

DOI:10.3969/j.issn.2097-0706.2023.06.001

基于门控图神经网络的高容错配电网状态估计方法

High fault-tolerant distribution network state estimation method based on gated graph neural network

刘艺娴^{a,b}, 王玉彬^a, 杨强^{a*}
LIU Yixian^{a,b}, WANG Yubin^a, YANG Qiang^{a*}

(浙江大学 a. 电气工程学院; b. 工程师学院, 杭州 310027)

(a. College of Electrical Engineering; b. Polytechnic Institute, Zhejiang University, Hangzhou 310027, China)

摘要: 随着电力系统可再生能源渗透率的逐渐提升, 为应对可再生能源的间歇性特点并确保电网安全运行, 对配电网进行实时、准确、高容错的状态估计至关重要。针对配电网量测装置装配水平不完备、模型驱动状态估计对高不确定性环境适应性不足的问题, 基于数据采集与监视控制(SCADA)系统和相量测量单元(PMU)获得的多个时间尺度的混合量测, 提出了一种基于门控图神经网络(GGNN)的高容错配电网状态估计方法, 利用图卷积层和类门控循环单元提取量测时空高维特征, 挖掘量测量与状态量的时空与因果关系。最后基于 IEEE 33 节点系统与 IEEE 118 节点系统进行了仿真验证, 结果表明, GGNN 能有效拟合配电网量测量到状态量的时空映射, 相比传统最小二乘法和多层感知机具有更高的精度和容错性。

关键词: 可再生能源; 配电网; 状态估计; 高容错; 融合量测; 门控图神经网络; 最小二乘法; 多层感知机

中图分类号: TK 01: TM 732 **文献标志码:** A **文章编号:** 2097-0706(2023)06-0001-08

Abstract: With the increase of renewable energy's penetration rate in power systems, it is essential to make real-time, accurate and highly fault-tolerant state estimations for distribution networks to cope with the intermittency of renewable energy and keep safe operation of the power grid. Since the assembly level of distribution network measurement devices is incomplete and the model-driven state estimation can hardly adapt to the high uncertainty of environment, the fused measurement data from SCADA/PMU is adopted to train the gated graph neural network (GGNN). Then, a high fault-tolerant distribution network state estimation method based on GGNN is proposed. It can obtain the spatio-temporal relationship between the measurement and the state estimation by using the graph convolutional layer and GRU-like to extract high-dimensional spatio-temporal features of the measurement. The proposed algorithmic solution is assessed and validated based on an IEEE 33-bus system and an IEEE 118-bus system, respectively. The assessment result show that GGNN can effectively fit the space-time mapping of measurement and state data with a higher accuracy and robustness compared with the traditional Weighted Least Squares (WLS) and Multi-layer Perceptron (MLP).

Keywords: renewable energy; distribution network; state estimation; high fault tolerance; fused measurement; gated graph neural network; least squares method; multi-layer perceptron

0 引言

随着分布式可再生电源和大量用户侧可调柔性资源的大量接入, 配电网中源网荷友好互动对保障电力供给和系统运行日益重要。分布式发电出力的间歇性和波动性导致配电网双向功率频发, 配电网的运行与控制方式日趋复杂, 配电网运行控制

难度增大^[1]。为了保证配电网安全、经济、可靠运行, 提高用户的用电质量, 有必要对配电网运行状态进行精确感知^[2]。状态估计是配电网进行状态感知的核心功能之一, 其精度直接影响电力系统的安全性和经济性。因此, 配电网状态估计的精确性、计算速度和容错能力对保障配电网实时安全稳定运行具有重要意义。

目前, 配电网系统中的数据主要来自 2 类量测系统, 分别是数据采集与监视控制(Supervisory

基金项目: 国家自然科学基金项目(52177119)
National Natural Science Foundation of China(52177119)

Control and Data Acquisition, SCADA)系统和基于相量测量单元(Phasor Measurement Units, PMU)的广域测量系统(Wide-Area Measurement System, WAMS)。SCADA系统的数据刷新频率较低,含有不良量测数据时会导致估计精度较差;PMU量测精度高,更新周期为ms级^[3],作为状态量的节点电压相量和支路电流相量可以由PMU直接量测得。相比于SCADA系统,PMU的量测性能在时效性、精确性等诸多维度上都有更好的表现,但由于技术、经济条件的限制,当前我国配电网只在关键节点配置PMU。基于PMU进行量测无法满足可观性的需求,将PMU数据与SCADA数据进行有效融合,以提高状态估计精度是现阶段较为合理的方法^[4-7]。

以加权最小二乘(Weighted Least Square, WLS)法为主的静态状态估计是电力系统应用最为成熟的状态估计算法^[8],但其需要迭代求解,当含有不良量测数据时估计精度低^[9];同时,配电网中馈线线路和配电变压器老化会引起配电网静态参数变化,由于无法及时感知配电网参数变化,基于WLS的状态估计结果的准确性将受到影响。受配电网中接入的间歇式分布式电源输出功率的影响^[10],配电网的量测量和状态量具有时序规律性,动态状态估计算法能够基于多个时间断面的量测数据对系统进行状态估计,从而提高状态估计算法对时序变化的灵敏度。

传统状态估计方法在工程上已得到广泛应用^[10-14],在当前电力系统建设进入数字化转型的关键阶段,将数据驱动方法应用于传统电力领域已成为当下研究的热点之一。基于海量历史数据和深度学习、机器学习,数据驱动方法有望为电力系统态势感知提供新的解决方案,提高状态估计的性能。作为当下状态估计领域的研究热点之一^[15-20],已有许多学者开展基于数据驱动的状态估计研究。文献[15]通过数据挖掘技术,对相似的历史量测数据进行聚类分析,搜索相似量测断面样本,进而进行电力系统实时状态估计。文献[16]提出了基于深度信念网络的伪量测模型,该模型提升了电网量测冗余度,保证系统可观。文献[17]利用神经网络的非线性拟合能力训练状态估计器,为高斯-牛顿法状态估计寻找较为合理的初值,提高了状态估计对初值的敏感性。在电力系统智能化发展的今天,传统算法在智能电网数据爆炸式增长的新形势下具有较大的局限性,而深度学习可以弥补工程应用中计算效率低、数据容错能力差等问题^[18]。此外,已有的伪量测模型难以对输入与输出之间的特征关系进行精确学习;同时,伪量测的量测方程为非

线性方程,无法很好地与PMU线性量测方程配合。为了更好地融合PMU/SCADA混合量测,提高量测冗余度和状态估计容错性,本文提出一种基于数据驱动的高容错状态估计方法。

(1)提出一种基于数据的配电网实时快速状态估计方法。利用历史SCADA/PMU的融合量测数据离线训练门控图神经网络(Gated Graph Neural Network, GGNN),通过迁移训练良好的神经网络估计器完成配电网实时快速状态估计。

(2)针对PMU和SCADA量测数据的差异性,提出一种基于多层感知机(Multi-Layer Perceptron, MLP)和差分整合移动平均自回归(Autoregressive Integrated Moving Average, ARIMA)模型的量测融合策略,组成同一时间尺度的融合量测,增加量测的冗余度,以支撑提高状态估计容错性。

(3)基于GGNN的高容错状态估计方法可利用邻居信息聚合机制提取电网拓扑信息,实现时空、拓扑信息的融合提取。

1 基于MLP和ARIMA的量测融合

本节基于SCADA和PMU获得的多时间尺度混合数据集,提出一种基于数据驱动的融合量测方案。利用已安装PMU节点的量测数据生成未安装PMU节点的伪量测数据;同时,针对刷新频率低的SCADA量测数据,生成与PMU量测数据刷新频率一致的SCADA伪量测数据,组成时间尺度统一的融合量测,增加量测的冗余度^[19]并支撑提高状态估计容错性。

1.1 基于MLP的伪量测建模方法

MLP是一种朴素的前馈人工神经网络模型,由输入层、输出层以及多个隐含层全连接构成。本节提出一种基于MLP的伪量测建模方法,其中伪量测模型的数学表达为

$$Z = \hat{Z} + e, \quad (1)$$

式中: Z 为真实量测值,通过潮流计算得到; $\hat{Z}$ 为通过MLP建模得到的伪量测值; e 为伪量测值相对真实量测值的误差,通过正态分布模型可以拟合得到伪量测误差的方差。

由于配电网中电阻和电抗之间的差异不大,电压相量的幅值和相位与每个节点注入的功率有关,因此,基于MLP的伪量测建模以节点注入有功功率 P_i 和无功功率 Q_i 作为输入数据,对配电网状态量 $\mathbf{x}_k = [V_i, \delta_i]^T$ (V_i 为节点电压幅值, δ_i 为节点电压相位)进行预测,模型框架如图1所示。通过首层隐含层将输入的量测数据映射到高维特征空间进行特

征提取,通过2个子网络提取重构量测特征并对 V_i , δ_i 进行预测,从而得到 V_i, δ_i 的伪量测值。




图1 基于MLP的伪量测值模型框架

Fig. 1 MLP-based pseudo-measurement model framework

1.2 基于ARIMA的SCADA量测超短期预测

目前SCADA以0.1~5.0 Hz的刷新频率来传输数据,而PMU的刷新频率为10~100 Hz。选取SCADA刷新频率为1 Hz,PMU刷新频率为20 Hz。为了使伪量测生成的混合数据以PMU量测的频率刷新,需要针对低频的SCADA量测数据进行超短期预测,从而使SCADA量测与PMU量测的刷新频率一致。由于电网正常运行时状态量波动较少且波动幅度较小,采用经典时间序列预测分析法——ARIMA模型对SCADA数据进行超短期预测。当SCADA数据满足平稳性要求后,采用赤池信息量准则(Akaike Information Criterion, AIC)定阶, AIC准则即最小化信息量准则。

$$C_{AI} = 2N - 2\ln L(p, q|x), \quad (2)$$

式中: N 为模型参数个数; $\ln L(p, q|x)$ 为模型的极大似然函数; p 为自回归项数; q 为滑动平均项数; x 为使之成为平稳序列所做的差分次数。

计算得 $p = 2, q = 0$,故模型为ARIMA(2,0,1)。以5个时刻为预测步长,利用前20个时刻的电压值进行超短期预测,将状态值与真值进行比较,结果见表1。由表1可见,模型的预测准确率较高,5个时刻的准确率都达到了97%以上,前3个时刻的准确率达99%以上。

表1 模型预测的准确率及误差

Table 1 Estimation accuracy and error of the model

项目	时刻1	时刻2	时刻3	时刻4	时刻5
预测值(标么值)	0.988 7	1.003 0	0.990 3	0.997 8	0.994 3
真实值(标么值)	0.982 6	1.007 9	0.981 4	1.025 8	0.982 5
误差/%	0.620	0.486	0.907	2.730	1.201
准确率/%	99.380	99.514	99.093	97.280	98.799

2 基于GGNN的动态状态估计

2.1 状态估计

状态估计的目的是计算冗余测量下系统状态

的最优解。使用最广泛的状态估计方法是WLS法^[8],配电网的测量方程为

$$z = h(x) + e, \quad (3)$$

式中: z 为 m 维测量向量; x 为系统状态变量的 m 维向量,表示测量数据与系统状态变量的映射关系; e 为测量噪声的矢量, $e \sim N(0, R)$, R 可从测量设备的铭牌数据中获得,

$$R = \text{diag}\{\sigma_1^2, \sigma_2^2, \dots, \sigma_m^2\}, \quad (4)$$

式中: σ_i 为第 i 个测量值的标准差。

根据PMU和SCADA的测量类型,测量矢量 z 由式(5)组成。相量测量只能存在于配置PMU的节点上。考虑配电线路可以忽略对地导纳支路,建立配电网测量方程。

$$z = [V_i, P_i, Q_i, P_{ij}, Q_{ij}, \delta_i]^T, \quad (5)$$

$$\begin{cases} V_i = V_i \\ P_i = V_i \sum_j V_j (G_{ij} \cos \delta_{ij} + B_{ij} \sin \delta_{ij}) \\ Q_i = V_i \sum_j V_j (G_{ij} \sin \delta_{ij} - B_{ij} \cos \delta_{ij}) \\ P_{ij} = V_i^2 g_{ij} - V_i V_j g_{ij} \cos \delta_{ij} - V_i V_j b_{ij} \sin \delta_{ij} \\ Q_{ij} = -V_i^2 b_{ij} - V_i V_j g_{ij} \sin \delta_{ij} + V_i V_j b_{ij} \cos \delta_{ij} \\ \delta_i^{\text{PMU}} = \delta_i \end{cases}, \quad (6)$$

式中: i, j 为编号; G_{ij} 和 B_{ij} 分别为节点导纳第 i 行、第 j 列元素的实部和虚部; P_{ij}, Q_{ij} 分别为 $i-j$ 支路的注入有功功率和注入无功功率。

2.2 GGNN

本节将具体介绍基于数据驱动的状态估计方法原理及应用。将状态估计抽象为以量测量作为输入,状态量作为输出的映射函数。GGNN是一种基于类门控循环单元(Gate Recurrent Unit, GRU)的端到端网络架构,通过循环迭代更新节点,学习图形结构化数据的特征^[21]。GGNN利用类似递归神经网络的信息传递原理在非欧式图结构中迭代地传播节点信息。为了更好地拟合状态估计量测量到状态量的复杂时空映射,本文对GGNN模型的传播阶段做出改进,基于GGNN结构中类GRU融合 T 个时刻的量测断面并提取配电网拓扑图数据时序特征,实现基于图卷积层提取数据的时空与因果关系。GGNN邻接矩阵构建原理如图2所示。




图2 GGNN邻接矩阵构建原理

Fig. 2 Construction of GGNN adjacency matrices

GGNN的传播模型为

$$a_v^{(t)} = A_v^T [h_1^{(t-1)T} \dots h_V^{(t-1)T}]^T + b, \quad (7)$$

$$z_v^t = \sigma(W^z a_v^{(t)} + U^z h_1^{(t-1)}), \quad (8)$$

$$r_v^t = \sigma(W^r a_v^{(t)} + U^r h_1^{(t-1)}), \quad (9)$$

$$h_v^{(t)} = (1 - z_v^t) \odot h_v^{(t-1)} + z_v^t \odot h_v^{(t)}, \quad (10)$$

式中: A_v^T 为邻接矩阵中对应节点 v 的位置向量; $[h_1^{(t-1)T} \dots h_V^{(t-1)T}]^T$ 为 $t-1$ 时刻集合所有节点特征行程的 $D|V|$ 维相量; b 为当前节点的前向传播的误差; z_v^t 为更新门限, 控制遗忘信息; W^z 为当前节点更新特征的计算矩阵; U^z 为前一节点更新特征的计算矩阵; $a_v^{(t)}$ 为 t 时刻节点和相邻节点通过边的相互作用结果; r_v^t 为重置门限, 控制产生新信息; W^r 为当前节点重置特征的计算矩阵; U^r 为前一节点重置特征的计算矩阵; $(1 - z_v^t) \odot$ 为选择遗忘哪些过去的信息; $h_v^{(t)}$ 为最终更新的节点状态。

GGNN 基于类 GRU 聚合时序信息, 自适应地分析图上多时间尺度的信息, 可以有效提升传统神经网络的时空特征感知能力; 同时, 作为黑箱模型, GGNN 在融合多个维度信息时无需额外的先验知识, 相比于 MLP 网络, 其模型参数明显减少。

2.3 基于 GGNN 的状态估计器训练

本文提出的基于 GGNN 的高容错配电网状态估计算法结构如图 3 所示, 它由 3 层神经网络组成: 第 1 层是 GGNN 层, 以融合量测作为输入, (输入、输出元素数目为 $n \times M$, n 为节点数, M 为节点量测特征维度), 进行等规模图特征提取; 第 2 层、第 3 层均为全连接神经网络, 对特征空间进行连接及重塑。为了捕捉配电网状态量的时序变动趋势, 利用第 2 层全连接神经网络将前 12 个时刻的特征空间连接起来并压缩重塑提取时序信息 (第 2 层网络输出的元素数目仍为 $n \times M$) 并输入第 3 层网络, 由第 3 层网络将特征空间映射到状态量, 使用 tanh 作为激活函数, 最终输出元素数目为 $n \times N$ (N 为状态量维度)。




图 3 基于 GGNN 的高容错配电网状态估计算法结构

Fig. 3 Framework of the high fault-tolerant GGNN-based distribution network state estimation method

基于 GGNN 的状态估计方法伪代码如图 4

所示。

```

Input and output:
Gated Graph Conv      Conv.      (in_feat=M, out_feat=M)
Fully Connected Layer 1  Conv.      (in_feat=M, out_feat=N)
Torch.concat ((x, h), 1)
Fully Connected Layer 2  Conv.      (in_feat=2M, out_feat=M)
Algorithm:
h ← tanh(x[:,0,:,:])
y ← Fully Connected Layer 1(h)      #shape:[n, batchsize, N]
for i = 1 → 12 do
    x ← x[:,i,:,:]                  #shape:[n, batchsize, M]
    h ← concat(h,x)                  #shape:[n, batchsize, 2M]
    h ← Fully Connected Layer 2(h)   #shape:[n, batchsize, M]
    h ← tanh(GatedGraphConv(h))     #shape:[n, batchsize, M]
end for pooling
y ← Fully Connected Layer 1(h)      #shape:[n, batchsize, N]

```

图 4 基于 GGNN 的状态估计方法伪代码

Fig. 4 Pseudocode of the GGNN-based state estimation method

对所述的 GGNN 状态估计器进行训练, 设置 Epoch=100, Batch=60, 以配电网拓扑构造图网络 $G = (V, L)$, 边集 L 类型为无向边, 顶集 V 为配电网母线。训练 MLP 网络作为对照, 超参数设置与 GGNN 一致。采用均方误差 (Mean-Square Error, MSE) 作为训练中的反向传播 Loss。

$$\delta_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (11)$$

式中: n 为样本个数; y_i 为真实值; $\hat{y}_i$ 为预测值。

GGNN 与 MLP 训练过程中 Loss 与测试集上 δ_{MSE} 的迭代变化趋势对比如图 5 所示。由图 5 可以看出: 前 20 Epoch 时两者都在训练集上快速收敛, 但 20 Epoch 后 GGNN 在测试集上的 δ_{MSE} 持续优化减小, MLP 由于拟合能力有限而陷入局部最优, 在测试集上泛化效果较差。




图 5 GGNN 与 MLP 训练过程中 Loss 与测试集上 δ_{MSE} 的变化趋势

Fig. 5 Comparison of Loss in training set and δ_{MSE} of test set made by GGNN and MLP

相比于GGNN,MLP未增加图结构和时序融合单元,仅利用量测与状态变量关系建立模型。MLP和GGNN在测试集上的训练效果对比如图6所示,由图6可见:GGNN估计结果的均方根误差(Root Mean Square Error, RMSE)为0.012,线性回归决定系数 R^2 为0.999,GGNN的精度和拟合效果相较于MLP有显著提升。




图6 GGNN与MLP训练效果对比

Fig. 6 Training results of GGNN and MLP

3 算例分析

3.1 试验设计与试验数据

为验证GGNN在配电网状态估计中的可行性,本节基于AMD Ryzen 7 5800H CPU和NVIDIA GeForce RTX 3060的64位GPU进行试验,在Python3的PyTorch1中实现算法框架,并使用Matlab程序包MatPower^[22]进行潮流计算。

基于标准IEEE 33节点系统和标准IEEE 118节点系统进行算例分析,其中IEEE 33节点系统配有PMU节点12个,IEEE 118节点系统配有PMU节点31个,具体量测配置情况见表2。

表2 IEEE 33,IEEE 118节点系统量测配置情况

Table 2 Measurement units configuration in IEEE 33-bus system and IEEE 118-bus system

节点系统	PMU节点编号
IEEE 33	3,6,9,11,14,17,19,22,24,26,29,32
IEEE 118	1,6,8,12,15,19,21,27,28,32,34,40,45,49,53,56,62,65,72,75,77,80,85,86,90,92,94,102,105,110,116

以纽约市用电负荷数据^[23]作为节点实际负载,实测数据的新能源电站的发电曲线作为仿真系统中新能源电站的实际出力^[24];选择2021-02-13—27的历史实际负载作为训练集,2021-02-28的实际负载作为测试集,数据间隔为5 min;设SCADA/PMU多时间尺度混合量测数据在采样时刻已经对齐了量测断面。基于潮流真值添加不同强度的高斯噪声构造SCADA与PMU的量测数据,参数设置具体如下:添加标准值为0.02、均值为0的误差构造SCADA量测;添加标准差分别为0.005,0.002,均值为0的误差构造PMU的电压幅值与相角量测。仿

真数据集说明见表3(刷新频率为0.2 Hz)。

表3 仿真数据集说明

Table 3 Simulation data set description

数据集	噪声
历史潮流真值	—
历史融合量测	SCADA系统量测误差标准值为0.020,均值为0;PMU幅值量测误差标准差为0.005;PMU相角量测误差标准差为0.002,均值为0
高噪声下融合量测	伪量测额外添加20%高斯白噪声

3.2 算法流程

该方法包括2个阶段,即离线模型训练和在线实时状态估计。在离线训练阶段,先分别训练MLP与ARIMA,对应地在空间、时间维度对PMU与SCADA数据进行扩增生成,形成时空尺度一致的数据集;当数据集中采样频率统一、空间上全网可观时,将混合量测输入GGNN中训练。在实时状态估计阶段,基于预训练的MLP与ARIMA对实时数据进行扩增补全,完成融合量测;随后进行数据归一化及坏数据替换的数据预处理,将结构化的数据输入预训练的GGNN完成快速状态估计。基于GGNN的高容错配电网状态估计算法流程如图7所示。




图7 基于GGNN的高容错配电网状态估计算法流程

Fig. 7 Algorithmic flow of the high fault-tolerant GGNN-based distribution network state estimation method

3.3 结果分析

3.3.1 估计结果及分析

针对IEEE 33节点系统和IEEE 118节点系统进行仿真,并将所提出的基于GGNN的状态估计算法与WLS算法^[8]和典型神经网络MLP算法进行对比,以残差为准确率指标。

$$\delta_{\text{RES}} = (x_{\text{p.u.}} - \hat{x}_{\text{p.u.}})^2, \quad (12)$$

式中: δ_{RES} 为残差; $x_{\text{p.u.}}$ 为潮流计算获得的真实状态量标么值; $\hat{x}_{\text{p.u.}}$ 为状态估计的估计量标么值。

为了反映3种算法在2种规模算例上的计算精度,截取单一时间断面对不同方法进行对比,3种方法的估计结果及残差对比如图8—11所示。本文提出的基于GGNN的状态估计模型电压幅值与电压相位计算结果与真值的残差均值及波动程度在3种算法中最小,验证了所述方法能稳定有效地提高状态估计精度;传统基于WLS的状态估计方法需要迭代以提高精度,由于各个节点电压相量的估计精度存在截断误差以及PMU与SCADA的量测数据之间存在精度差异,导致WLS算法在特定时刻收敛困难;相比于GGNN,基于典型深度学习方法MLP的状态估计模型参数较多,但无法提取电力拓扑结构信息及相邻时刻的时序特征,存在拟合能力不足及容易过拟合的问题。随着配电网规模增大及复杂度增加,状态估计面临量测维度呈现高维趋势及静态参数复杂化的挑战,由图11可见,3种状态估计算法在IEEE 118节点系统上的计算残差都有所增大,但GGNN的平均残差在3种方法中最小,说明随着网络复杂度的增加,本文所提方法具有更稳定的效果和容错性。




图8 IEEE 33节点量测断面电压幅值估计残差对比

Fig. 8 Voltage amplitude residuals on IEEE 33-bus system




图9 IEEE 33节点量测断面电压幅值估计结果对比

Fig. 9 Voltage amplitude estimating results on IEEE 33-bus system




图10 IEEE 33节点量测断面电压相位估计残差对比

Fig. 10 Voltage angle residuals on IEEE 33-bus system




图11 IEEE 118节点量测断面电压幅值估计残差对比

Fig. 11 Voltage amplitude residuals on IEEE 118-bus system

3.3.2 鲁棒性测试

为了测试所提方法在线应用的可行性,模拟PMU/SCADA量测精度差异和网络传输中通信干扰等带来的实际量测值误差,采用以下加噪方法。

(1)向PMU量测和SCADA量测分别加3.1节所述不同强度的高斯白噪声。

(2)在步骤(1)的基础上,向未装配PMU节点的伪量测数据再次添加20%的高斯白噪声。

为了比较基于WLS,MLP和GGNN的状态估计方法在干扰下的容错性,分别计算3种方法在高比例噪声下的状态量与潮流真值的相对误差 δ ,所得结果见表4。

$$\delta = \frac{x - x_i}{x_i} \times 100\%, \quad (13)$$

式中: x 为潮流真值; x_i 为状态估计值。

表4 3种计算方法的相对误差

Table 4 Relative errors of three algorithms %		
方法	电压幅值相对误差	电压相角相对误差
WLS	7.02	7.59
MLP	4.11	6.58
GGNN	2.89	5.11

由表4可见,添加20%噪声后,相较于WLS与MLP方法,GGNN能够在一定程度上增强噪声矫正能力,在状态估计任务下的抗误差能力更强,电压幅值平均相对误差分别降低了4.13,1.22百分点,

电压相位平均相对误差分别降低了 2.48,1.47 百分点。GGNN 方法在准确率和容错性方面表现较好,具体表现为:(1)添加 20% 噪声后,GGNN 估计方法所得状态量的相对误差明显小于 WLS 和 MLP 状态估计方法;(2)GGNN 能够通过学习历史数据,捕捉配电网各节点之间的关联性以及其物理模型特征,融合多个节点之间量测数据来提高模型的鲁棒性和容错性,避免了 WLS 在测量数据不完整和不准确的情况下难以收敛、误差较大的问题。

3.3.3 灵敏度测试

2.3 节将 Epoch, Batch 分别设置为 100 和 60,在梯度下降的模型训练过程中,神经网络逐渐从不拟合状态到优化拟合状态,达到最优状态之后会进入过拟合状态。当数据集较大时,一次向网络喂入全部数据得不到很好的训练效果。为验证超参数设置,进行灵敏度测试,在不同的 Batch 及 Epoch 设置下对比训练集 Loss 与测试集 δ_{MSE} ,见表 5、表 6。由表 5、表 6 可见:Batch 设置为 60 时,训练集上 Loss 与测试集 δ_{MSE} 最小,即训练效果最佳;Batch 取 60 时,Epoch 设置为 100 时训练集上 Loss 与测试集 δ_{MSE} 最小,即训练效果最佳。

表 5 不同的 Batch 设置下训练集 Loss 与测试集 δ_{MSE}
Table 5 Training set Loss and test set δ_{MSE} under different

项目	Batch size			
	Batch			
	32	60	96	128
训练集 Loss($\times 10^{-5}$)	3.76	1.47	2.34	3.67
测试集 δ_{MSE}	0.067	0.064	0.082	0.079

表 6 不同的 Epoch 设置下训练集 Loss 与测试集 δ_{MSE}
Table 6 Training set Loss and test set δ_{MSE} under different

项目	Epoch size			
	Epoch			
	50	100	150	200
训练集 Loss($\times 10^{-5}$)	7.21	1.01	5.49	4.62
测试集 δ_{MSE}	0.076	0.068	0.068	0.069

4 结束语

本文针对当前配电网量测装置配置情况及基于模型驱动的状态估计算法的局限性,基于 SCADA 和 PMU 获得的多个时间尺度的混合量测,提出了一种基于融合量测和 GGNN 的状态估计方法。建立了基于 GGNN 的配电网动态状态估计方法,基于配电网拓扑建图并对 GGNN 模型的误差传播模式做出适应性改进,基于类 GRU 融合 T 个时刻的量测断面,利用图卷积层提取量测时空高维特征,挖掘量测量与状态量的因果关系。设计了一种处理不同时间

尺度、不同数据成分的量测信息的融合方法。基于 MLP 与 ARIMA 的伪量测方法将多时间尺度的混合量测组成统一时间尺度、全网可观的融合量测,避免单时刻数据受到大干扰而出现误判,支撑高容错的状态估计。基于 IEEE 33, IEEE 118 节点系统进行仿真,验证了相较于 WLS, MLP 算法,基于 GGNN 的状态估计方法电压幅值与电压相角的估计精度更高;鲁棒性测试验证了本文所提方法在 20% 噪声下的容错性更强。

未来研究将进一步考虑配电网的静态参数变化对算法性能的影响,对所提出的 GGNN 算法在复杂电力网络的适用性进行测试并开展错误参数辨识算法等方面的研究。

参考文献:

[1]马钊,周孝信,尚宇炜,等.未来配电系统形态及发展趋势[J].中国电机工程学报,2015,35(6):1289-1298.
MA Zhao, ZHOU Xiaoxin, SHANG Yuwei, et al. Form and development trend of future distribution system [J]. Proceedings of the CSEE, 2015, 35(6): 1289-1298.
[2]MELIOPOULOS A P S, POLYMENEAS E, TAN Z, et al. Advanced distribution management system [J]. IEEE Trans on Smart Grid, 2013, 4(4): 2109-2117.
[3]褚晨杰,吕干云,吕经纬,等.基于 PMU/SCADA 混合量测的电力系统鲁棒状态估计[J].南京工程学院学报(自然科学版),2020,18(4):14-19.
CHU Chenjie, LYU Ganyun, LYU Jingwei, et al. Robust state estimation of power system based on PMU and SCADA hybrid measurement [J]. Journal of Nanjing Institute of Technology (Natural Science Edition), 2020, 18(4): 14-19.
[4]丁宏恩,戴则梅,霍雪松,等.基于混合量测的二次线性状态估计方法及其工程应用[J].电力系统保护与控制,2016,44(13):163-170.
DING Hong'en, DAI Zemei, HUO Xuesong, et al. Hybrid measurement based secondary linear state estimation method and its engineering application [J]. Power System Protection and Control, 2016, 44(13): 163-170.
[5]FILHO M B D C, SOUZA J C S D. Forecasting-aided state estimation—Part I: Panorama [J]. IEEE Transactions on Power Systems, 2009, 24(4): 1667-1677.
[6]丁军策,蔡泽祥,王克英.基于广域测量系统的混合量测状态估计算法[J].中国电机工程学报,2006,26(2):58-63.
DING Junce, CAI Zexiang, WANG Keying. Mixed measurements state estimation based on WAMS [J]. Proceedings of the CSEE, 2006, 26(2): 58-63.
[7]赵红嘎,薛禹胜,汪德星,等.计及 PMU 支路电流相量的状态估计模型[J].电力系统自动化,2004,28(17):37-40.

- ZHAO Hongga, XUE Yusheng, WANG Dexing, et al. Station estimation model with PMU current phasor measurement [J]. Automation of Electric Power Systems, 2004, 28(17): 37-40.
- [8] 于尔铿. 电力系统状态估计[M]. 北京: 水利电力出版社, 1985.
- [9] 王玉彬. 基于 PMU/SCADA 量测数据的配电网状态估计方法研究[D]. 北京: 北京交通大学, 2019.
- WANG Yubin. Research on distribution network state estimation method based on PMU/SCADA measurement data [D]. Beijing: Beijing Jiaotong University, 2019.
- [10] 李伟, 严川, 盛庆博, 等. 大数据背景下智能配电网运营管理方法研究[J]. 华电技术, 2021, 43(8): 33-40.
- LI Wei, YAN Chuan, SHENG Qingbo, et al. Study on smart distribution network operation and management methods in the context of big data [J]. Huadian Technology, 2021, 43(8): 33-40.
- [11] 罗玉春, 王毅. PAS 网络建模流程的设计[J]. 电力工程技术, 2015, 34(5): 40-42.
- LUO Yuchun, WANG Yi. Design of power grid modeling process in advanced application software package [J]. Electric Power Engineering Technology, 2015, 34(5): 40-42.
- [12] 周寅飞. 基于内点法和离散粒子群算法的输电网参数辨识[J]. 电力工程技术, 2014, 33(1): 22-25.
- ZHOU Yinfei. Hybrid strategy based on interior point method and DPSO for electricity transmission network parameter estimation [J]. Electric Power Engineering Technology, 2014, 33(1): 22-25.
- [13] 王义, 杨志伟, 吴坡, 等. 计及高比例分布式光伏能源接入的配电网状态估计[J]. 综合智慧能源, 2022, 44(10): 12-18.
- WANG Yi, YANG Zhiwei, WU Po, et al. State estimation for the distribution network with high-proportion distributed photovoltaic energy [J]. Integrated Intelligent Energy, 2022, 44(10): 12-18.
- [14] 谢铁明, 卫志农, 袁安建. 基于超短期负荷预测的电力系统动态状态估计[J]. 电力工程技术, 2009, 28(1): 8-10.
- XIE Tieming, WEI Zhinong, YUAN Anjian. Dynamic state estimation based on ultra short-term prediction of load [J]. Electric Power Engineering Technology, 2009, 28(1): 8-10.
- [15] 孙国强, 钱婧, 陈亮, 等. 基于深度信念网络伪量测建模的配电网状态估计[J]. 电力自动化设备, 2018, 32(12): 94-99.
- SUN Guoqiang, QIAN Qiang, CHEN Liang, et al. State estimation of distribution system based on pseudo measurement modeling using deep belief network [J]. Electric Power Automation Equipment, 2018, 32(12): 94-99.
- [16] 赵巍岳, 靳松, 吕天成. 基于神经网络的状态估计方法研究[J]. 电力系统保护与控制, 2018, 46(22): 109-115.
- ZHAO Weiyue, JIN Song, LYU Tiancheng. Research on state estimation based on artificial neural network [J]. Power System Protection and Control, 2018, 46(22): 109-115.
- [17] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化, 2019, 43(4): 180-191.
- ZHOU Niancheng, LIAO Jianquan, WANG Qianggang, et al. Analysis and prospect of deep learning application in smart grid [J]. Automation of Electric Power Systems, 2019, 43(4): 180-191.
- [18] DUBEY A, CHAKRABARTI S, TERZIJA V. SCADA and PMU measurement based methods for robust hybrid state estimation [J]. Electric Power Components and Systems, 2019, 47(9-10): 849-860.
- [19] SKOK S, IVANKOVIC I, CERINA Z. Hybrid state estimation model based on PMU and SCADA measurements [J]. IFAC-PapersOnLine, 2016, 49(27): 390-394.
- [20] BRONSTEIN M M, BRUNA J, LECUN Y, et al. Geometric deep learning: Going beyond euclidean data [J]. IEEE Signal Processing Magazine, 2017, 34(4): 18-42.
- [21] LI Y J, DANIEL T, MARC B, et al. Gated graph sequence neural networks [C]//4th International Conference on Learning Representations. San Juan, 2016: 1884-2021.
- [22] ZIMMERMAN R D, MURLLO-SANCHEZ C E, THOMAS R J. MATPOWER: Steady-state operations, planning, and analysis tools for power systems research and education [J]. IEEE Transactions on Power Systems, 2011, 26(1): 12-19.
- [23] NYISO. Load data [EB/OL]. (2021-02-13) [2022-10-22]. <http://www.nyiso.com/>.
- [24] 黄蔓云, 孙国强, 卫志农, 等. 基于历史数据挖掘的配电网态势感知方法[J]. 电网技术, 2017, 41(4): 1139-1145.
- HUANG Manyun, SUN Guoqiang, WEI Zhinong, et al. A novel situation awareness approach based on historical data-mining model in distribution networks [J]. Power System Technology, 2017, 41(4): 1139-1145.

(本文责编: 刘芳)

收稿日期: 2022-10-29; 修回日期: 2023-03-07
上网日期: 2023-05-08; 附录网址: www.iienenergy.cn

作者简介:

刘艺娴(1998), 女, 在读硕士研究生, 从事电力系统及人工智能、配电网态势感知等方面的研究, liuyixian@zju.edu.cn;

王玉彬(1994), 男, 在读博士研究生, 从事电力系统状态估计、电力线路参数辨识、综合能源系统经济调度等方面的研究, 12010061@zju.edu.cn;

杨强*(1979), 男, 教授, 博士生导师, 博士, 从事人工智能在电力系统中的应用等方面的研究, qyang@zju.edu.cn。

*为通信作者。