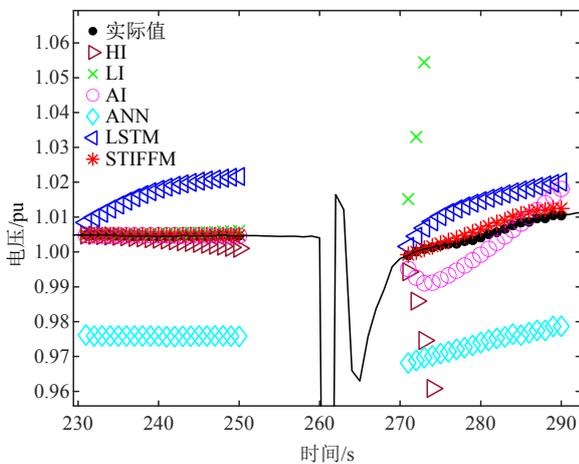


图 15 PMU 实测数据下连续低质量数据重构对比

Fig. 15 Reconstruction and comparison of continuous low-quality data under PMU actual measured data

相比于仿真测试来的较小，因此 3 种插值法在稳态中可以得到不错的结果。但是对于 ANN、LSTM 来说，由于难以对实际电网数量繁多的节点和可能出现的各种异常事件进行有效训练，因此得出的仿真

表 3 PMU 实测数据下 6 种方法的重构结果

Table 3 Reconstruction results of 6 methods based on PMU measured data

数据重构方法	$\delta_{MARE}/\%$					
	单点低质量数据		非连续低质量 (20%坏数据)		连续低质量 (连续 20 个)	
	稳态	暂态	稳态	暂态	稳态	暂态
HI	0.0175	0.1257	0.0258	0.0517	0.1341	20.7652
LI	0.0158	0.1107	0.0089	0.5506	0.0670	40.8104
AI	0.0087	0.1169	0.0163	0.0382	0.0138	0.5372
ANN	2.9841	2.7655	2.8520	2.9150	2.8657	3.0979
LSTM	0.3176	0.2566	0.3720	0.3100	1.2295	0.8752
STIFFM	0.0077	0.0148	0.0087	0.0228	0.0187	0.1688

结果偏移较大。在暂态过渡阶段出现的连续低质量情况下，仅有文中所提的 STIFFM 算法可以得到有效的数据重构结果。并且从表 3 可得，在各种低质量情况下 STIFFM 算法的数据重构结果最优。

6 结论

为了应对实际测量环境导致 PMU 数据出现的各类不良数据和数据缺失情况，本文提出基于时空多视图学习算法的 PMU 电压数据重构新方法，该方法可以应对系统暂稳态量测中出现的多种类型的低质量数据情况，实现 PMU 在线量测快速准确的实时数据重构，保证测量数据的可靠性和完备性，为后续在系统中的应用提供了数据基础保障。本文主要结论如下：

1) 根据实际 PMU 测量数据情况，归纳了 4 种不同低质量数据情况；提出系统运行状态辨识方法，实现对系统异常事件干扰数据和低质量数据的区分，并对系统所处的运行状态进行暂稳态辨识。

2) 利用时空 MVL 算法中的 GTV、GSV 分别对系统稳态阶段和系统暂态过渡阶段较好的预测效果，结合系统暂稳态辨识方法，实现对 PMU 量测的低质量数据辨识。

3) 采用 MVL 方法思想，形成带有时空信息特征的全局与局部多维视角的数据生成算法，并且通过暂稳态下 4 种时空视图法各自的总体误差来自适应分配权重，构建 STIFFM 算法实现缺失数据实时在线重构。

文中所提出的 STIFFM 方法在无需大量离线训练的情况下，可有效提取 PMU 实时量测数据周围的时空信息特征，在面对实际电力系统中出现的各类未知异常事件以及长时间连续数据缺失情况下依然能够有效准确地进行实时在线数据重构，有效提高了 PMU 量测数据的质量，为后续基于 WAMS 数据的高级应用提供了保障。

参考文献

[1] 白宏. 基于 PMU 量测信息的面向过程状态估计研究[D]. 哈尔滨: 哈尔滨工业大学, 2008.
BAI Hong. Researches on process-oriented state estimation based on pmu's measurement information[D]. Harbin: Harbin Institute of Technology, 2008(in Chinese).

[2] 李明节, 陶洪铸, 许洪强, 等. 电网调控领域人工智能技术框架与应用展望[J]. 电网技术, 2020, 44(2): 393-400.

- LI Mingjie, TAO Hongzhu, XU Hongqiang, et al. The technical framework and application prospect of artificial intelligence application in the field of power grid dispatching and control[J]. Power System Technology, 2020, 44(2): 393-400(in Chinese).
- [3] 刘灏, 毕天姝, 徐全, 等. 配电网高精度同步相量测量技术方案与展望[J]. 电力系统自动化, 2020, 44(18): 23-29.
- LIU Hao, BI Tianshu, XU Quan, et al. Scheme and prospect of high-precision synchrophasor measurement technology for distribution network[J]. Automation of Electric Power Systems, 2020, 44(18): 23-29(in Chinese).
- [4] LIU Hao, BI Tianshu, YANG Qixun. The evaluation of phasor measurement units and their dynamic behavior analysis[J]. IEEE Transactions on Instrumentation and Measurement, 2013, 62(6): 1479-1485.
- [5] REN Jinfeng. Synchrophasor measurement using substation intelligent electronic devices: algorithms and test methodology[D]. College Station: Texas A&M University, 2011.
- [6] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. GB/T 28815—2012 电力系统实时动态监测主站技术规范[S]. 北京: 中国标准出版社, 2013.
- General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. GB/T 28815—2012 Specification for master station of real-time dynamics monitoring system for power systems[S]. Beijing: Standards Press of China, 2013(in Chinese).
- [7] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. GB/T 26862—2011 电力系统同步相量测量装置检测规范[S]. 北京: 中国标准出版社, 2011.
- General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. GB/T 26862—2011 Test specification for synchrophasor measurement unit for power systems [S]. Beijing: Standards Press of China, 2011(in Chinese).
- [8] 杨玉泽, 刘文霞, 李承泽, 等. 面向电力 SCADA 系统的 FDIA 检测方法综述[J]. 中国电机工程学报, 2023, 43(22): 8602-8622.
- YANG Yuze, LIU Wenxia, LI Chengze, et al. Review of FDIA detection methods for power SCADA systems [J]. Proceedings of the CSEE, 2023, 43(22): 862-8622(in Chinese).
- [9] 徐俊俊, 吴在军, 张腾飞, 等. 融入多源量测数据的配电网分布式区间状态估计[J]. 中国电机工程学报, 2022, 42(24): 8888-8900.
- XU Junjun, WU Zaijun, ZHANG Tengfei, et al. State estimation of distribution network distribution interval based on multi-source measurement data[J]. Proceedings of the CSEE, 2022, 42(24): 8888-8900(in Chinese).
- [10] HUANG Can, LI Fangxing, ZHAN Lingwei, et al. Data quality issues for synchrophasor applications Part II: problem formulation and potential solutions[J]. Journal of Modern Power Systems and Clean Energy, 2016, 4(3): 353-361.
- [11] 刘灏, 杨智伟, 毕天姝, 等. 基于优先级分配策略的 PMU 数据恢复方法[J]. 电网技术, 2018, 42(9): 2814-2820.
- LIU Hao, YANG Zhiwei, BI Tianshu, et al. PMU data recovery method based on priority allocation strategy [J]. Power System Technology, 2018, 42(9): 2814-2820(in Chinese).
- [12] 朱琼锋, 李家腾, 乔骥, 等. 人工智能技术在新能源功率预测的应用及展望[J]. 中国电机工程学报, 2023, 43(8): 3027-3048.
- ZHU Qiongfeng, LI Jiateng, QIAN Ji, et al. Application and prospect of artificial intelligence technology in new energy power prediction[J]. Proceedings of the CSEE, 2023, 43(8): 3027-3048(in Chinese).
- [13] GAO Pengzhi, WANG Meng, GHIOCEL S G, et al. Missing data recovery by exploiting low- dimensionality in power system synchrophasor measurements[J]. IEEE Transactions on Power Systems, 2016, 31(2): 1006-1013.
- [14] KONSTANTINOPOULOS S, DE MIJOLLA G M, CHOW J H, et al. Synchrophasor missing data recovery via data-driven filtering[J]. IEEE Transactions on Smart Grid, 2020, 11(5): 4321-4330.
- [15] LIAO Mang, SHI Di, YU Zhe, et al. An alternating direction method of multipliers based approach for PMU data recovery[J]. IEEE Transactions on Smart Grid, 2019, 10(4): 4554-4565.
- [16] YU J J Q, HILL D J, LI V O K, et al. Synchrophasor recovery and prediction: a graph-based deep learning approach[J]. IEEE Internet of Things Journal, 2019, 6(5): 7348-7359.
- [17] 王守相, 陈海文, 潘志新, 等. 采用改进生成式对抗网络的电力系统量测缺失数据重建方法[J]. 中国电机工程学报, 2019, 39(1): 56-64.
- WANG Shouxiang, CHEN Haiwen, PAN Zhixin, et al.

- A reconstruction method for missing data in power system measurement using an improved generative adversarial network[J]. Proceedings of the CSEE, 2019, 39(1): 56-64(in Chinese).
- [18] REN Chao, XU Yan. A fully data-driven method based on generative adversarial networks for power system dynamic security assessment with missing data[J]. IEEE Transactions on Power Systems, 2019, 34(6): 5044-5052.
- [19] MAHAPATRA K, CHAUDHURI N R. Online robust PCA for malicious attack-resilience in wide-area mode metering application[J]. IEEE Transactions on Power Systems, 2019, 34(4): 2598-2610.
- [20] CHATTERJEE K, MAHAPATRA K, CHAUDHURI N R. Robust recovery of PMU signals with outlier characterization and stochastic subspace selection [J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3346-3358.
- [21] HUANG Can, LI Fangxing, ZHOU Dao, et al. Data quality issues for synchrophasor applications Part I: a review[J]. Journal of Modern Power Systems and Clean Energy, 2016, 4(3): 342-352.
- [22] 贾科, 杨哲, 魏超, 等. 基于斯皮尔曼等级相关系数的新能源送出线路纵联保护[J]. 电力系统自动化, 2020, 44(15): 103-111.
JIA Ke, YANG Zhe, WEI Chao, et al. Pilot protection based on spearman rank correlation coefficient for transmission line connected to renewable energy source[J]. Automation of Electric Power Systems, 2020, 44(15): 103-111(in Chinese).
- [23] 魏向向, 温渤婴. 基于2阶累加生成相关性的谐振接地系统故障选线方法[J]. 电网技术, 2017, 41(5): 1674-1682.
WEI Xiangxiang, WEN Boying. A novel fault line detection method based on 2-order accumulated generating operation correlation analysis for resonant earthed system[J]. Power System Technology, 2017, 41(5): 1674-1682(in Chinese).
- [24] 张苏涵, 顾伟, 姚帅, 等. 综合能源网络统一建模及其应用(一): 时域二端口模型[J]. 中国电机工程学报, 2021, 41(19): 6509-6520.
ZHANG Suhan, GU Wei, YAO Shuai, et al. Unified modeling of integrated energy networks in time domain and its applications(I): two-port models in time domain [J]. Proceedings of the CSEE, 2021, 41(19): 6509-6520(in Chinese).
- [25] YI Xiuwen, ZHENG Yu, ZHANG Junbo, et al. ST-MVL: filling missing values in geo-sensory time series data[C]// Proceedings of the 25th International Joint Conference on Artificial Intelligence. New York: AAAI Press, 2016: 2704-2710.
- [26] 安颖坤, 朱永丹. 基于线性回归法和指数平滑法对电力负荷的预测[J]. 电力设备管理, 2021(5): 177-179.
AN Yingkun, ZHU Yongdan. Power load forecasting based on linear regression method and exponential smoothing method[J]. Electric Power Equipment Management, 2021(5): 177-179(in Chinese).
- [27] 余国浩, 蔡远文. 自适应指数平滑法预测遥测数据实时趋势研究[J]. 装备指挥技术学院学报, 2007, 18(2): 65-69.
YU Guohao, CAI Yuanwen. Research on exponent-smoothing model with variable parameters applied in real-time trend prediction of telemetric data[J]. Journal of Equipment Academy, 2007, 18(2): 65-69(in Chinese).
- [28] 樊子德, 李佳霖, 邓敏. 顾及多因素影响的自适应反距离加权插值方法[J]. 武汉大学学报: 信息科学版, 2016, 41(6): 842-847.
FAN Zide, LI Jialin, DENG Min. An adaptive inverse-distance weighting spatial interpolation method with the consideration of multiple factors[J]. Geomatics and Information Science of Wuhan University, 2016, 41(6): 842-847(in Chinese).
- [29] 杨雄平. 电力系统网络拓扑结构分析及运行方式组合研究[D]. 武汉: 华中科技大学, 2007.
YANG Xiongping. Study on network topology analysis and operation modes combination in power system [D]. Wuhan: Huazhong University of Science and Technology, 2007(in Chinese).
- [30] 施锦涛, 陈磊, 秦凯, 等. 基于时空相似性的即时学习在线建模[J]. 仪器仪表学报, 2022, 43(6): 185-193.
SHI Jintao, CHEN Lei, QIN Kai, et al. Online modeling of just-in-time learning based on spatial-temporal similarity[J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 185-193(in Chinese).
- [31] 岳艳春, 黄廷祝. 误差倒数变权组合预测方法[J]. 电子科技大学学报, 2007, 36(2): 349-351.
YUE Yanchun, HUANG Tingzhu. A method for error reciprocal variable weight combined forecasting [J]. Journal of University of Electronic Science and Technology of China, 2007, 36(2): 349-351(in Chinese).
- [32] ZEINALI M, SHAHMORAD S, MIRNIA K. Hermite and piecewise cubic Hermite interpolation of fuzzy data [J]. Journal of Intelligent & Fuzzy Systems, 2014, 26(6): 2889-2898.
- [33] BICA A M. Optimizing at the end-points the Akima's

- interpolation method of smooth curve fitting[J]. Computer Aided Geometric Design, 2014, 31(5): 245-257.
- [34] 张驰, 郭媛, 黎明. 人工神经网络模型发展及应用综述[J]. 计算机工程与应用, 2021, 57(11): 57-69.
ZHANG Chi, GUO Yuan, LI Ming. Review of development and application of artificial neural network models[J]. Computer Engineering and Applications, 2021, 57(11): 57-69.
- [35] FENG Shufang, FENG Yong. A dual-staged attention based conversion-gated long short term memory for multivariable time series prediction[J]. IEEE Access, 2022, 10: 368-379.
- [36] 魏大千, 王波, 刘涤尘, 等. 基于时序数据相关性挖掘的 WAMS/SCADA 数据融合方法[J]. 高电压技术, 2016, 42(1): 315-320.
WEI Daqian, WANG Bo, LIU Dichen, et al. WAMS/SCADA data fusion method based on time-series data correlation mining[J]. High Voltage Engineering, 2016, 42(1): 315-320(in Chinese).
- [37] 唐王倩云, 张睿, 胡家兵. 用于系统暂态行为分析的双馈风机转子转速控制时间尺度暂态模型[J]. 中国电机工程学报, 2021, 41(9): 3037-3045.
TANG Wangqianyun, ZHANG Rui, HU Jiabing. Modelling of DFIG-based WT for power system transient responses analysis in rotor speed control timescale[J].

Proceedings of the CSEE, 2021, 41(9): 3037-3045(in Chinese).



林俊杰

在线出版日期: 2024-05-14。

收稿日期: 2023-09-14。

作者简介:

林俊杰(1992), 男, 博士, 副教授, 研究方向为同步相量测量技术、电力系统状态估计, linjunjie@fzu.edu.cn;

涂明权(1997), 男, 硕士研究生, 研究方向为同步相量测量技术, 1319857943@qq.com;

朱利鹏(1990), 男, 博士, 教授, 研究方向为数据驱动的电力系统稳定分析与控制、广域同步相量测量技术 lpzhu@hnu.edu.cn;

宋文超(1996), 男, 博士研究生, 研究方向为基于同步相量测量的状态估计和潮流计算, swcgryz@163.com;

*通信作者: 陆超(1977), 男, 博士, 教授, 研究方向为电力系统分析与控制、轨道交通牵引供电技术、数据驱动与人工智能应用技术, luchao@tsinghua.edu.cn。

(编辑 乔宝榆, 李新洁)