

融合改进生成对抗与图注意力网络的配电网状态估计

赵奇, 田江, 徐秀之, 吕洋

(国网江苏省电力有限公司苏州供电公司, 江苏苏州 215004)

摘要: 随着分布式新能源、可控资源等新型元素接入配电网, 传统状态估计模型面临量测信息不全、配电网拓扑变化频繁和负荷时序性波动等新问题, 模型估计精度降低。针对该问题, 文中提出一种融合改进生成对抗与图注意力网络的配电网状态估计方法。首先, 选取不同的历史时间断面, 利用拓扑参数和量测信息生成数据集, 通过将双向长短期记忆网络引入生成对抗网络填补数据中的缺失量测信息; 其次, 利用图注意力网络自适应地捕捉节点间的空间动态关系, 利用双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络充分挖掘不同时间断面序列信息的时间耦合关系, 拼接形成关于量测量到状态量的时空特征表达, 得到改进图神经网络状态估计模型; 最后, 在 IEEE 118 节点系统中进行仿真实验, 并与卷积神经网络、图注意力网络等算法进行对比。结果表明, 文中所提算法在数据缺失和拓扑时变情况下具有更优的估计效果。

关键词: 状态估计; 生成对抗网络; 图神经网络; 注意力机制; 双向长短期记忆(BiLSTM)网络; 时空建模

中图分类号: TM73

文献标志码: A

文章编号: 2096-3203(2026)02-0131-10

0 引言

为实现“碳达峰·碳中和”目标, 新型配电网迅速发展, 拓扑变化更加频繁, 且分布式新能源出力的随机性、时变性特点增加了系统运行的不确定性, 影响配电网的安全稳定运行^[1-3]。状态估计是配电管理系统重要的组成部分, 能够为调度人员提供准确可靠的数据支撑, 对保障配电网安全稳定运行具有重要意义^[4-5]。

目前, 加权最小二乘 (weighted least square, WLS) 因其估算结果具有最小方差且无偏的特点, 成为状态估计的常规方法^[6]。然而在配电网实际运行中, 配电网拓扑变化频繁, 部分节点实时量测数据缺失, 大量分布式新能源的出力受环境因素影响导致配电网量测量时序性波动, 使得 WLS 的估计结果变差^[7-10]。

国内外学者将人工智能算法引入电力系统分析领域, 开展了卓有成效的工作^[11-13]。在数据补齐方面, 文献^[14-15]利用生成对抗网络(generative adversarial network, GAN)补全配电网量测数据并实现有源配电网的电压优化, 验证 GAN 在电力系统中补全数据的可行性; 在时序分析方面, 文献^[16-17]利用双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络对多变量时间序列进行动态时间建模, 通过融合前向与后向的传播计算, 实现功率的短期预测; 在拓扑方面, 文献^[18-19]利用图注意力网络(graph attention network, GAT), 通过调

节量测节点间的注意力系数, 深入挖掘数据的动态空间特征, 提高数据驱动模型对拓扑变化的自适应能力。

目前研究多从单一时间维度或空间维度挖掘量测量与状态量之间的关系, 难以充分提取量测数据中的时空潜在信息, 降低了基于人工智能算法的状态估计精度。文中针对配电网状态量测数据不足、拓扑多变、时序波动问题, 提出一种融合改进生成对抗与图注意力网络(BiLSTM-GAN-GAT)的配电网状态估计方法。创新性主要在于: (1) 提出一种基于改进 GAN 模型的量测数据补全方法, 将 BiLSTM 嵌入 GAN 模型, 从前向和后向充分挖掘时间序列信息, 克服了 GAN 仅在断面上处理数据的缺点, 从而提高补齐数据的精度。(2) 构建 GAT-BiLSTM 模型, 自适应地学习不同拓扑下节点间数据的空间关系, 并且在时间维度上全面捕捉多断面数据之间的依赖关系, 实现了时空信息的深度融合。

1 基于 BiLSTM-GAN-GAT 模型的状态估计方法

1.1 基于 BiLSTM 改进 GAN 模型的数据补齐方法

由于配电网实时量测仅部分可观测, 配电网状态估计结果精度下降, 文中提出基于 BiLSTM 的改进 GAN 数据补齐方法。GAN 由生成模型(generative model, GM)和判别模型(discriminative model, DM)组成。设历史真实量测数据为 z , 噪声向量为 v , 量测序列真实数据的分布关系为 $p_{\text{real}}^{\text{os}}$, 噪声向

量的分布关系为 p_v 。将 v 作为生成器的输入数据, 得到符合 $p_{\text{real}}^{\text{os}}$ 分布的量测数据, 通过神经网络将 p_v 映射到 $p_{\text{real}}^{\text{os}}$ 空间, 使得生成的数据满足量测数据的特征^[20-21]。

生成器的损失函数 L_{gen} 为:

$$L_{\text{gen}} = -E_{v \sim p_v(v)}(D(G(v))) \quad (1)$$

式中: $G(v)$ 为生成器基于噪声向量 v 生成的伪量测数据; $D(\cdot)$ 为判别器对数据真实性的评估结果; $E_{v \sim p_v(v)}(\cdot)$ 为对满足 p_v 分布的噪声向量 v 进行计算的数学期望函数。

判别器的损失函数 L_{dis} 为:

$$L_{\text{dis}} = -E_{z \sim p_{\text{real}}^{\text{os}}(z)}(D(z)) + E_{v \sim p_v(v)}(D(G(v))) \quad (2)$$

式中: $E_{z \sim p_{\text{real}}^{\text{os}}(z)}(\cdot)$ 为对满足 $p_{\text{real}}^{\text{os}}$ 分布的量测样本 z 进行计算的数学期望函数。

生成器和判别器两者互相博弈, 通过缩小与目标分布之间的差距来引导模型达到最优状态^[20-21], 其目标函数 $V(G, D)$ 为:

$$\min_G \max_D V(G, D) = E_{z \sim p_{\text{real}}^{\text{os}}(z)}(D(z)) - E_{v \sim p_v(v)}(D(G(v))) \quad (3)$$

该目标函数表明, GAN 训练过程本质上是一个零和博弈问题, 生成器致力于生成与真实数据高度相似的量测数据以混淆判别器, 使判别器难以区分生成数据与真实数据, 从而使得补齐的量测数据最为真实, 而判别器则试图区分真实数据和生成数据。

为克服 GAN 仅在断面上补齐数据而忽略历史量测数据中时间序列信息的缺点, 文中将 BiLSTM 层嵌入生成器与判别器中, 用于处理和预测时间序列数据或具有长期依赖关系的序列数据^[22-23], 进一步提高补齐数据的精度。长短期记忆(long short-term memory, LSTM)网络包含遗忘门、输入门、输出门和记忆单元^[24]。在状态估计数据补齐应用中, 遗忘门决定记忆单元中哪些旧量测信息应被丢弃, 输入门决定哪些新量测信息需要被储存到记忆单元, 输出门决定选择哪些量测信息用于后续的预测和处理。BiLSTM 网络在 LSTM 网络的基础上, 增加反向量测序列信息的计算, 并将双向信息叠加, 克服了 LSTM 网络只能单向地从前一时刻获取信息的局限性, 使得算法在处理长时序量测信息时有更强的信息分布捕捉能力^[25-27]。

建立面向状态估计的 BiLSTM 模块, 假设给定时间步长 T 的量测数据矩阵 $\mathbf{x}_t = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T) \in \mathbf{R}^{N \times C}$ 。其中 N 为节点数; C 为每个量测节点特征维度, 在状态估计中值为 4, 不失一般性可以为节点电压幅

值、节点电压相角、节点注入有功功率和无功功率。BiLSTM 网络模型如下:

$$\begin{cases} \vec{\mathbf{h}}_t = \tanh(\mathbf{W}_2 \mathbf{x}_t + \mathbf{W}_4 \vec{\mathbf{h}}_{t-1} + \vec{\mathbf{b}}_o) \\ \overset{\leftarrow}{\mathbf{h}}_t = \tanh(\mathbf{W}_1 \mathbf{x}_t + \mathbf{W}_3 \overset{\leftarrow}{\mathbf{h}}_{t+1} + \overset{\leftarrow}{\mathbf{b}}_o) \end{cases} \quad (4)$$

$$\mathbf{H}_t = \vec{\mathbf{h}}_t \oplus \overset{\leftarrow}{\mathbf{h}}_t \quad (5)$$

式中: $\vec{\mathbf{h}}_{t-1}$ 、 $\overset{\leftarrow}{\mathbf{h}}_{t+1}$ 分别为 $t-1$ 时刻前向隐藏层状态和 $t+1$ 时刻后向隐藏层状态; $\vec{\mathbf{h}}_t$ 、 $\overset{\leftarrow}{\mathbf{h}}_t$ 分别为 t 时刻前向隐藏层状态和后向隐藏层状态; \mathbf{W}_1 、 \mathbf{W}_2 、 \mathbf{W}_3 、 \mathbf{W}_4 为权重矩阵; \tanh 为激活函数, 用于创建新的候选值向量; $\vec{\mathbf{b}}_o$ 、 $\overset{\leftarrow}{\mathbf{b}}_o$ 分别为前向和后向偏置向量; \mathbf{H}_t 为 t 时刻的输出值; \oplus 表示拼接操作。

将 BiLSTM 网络模块嵌入 GAN, 利用其序列前后向输入特点, 获取上下文信息, 使得过去与未来隐藏层的状态都可以进行递归反馈, 从而能进一步挖掘当前量测数据同过去与未来时刻量测数据的内在联系, 以充分利用特征数据并提升模型补齐数据精度。

1.2 基于 GAT-BiLSTM 模型的状态估计方法

图神经网络(graph neural network, GNN)近年在拓扑相关领域得到广泛应用。GNN 采用消息传递机制, 在每一层卷积中, 节点能够聚合其相邻节点的特征信息。在电力系统分析中, 利用 GNN 将电网拓扑嵌入节点特征, 能够更有效地处理电网拓扑等非欧几里得数据^[28-30]。但在配电网状态估计中, 配电网拓扑变化频繁, GNN 在拓扑变化时聚合特征精确度不高, 导致状态估计性能下降。在配电网中不同量测点的重要性不同, 例如辐射型网络中根节点、T 接网络中联络节点的重要性更强。基于配电网的节点物理特征, GAT 能够为不同的相邻量测点分配差异化的注意力权重^[31-33]。当配电网拓扑改变导致邻接关系变化时, GAT 可自适应地调整这些注意力系数, 从而实现对拓扑频繁变化的自适应, 并展现出良好的泛化能力。

建立面向状态估计的 GAT 网络, 假设 x_i 和 x_j 为两个相邻节点, \mathbf{p}_i 、 \mathbf{p}_j 为两节点对应的特征向量, 通过权重矩阵 \mathbf{W}_i 、 \mathbf{W}_j 将特征映射到同一空间以计算注意力得分。

$$e_{i,j} = \sigma_1(\mathbf{W}_i \mathbf{p}_i \oplus \mathbf{W}_j \mathbf{p}_j) \quad (6)$$

式中: σ_1 为 LeakyReLU 激活函数; $e_{i,j}$ 为注意力得分, 表示节点 j 对节点 i 的重要程度。

对节点 i 的相邻节点集合 N_i 分别计算注意力得分后, 再进行归一化和融合, 得到注意力权重 $a_{i,j}$:

$$a_{i,j} = \text{Softmax}(e_{i,j}) = \frac{\exp(e_{i,j})}{\sum_{j \in N_i} \exp(e_{i,j})} \quad (7)$$

式中: Softmax 为归一化指数函数。

对节点 i 相邻节点特征进行加权求和, 得到节点 i 的最终特征向量 \mathbf{P}_i :

$$\mathbf{P}_i = \sigma_2 \left(\frac{1}{K} \sum_{j \in N_i} a_{i,j} \mathbf{W}_j \mathbf{p}_j \right) \quad (8)$$

式中: σ_2 为 ELU 激活函数; K 为 N_i 中的节点个数。

GAT 网络结合 BiLSTM 进一步提高了状态估计精准度和拓扑泛化性能。

2 基于 BiLSTM-GAN-GAT 模型的状态估计框架和流程

2.1 状态估计框架

基于第 1 章所提方法, 综合考虑配电网状态估计数据补全、拓扑泛化、时空相关性等特点, 设计图 1 所示 BiLSTM-GAN-GAT 模型。BiLSTM-GAN-GAT 模型主要由 BiLSTM+生成器、BiLSTM+判别器、数据处理层、两层 GAT、两层 BiLSTM、GNN 连接层等构成。图 1 中, \mathbf{H}'_t 为两层 BiLSTM 的输出; \mathbf{P}'_i 为两层 GAT 的输出。

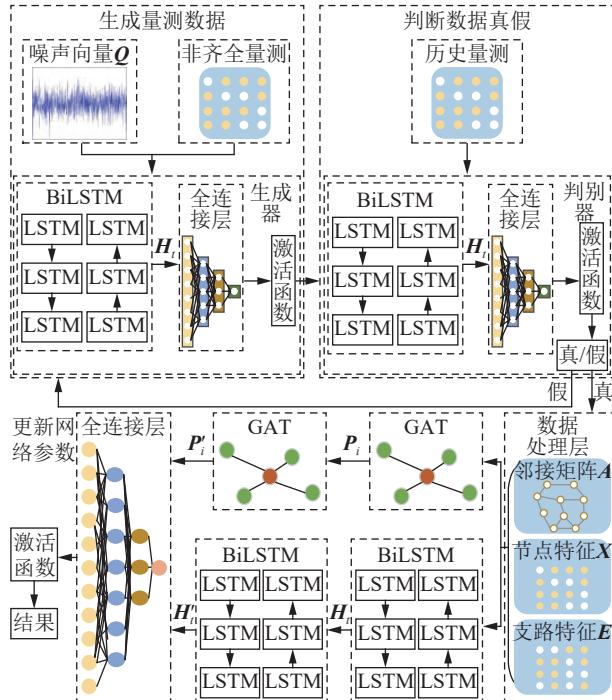


图 1 BiLSTM-GAN-GAT 模型框架

Fig.1 BiLSTM-GAN-GAT model structure

生成器层输入为遵循高斯分布的随机噪声序列和缺失部分信息的量测数据。首先, 使用一层包含 128 个神经元的 BiLSTM, 设定其时间步长与输入序列长度完全一致, 以确保模型能够有效捕捉序

列的双向依赖性。随后, 将 BiLSTM 的输出传递至一个全连接层, 以进一步提取与聚合特征。此过程中, 通过 4 层全连接层的递进处理, 并结合 Reshape 层重新调整张量的形状, 以满足后续处理的需要。为解决梯度消失问题, 在各层级间嵌入批量归一化层。此外, 还引入 Dropout 层, 以 0.2 的概率随机丢弃部分神经元, 从而防止过拟合。最后, 通过 tanh 激活函数对最终输出张量进行处理, 确保生成的数据维度与原始输入序列一致。

判别器层与生成器类似, 同样由一层包含 256 个神经元的 BiLSTM 和 4 层全连接层组成, 在层级之间使用 Dropout 层, 但不同的是判别器删除了批量归一化层, 使得输出数据的概率分布更广泛, 更利于提高识别数据真假的准确率。最后, 通过 Sigmoid 激活函数, 输出真实数据的概率。

数据处理层负责将不同历史断面下量测信息和拓扑转化为 $G(\mathbf{X}, \mathbf{A}, \mathbf{E})$ 形式。 \mathbf{X} 为电网节点的特征矩阵, 表示电网的节点信息; \mathbf{A} 为邻接矩阵, 用于描述电网拓扑; \mathbf{E} 为边权矩阵, 包含电网的支路信息。

在第一层 GAT 中, 计算节点 i 与其一阶相邻节点的空间注意力权重, 在第二层 GAT 中, 计算节点 i 与其二阶相邻节点的空间注意力权重。两层 BiLSTM 可以充分学习量测信息序列多层次时间特征, 然后将两部分特征拼接, 最后由 GNN 全连接层输出系统的节点电压幅值和节点电压相角。由于状态估计本质上是一个回归问题, 所以采用 Leaky-ReLU 作为全连接层的激活函数, 以防止非线性映射后神经元消亡, 从而加快模型训练速度。具体公式如下:

$$\hat{y} = \sigma_1(\mathbf{W}(\mathbf{H}'_t \oplus \mathbf{P}'_i) + \mathbf{b}) \quad (9)$$

式中: \hat{y} 为全连接层输出; \mathbf{W} 为权重矩阵; \mathbf{b} 为偏置量。

2.2 状态估计流程

文中所提基于 BiLSTM-GAN-GAT 模型的状态估计流程如图 2 所示。

具体步骤如下。

(1) 数据准备。选取不同历史时间断面下不同拓扑的配电网量测数据构建数据集, 并按照 9:1 的比例划分为训练集和测试集, 训练集用于训练 BiLSTM-GAN-GAT 模型, 测试集用于评估模型的性能。不失一般性地, 节点特征为包括节点电压幅值、节点电压相角、节点注入有功功率和无功功率的 4 维向量, 边特征为包括支路有功功率、支路无功功率、支路导纳的 3 维向量。考虑量测数据量纲的异构性对模型训练的影响和过拟合现象, 对数

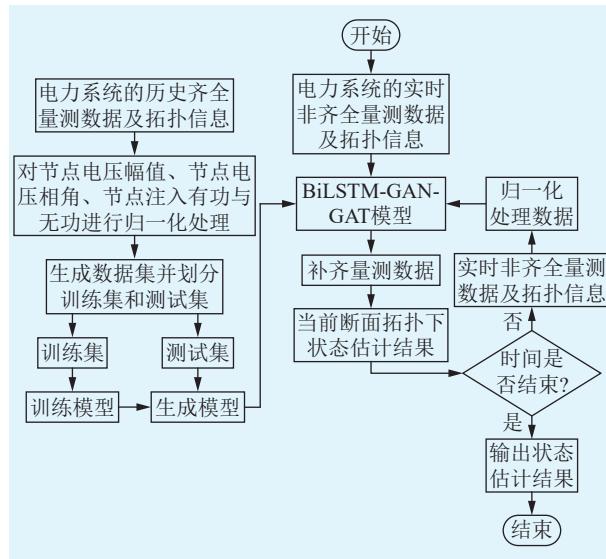


图 2 基于 BiLSTM-GAN-GAT 的状态估计方法流程

Fig.2 Flow chart of state estimation method based on BiLSTM-GAN-GAT

据进行归一化处理,具体公式如下:

$$u'_k = \frac{u_k - \min_k u_k}{\max_k u_k - \min_k u_k} \quad (10)$$

式中: u'_k 为第 k 个量测量归一化后的值; u_k 为第 k 个量测量的真实值。

(2) 模型准备。在模型训练前,确定 BiLSTM-GAN-GAT 模型的超参数,包括生成器、判别器、两层 GAT 和两层 BiLSTM。两层 BiLSTM 分别有 64 个和 128 个隐藏节点,对应两个 Dropout 层,丢弃概率分别设置为 0.2 和 0.3,同时可除去一些不重要的特征,且 BiLSTM 中 LSTM 层数为 3。采用 Adam 优化器,学习率设定为 0.001,训练轮数为 50,批次大小为 128。

(3) BiLSTM-GAN-GAT 模型离线训练。输入训练数据集,首先固定判别器、调整生成器参数以降低损失函数值,然后固定生成器、训练判别器以提高准确率,当两者损失函数值趋于稳定时,表示 GAN 部分训练完成;通过多层 GAT 和 BiLSTM,深入挖掘节点特征的时空关联性,利用全连接层将这些信息转换为节点电压幅值与相角的预测。为了评估模型的准确性,根据预测值与实际值的差异来计算损失函数,并采用反向传播算法优化模型的权重参数。损失函数选取均方差损失函数,公式如下:

$$L = \frac{1}{M} \sum_{m=1}^M (y_m - \hat{y}_m)^2 \quad (11)$$

式中: L 为损失值; M 为样本数量; y_m 为样本 m 的真实值; \hat{y}_m 为样本 m 的预测值。经过多次迭代训练,最终构建适用于量测数据缺失和拓扑时变的

BiLSTM-GAN-GAT 状态估计模型。

(4) 在线估计。将当前时间断面下的非齐全量测数据和拓扑信息输入到训练好的状态估计模型中,模型会自适应进行数据补齐并在线计算得到系统的状态量。

3 算例分析

3.1 算例设置

算例基于 IEEE 118 节点配电网系统,基准电压为 12.66 kV,基准功率为 10 MV·A。将卷积神经网络(convolutional neural network, CNN)、GAT 和 GAT-BiLSTM 算法作为对比方法,以验证文中算法在量测数据缺失和拓扑时变情况下的状态估计结果的有效性与优越性。为模拟配电网真实运行状态变化,文中负荷曲线来自某实际电网连续 400 h 的运行数据,以 20 min 为一个采样周期,共可获得 1 200 组采样数据,包括每个节点的电压幅值、电压相角、注入有功功率和无功功率的量测值。将前 1 080 组数据作为训练集,后 120 组数据作为测试集。文中以潮流计算得到的多断面数据作为真值,添加(0, 0.01)的正态随机误差模拟量测数据,将其与离线采集的拓扑数据结合生成多断面数据集,以相角为标签进行损失函数计算,并通过训练得到模型。以此为基础对 BiLSTM-GAN-GAT 模型进行训练。

测试的硬件平台为 PC 机,处理器为 Intel® Core™ i5-10210U CPU @ 1.60 GHz,内存为 16 GB,基于 Python 软件的 Pytorch 模块进行编程。

为更直观体现文中所提算法和其他算法的估计性能差异,对估计状态量计算平均相对误差,具体公式如下:

$$\bar{\delta} = \frac{1}{U} \sum_{l=1}^U \left| \frac{\hat{h}_k(l) - h_k(l)}{h_k(l)} \right| \times 100\% \quad (12)$$

式中: $\bar{\delta}$ 为平均相对误差; U 为总断面数; $\hat{h}_k(l)$ 为第 l 个断面下第 k 个状态估计结果; $h_k(l)$ 为第 l 个断面下第 k 个真实值。

3.2 补齐数据的正确性验证和对比

为验证文中所提数据补齐方法的正确性,在数据缺失比例为 20% 的情况下将文中算法与未补全数据的 GAT-BiLSTM 和使用常规 GAN 补齐数据后的 GAT-BiLSTM(记作 NGAN-GAT-BiLSTM)进行对比,所得各节点状态估计结果如图 3 所示。电压幅值平均相对误差和电压相角平均相对误差分别如表 1 和表 2 所示。

由图 3 可知,当量测数据缺失时, GAT-BiLSTM 方法未对数据补齐,估计结果较大程度地偏离了系

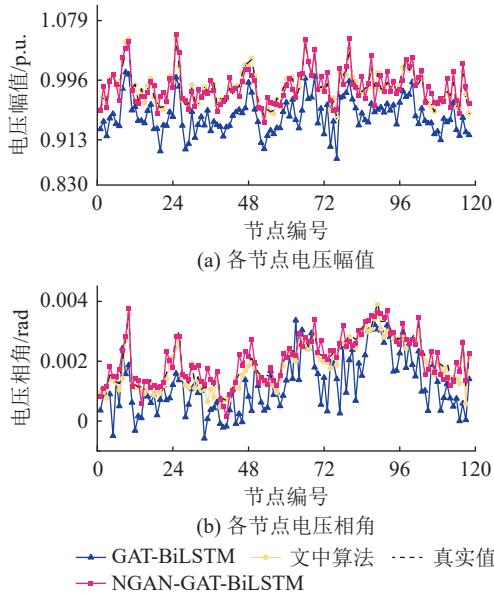


图 3 量测数据缺失下 118 节点系统各节点状态量

Fig.3 The state variables of 118-bus system with incomplete data

表 1 数据缺失下电压幅值估计误差

Table 1 Voltage amplitude estimation errors with incomplete data

算法	节点电压幅值 平均相对误差/%
文中算法	0.248 6
GAT-BiLSTM	4.950 7
NGAN-GAT-BiLSTM	0.845 3

表 2 数据缺失下电压相角估计误差

Table 2 Voltage phase angle estimation errors with incomplete data

算法	节点电压相角 平均相对误差/%
文中算法	0.311 5
GAT-BiLSTM	6.343 6
NGAN-GAT-BiLSTM	1.258 3

统真实状态, 估计效果较差; NGAN-GAT-BiLSTM 由于使用 GAN 对数据进行补齐, 平均相对误差较 GAT-BiLSTM 有很大提升; 而文中算法通过基于 BiLSTM 改进的 GAN 弥补了常规 GAN 忽略历史数据中时间序列信息的缺点, 提高了补齐数据的精度, 在量测数据缺失的情况下仍可以估计获得高精度的状态结果。

设定量测数据缺失比例为 20%、30%、40%、50%、60%, 计算各数据缺失比例下的电压幅值和电压相角估计误差, 如表 3 和表 4 所示。

由表 3 和表 4 可知, 当量测数据未完全缺失时, 文中算法可以估计得到较高精度的状态结果; 当缺失比例达到 20% 时, 幅值平均相对误差为

表 3 各数据缺失比例下电压幅值估计误差

Table 3 Voltage amplitude estimation errors at different proportions of incomplete data

数据缺失 比例/%	节点电压幅值 平均相对误差/%
20	0.248 6
30	0.417 2
40	1.034 2
50	1.689 4
60	3.587 4

表 4 各数据缺失比例下电压相角估计误差

Table 4 Voltage phase angle estimation errors at different proportions of incomplete data

数据缺失 比例/%	节点电压相角 平均相对误差/%
20	0.311 5
30	0.448 7
40	1.088 1
50	1.568 4
60	3.579 1

0.248 6%, 相角平均相对误差为 0.311 5%, 但当缺失比例达到 60% 时, 幅值平均相对误差为 3.587 4%, 相角平均相对误差为 3.579 1%, 因此文中所提方法的估计精度随着数据缺失比例的升高而下降。一般缺失比例在 30% 左右时可以满足工程应用要求。

3.3 拓扑时变下的正确性验证和对比

由于实际配电网运行中拓扑随时间频繁变化, 因此, 为验证文中算法在拓扑时变下的优越性, 对完整拓扑下的状态估计进行模拟仿真, 并与 WLS、CNN、GAT 和 GAT-LSTM 进行对比, 所得各节点状态估计结果如图 4 所示。各算法在完整拓扑下估计的电压幅值平均相对误差和电压相角平均相对误差分别如表 5 和表 6 所示。

由图 4 可知, 各算法在 IEEE 118 节点系统完整拓扑下均能实现状态估计, 但由于文中算法深入挖掘量测量和状态量的时空关系, 与其他算法相比, 具有更好的表现, 对比 WLS 和 CNN, 幅值估计精度分别提升 39.3% 和 35.1%, 相角估计精度分别提升 35.4% 和 29.0%。

进一步随机模拟表 7 所示的 4 种配电网拓扑变化场景, 每个拓扑选取 20 个不同时间断面下的量测数据。以随机选取的节点 20 为例进行分析, 并与 WLS、CNN、GAT 和 GAT-LSTM 进行对比, 具体结果如图 5 所示。各算法在拓扑时变下估计的电压幅值平均相对误差和电压相角平均相对误差分别如表 8 和表 9 所示。

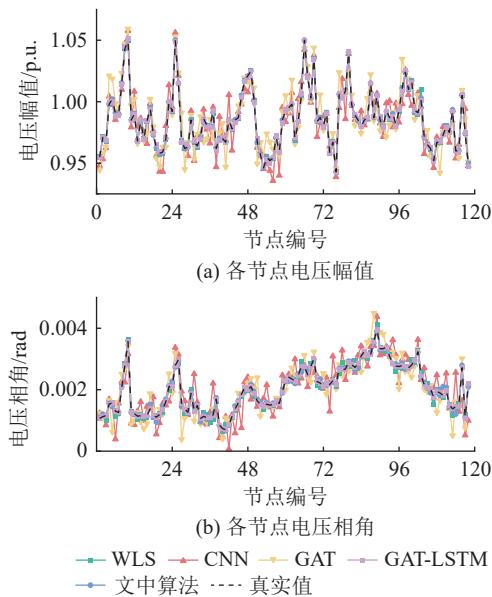


图 4 IEEE 118 节点系统完整拓扑下各节点状态量

Fig.4 State variables of IEEE 118-bus system with complete topology

表 5 IEEE 118 节点系统完整拓扑下电压幅值估计误差

Table 5 Voltage amplitude estimation errors of IEEE 118-bus system with complete topology

算法	节点电压幅值平均相对误差/%
文中算法	0.108 6
WLS	0.178 9
CNN	0.167 4
GAT	0.141 7
GAT-LSTM	0.127 8

表 6 IEEE 118 节点系统完整拓扑下电压相角估计误差

Table 6 Voltage phase angle estimation errors of IEEE 118-bus system with complete topology

算法	节点电压相角平均相对误差/%
文中算法	0.146 4
WLS	0.226 5
CNN	0.206 2
GAT	0.194 9
GAT-LSTM	0.179 3

表 7 拓扑变化场景

Table 7 Topological time-varying conditions

时间断面	拓扑
1—20	拓扑1: 支路2—4断开
21—40	拓扑2: 支路23—24断开
41—60	拓扑3: 支路76—77断开
61—80	拓扑4: 支路7—8、支路33—34、支路58—59和支路91—92断开

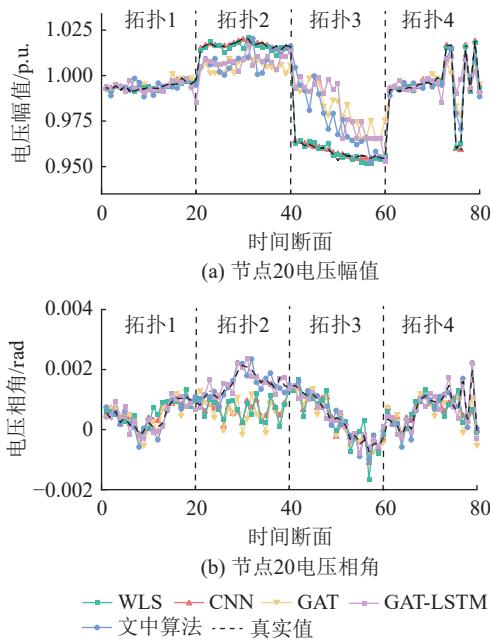


图 5 拓扑时变下节点 20 状态估计情况

Fig.5 State estimation of node 20 in the time-varying topology

表 8 IEEE 118 节点系统拓扑时变下电压幅值估计误差

Table 8 Voltage amplitude estimation errors of IEEE 118-bus system with time-varying topology

算法	节点电压幅值平均相对误差/%			
	拓扑1	拓扑2	拓扑3	拓扑4
文中算法	0.125 3	0.143 5	0.133 7	0.154 8
WLS	0.875 6	2.346 2	4.782 5	7.894 9
CNN	0.759 7	2.234 6	4.652 1	7.459 3
GAT	0.366 4	1.519 9	1.957 4	4.881 6
GAT-LSTM	0.164 5	0.189 4	0.177 8	0.349 6

表 9 IEEE 118 节点系统拓扑时变下电压相角估计误差

Table 9 Voltage phase angle estimation errors of IEEE 118-bus system with time-varying topology

算法	节点电压相角平均相对误差/%			
	拓扑1	拓扑2	拓扑3	拓扑4
文中算法	0.151 4	0.167 3	0.162 3	0.181 2
WLS	1.046 9	1.515 6	1.197 4	4.783 6
CNN	0.873 5	1.375 3	1.084 9	4.531 7
GAT	0.423 5	0.538 5	0.637 5	3.872 3
GAT-LSTM	0.201 9	0.203 2	0.246 7	0.775 1

由图 5 可知, 不同时间断面下某条支路断开, WLS 和 CNN 估计精度明显下降, GAT 由于可以自适应拓扑空间变化, 精度较前两种算法高; GAT-LSTM 进一步结合时空, 生成更为全面的信息特征表达式, 在估计精度上较前 3 种算法有明显提升。而文中提出的 GAT-BiLSTM 既考虑自适应拓扑空间的变化, 又在时间维度上双向提取信息特征, 深

入挖掘学习量测量和状态量的时空关联性,因此能获得更精确的状态估计结果。当断开支路数增加时,文中所提算法精度略有降低,但仍在可接受范围内,且较其他4种算法有明显优势。

3.4 分布式电源接入后状态估计的正确性验证

在编号为41的节点处接入额定功率为50 kW的风力发电机,功率因数为0.9;在编号为87的节点处接入容量为40 kW的光伏发电系统,功率因数为0.8。将分布式电源等效为PQ节点,对各节点的状态估计进行模拟仿真,并与WLS、CNN进行对比,所得结果如图6所示。各算法估计的电压幅值平均相对误差和电压相角平均相对误差分别如表10和表11所示。

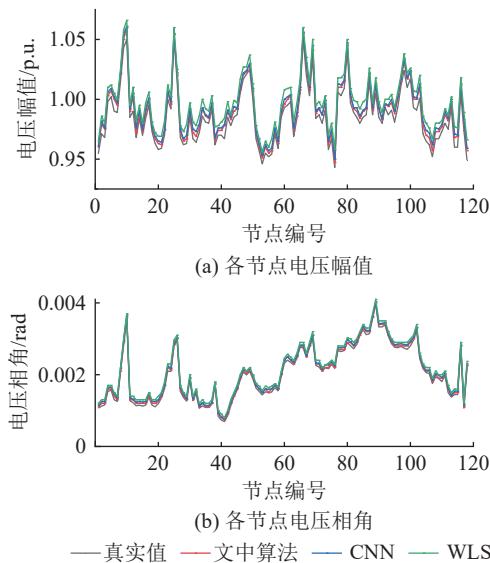


图6 分布式电源接入下118节点状态估计情况
Fig.6 State estimation of the 118-bus system with distributed generation integration

表10 IEEE 118节点系统电压幅值估计误差
Table 10 Voltage amplitude estimation errors of IEEE 118-bus system

算法	节点电压幅值 平均相对误差/%
文中算法	0.116 9
WLS	0.222 7
CNN	0.170 1

表11 IEEE 118节点系统电压相角估计误差
Table 11 Voltage phase angle estimation errors of IEEE 118-bus system

算法	节点电压相角 平均相对误差/%
文中算法	0.154 1
WLS	0.250 9
CNN	0.196 2

由图6可知,分布式电源接入后,文中算法估计得到的各节点电压幅值与电压相角均接近于真实值,估计误差较WLS和CNN算法更低,在一定程度上验证了文中算法对含随机功率源配电网状态估计的可行性和有效性。

3.5 算法计算时间对比

传统的状态估计方法依赖雅可比矩阵的迭代过程,以精确逼近所需的状态向量,然而,当系统复杂度增加时,其计算量也随之显著增长。文中算法引入数据驱动的思想,学习量测量和状态量之间的潜在关联,无须对系统内部进行物理建模,显著提升了系统在线评估效率。各系统完整拓扑下使用WLS、CNN和文中算法估计的时间如表12所示。

表12 各系统完整拓扑下估计时间比较
Table 12 Comparison of estimation time values under the complete topology of each system

测试系统	估计耗时/s		
	WLS	CNN	文中算法
IEEE 118	0.007 3	0.013 4	0.016 8
IEEE 300	0.058 5	0.015 9	0.018 1
IEEE 2786	0.484 6	0.018 2	0.021 2
IEEE 8449	2.923 9	0.020 7	0.022 6
IEEE 13984	5.834 9	0.021 5	0.023 4

由表12可知,对于较小规模的电力系统,文中算法在估计效率上的优势并不显著。然而,随着系统规模的逐步扩大,文中算法的估计耗时却保持相对稳定,未出现显著增长。相比之下,传统的WLS算法在处理大规模系统时,其估计时间显著增加。文中算法由于引入改进的GAN以生成缺失量测数据,计算量大于CNN,致使计算时间高于CNN,但仍在可接受范围之内。以IEEE 300节点系统为例,文中算法在估计耗时上较WLS缩短了69.06%。在面对如IEEE 13984节点的大型系统时,算法仍然高效,表明文中算法在大型电网状态估计中具有较好的可行性。

4 结论

文中提出融合改进GAN与GAT的状态估计模型。该方法能学习量测量和状态量之间复杂的时空耦合关系,实现在拓扑时变下的准确状态估计。通过在IEEE 118节点系统下进行算法仿真,得到以下结论:

(1) 文中将BiLSTM嵌入GAN,能够充分学习历史量测数据的前向和后向时序信息,增强模型的非线性拟合能力,提高补齐数据的精度,且估计精

度随数据缺失比例提升而降低,一般在缺失比例30%左右时仍可以满足工程应用要求。

(2) 将 GAT 和 BiLSTM 引入数据驱动状态估计模型,自适应地根据配电网拓扑变化改变节点间注意力系数,充分学习量测数据前向和后向的时序信息,生成更全面的时空信息表达式。

(3) 文中算法在新型配电网状态估计中有较好的应用前景,与传统 WLS 算法相比,在保证计算精度的同时,能够大幅缩短大型电网状态估计中的计算时间,满足在线应用要求,在分布式电源等随机功率源接入后也表现出良好的性能。

致 谢

本文得到国网江苏省电力有限公司科技项目(J2022133)资助,谨此致谢!

参考文献:

- [1] 魏新迟,秦龙宇,方陈,等.配电网同步相量测量技术与应用综述[J].电力建设,2023,44(5): 13-22.
WEI Xinchi, QIN Longyu, FANG Chen, et al. Review of the synchronous measurement technology and its application in distribution networks[J]. Electric Power Construction, 2023, 44(5): 13-22.
- [2] 袁海山,叶昀,陈有强,等.基于能源互联网技术的电网分布式电源布置研究[J].电网与清洁能源,2023,39(3): 136-142.
YUAN Haishan, YE Yun, CHEN Youqiang, et al. Research on grid distributed generation layout based on energy Internet technology[J]. Advances of Power System & Hydroelectric Engineering, 2023, 39(3): 136-142.
- [3] 刘敬敬,白牧可,樊文婷,等.基于马尔可夫链与改进最小路法的柔性配电网运行可靠性评估[J].供用电,2024,41(9): 24-33,52.
LIU Jingjing, BAI Muko, FAN Wenting, et al. Operational reliability assessment of flexible distribution network based on Markov chain and improved minimum path method[J]. Distribution & Utilization, 2024, 41(9): 24-33,52.
- [4] 王玲,朱远哲,杜婉琳,等.考虑分布式电源接入的电压暂降状态估计与监测装置优化配置方法[J].广东电力,2024,37(1): 60-67.
WANG Ling, ZHU Yuanzhe, DU Wanlin, et al. Method for voltage sag state estimation and monitoring device configuration considering DG access[J]. Guangdong Electric Power, 2024, 37(1): 60-67.
- [5] 吴振升,刘超,胡金东,等.基于合作博弈和改进属性数学的新型配电系统运行状态评估方法[J].供用电,2025,42(10): 108-117.
WU Zhensheng, LIU Chao, HU Jindong, et al. A new power distribution system operating state evaluation method based on cooperative game and improved attribute mathematics[J]. Distribution & Utilization, 2025, 42(10): 108-117.
- [6] 黄蔓云,郭镜玮,臧海祥,等.基于消息传递图神经网络的电力系统状态估计[J].电网技术,2023,47(11): 4396-4409.
HUANG Manyun, GUO Jingwei, ZANG Haixiang, et al. State estimation of power system based on a message passing neural network[J]. Power System Technology, 2023, 47(11): 4396-4409.
- [7] 刘艺娴,王玉彬,杨强.基于门控图神经网络的高容错配电网状态估计方法[J].综合智慧能源,2023(6): 1-8.
LIU Yixian, WANG Yubin, YANG Qiang. High fault-tolerant distribution network state estimation method based on gated graph neural network[J]. Integrated Intelligent Energy, 2023(6): 1-8.
- [8] 杨雄,方鑫,汪家铭,等.考虑配电变压器变比误差的配电网多断面联合状态估计[J].广东电力,2024,37(6): 87-94.
YANG Xiong, FANG Xin, WANG Jiaming, et al. Distribution network state estimation with multi-scan measurements considering tap ratio error of distribution transformers[J]. Guangdong Electric Power, 2024, 37(6): 87-94.
- [9] 何振武,姜飞,欧阳卫,等.基于自适应分区和SFVMD-LSTM 伪量测建模的新型配电系统抗差状态估计[J].电力建设,2024,45(10): 78-89.
HE Zhenwu, JIANG Fei, OUYANG Wei, et al. Novel distribution system robust state estimation based on adaptive partitioning and SFVMD-LSTM pseudo-measurement modeling[J]. Electric Power Construction, 2024, 45(10): 78-89.
- [10] 高丽萍,闫珺,衡东强,等.基于广义 Benders 分解的新能源接入配电网混合状态估计研究[J].电力电容器与无功补偿,2025,46(5): 45-53.
GAO Liping, YAN Jun, HENG Dongqiang, et al. Research on hybrid state estimation of distribution networks with renewable energy integration based on generalized Benders decomposition[J]. Power Capacitor & Reactive Power Compensation, 2025, 46(5): 45-53.
- [11] 宋雨露,樊艳芳,刘雨佳,等.基于深度神经网络-近似线性网络混合模型的电力系统状态估计方法[J].科学技术与工程,2022,22(25): 11041-11048.
SONG Yulu, FAN Yanfang, LIU Yujia, et al. Power system state estimation method based on deep neural network-proline network hybrid model[J]. Science Technology and Engineering, 2022, 22(25): 11041-11048.
- [12] 王泽,张玉敏,吉兴全,等.基于深度学习与内核岭回归的电力系统鲁棒状态估计[J].高电压技术,2022,48(4): 1332-1342.
WANG Ze, ZHANG Yumin, JI Xingquan, et al. Robust state estimation of power system based on deep learning and kernel ridge regression[J]. High Voltage Engineering, 2022, 48(4): 1332-1342.
- [13] 焦昊,赵佳伟,韦磊,等.基于深度迁移学习的电力系统暂态状态估计[J].电力建设,2025,46(1): 97-106.
JIAO Hao, ZHAO Jiawei, WEI Lei, et al. Transient state estimation for power system based on deep transfer learning[J]. Electric Power Construction, 2025, 46(1): 97-106.

- [14] 刘志坚,陶韵旭,刘航,等.基于双通道生成对抗网络的城市用电负荷缺失数据补全方法[J].电力系统自动化,2024,48(17): 161-170.
LIU Zhijian, TAO Yunxu, LIU Hang, et al. Completion method for missing urban power load data based on double-channel generative adversarial networks[J]. Automation of Electric Power Systems, 2024, 48(17): 161-170.
- [15] 张科鑫,窦晓波,李炜祺,等.基于量测数据补全的有源配电网电压优化技术[J].电力自动化设备,2023,43(11): 67-74.
ZHANG Kexin, DOU Xiaobo, LI Weiqi, et al. Voltage optimization technology of active distribution network based on measurement data completion[J]. Electric Power Automation Equipment, 2023, 43(11): 67-74.
- [16] 周建新,王鸿滔.基于相似日理论和改进 PSO-LSTM 模型的风电短期出力预测[J].中国工程机械学报,2024,22(4): 447-451,457.
ZHOU Jianxin, WANG Hongtao. Short-term wind power prediction based on similar day theory and improved PSO-LSTM model[J]. Chinese Journal of Construction Machinery, 2024, 22(4): 447-451,457.
- [17] 欧旭鹏,唐云,张凯,等.基于 CEEMDAN-IDOA-BiLSTM 的超短期风电功率预测[J].电网与清洁能源,2023,39(11): 142-150.
OU Xupeng, TANG Yun, ZHANG Kai, et al. The ultra short term wind power prediction based on CEEMDAN-IDOA-BiLSTM[J]. Power System and Clean Energy, 2023, 39(11): 142-150.
- [18] 李佳玮,王小君,和敬涵,等.基于图注意力网络的配电网故障定位方法[J].电网技术,2021,45(6): 2113-2121.
LI Jiawei, WANG Xiaojun, HE Jinghan, et al. Distribution network fault location based on graph attention network[J]. Power System Technology, 2021, 45(6): 2113-2121.
- [19] 陈晓龙,孙丽蓉,李永丽,等.基于图注意力网络和一致性风险控制的配电网故障区段定位方法[J].电网技术,2023,47(12): 4866-4877.
CHEN Xiaolong, SUN Lirong, LI Yongli, et al. A fault section location method based on graph attention network and conformal risk control in distribution network[J]. Power System Technology, 2023, 47(12): 4866-4877.
- [20] 詹兆康,胡旭光,赵浩然,等.基于多变量时空融合网络的风机数据缺失值插补研究[J].自动化学报,2024,50(6): 1171-1184.
ZHAN Zhaokang, HU Xuguang, ZHAO Haoran, et al. Study of missing value imputation in wind turbine data based on multi-variate spatiotemporal integration network[J]. Acta Automatica Sinica, 2024, 50(6): 1171-1184.
- [21] 臧海祥,郭镜伟,黄蔓云,等.基于改进 Wasserstein 生成式对抗网络的电力系统不良数据辨识[J].电力自动化设备,2022,42(9): 50-56, 110.
ZANG Haixiang, GUO Jingwei, HUANG Manyun, et al. Bad data identification of power system based on WGAN-GP[J]. Electric Power Automation Equipment, 2022, 42(9): 50-56, 110.
- [22] 黄蔓云,王天昊,卫志农,等.基于长短期记忆网络的 UKF 动态谐波状态估计[J].电力系统保护与控制,2022,50(11): 1-11.
HUANG Manyun, WANG Tianhao, WEI Zhinong, et al. Dynamic harmonic state estimation of an unscented Kalman filter based on long short-term memory neural networks[J]. Power System Protection and Control, 2022, 50(11): 1-11.
- [23] 唐清苇,向月,代佳琨,等.基于 CNN-LSTM 的风电场发电功率迁移预测方法[J].工程科学与技术,2024,56(2): 91-99.
TANG Qingwei, XIANG Yue, DAI Jiakun, et al. Wind farm power transfer forecasting method based on CNN-LSTM[J]. Advanced Engineering Sciences, 2024, 56(2): 91-99.
- [24] 凌佳凯,章逸舟,胡金峰,等.基于 CNN-LSTM-Attention 的配电网拓扑实时辨识方法[J].浙江电力,2024,43(3): 84-94.
LING Jiakai, ZHANG Yizhou, HU Jinfeng, et al. A real-time topology identification method of distribution networks based on CNN-LSTM-Attention[J]. Zhejiang Electric Power, 2024, 43(3): 84-94.
- [25] 杨龙,吴红斌,丁明,等.新能源电网中考虑特征选择的 Bi-LSTM 网络短期负荷预测[J].电力系统自动化,2021,45(3): 166-173.
YANG Long, WU Hongbin, DING Ming, et al. Short-term load forecasting in renewable energy grid based on bi-directional long short-term memory network considering feature selection[J]. Automation of Electric Power Systems, 2021, 45(3): 166-173.
- [26] 刘杰,从兰美,夏远洋,等.基于 DBO-VMD 和 IWOA-BiLSTM 神经网络组合模型的短期电力负荷预测[J].电力系统保护与控制,2024,52(8): 123-133.
LIU Jie, CONG Lanmei, XIA Yuanyang, et al. Short-term power load prediction based on DBO-VMD and an IWOA-BiLSTM neural network combination model[J]. Power System Protection and Control, 2024, 52(8): 123-133.
- [27] 刘义艳,李国良,代杰.基于 VMD-TCN-BiLSTM-Attention 的短期电力负荷预测[J].智慧电力,2025,53(10): 87-94.
LIU Yiyian, LI Guoliang, DAI Jie. Short-term power load forecasting based on VMD-TCN-BiLSTM-Attention[J]. Smart Power, 2025, 53(10): 87-94.
- [28] WANG L, ZHOU Q, JIN S S. Physics-guided deep learning for power system state estimation[J]. *Journal of Modern Power Systems and Clean Energy*, 2020, 8(4): 607-615.
- [29] 张汪洋,樊艳芳,侯俊杰,等.基于集成深度神经网络的配电网分布式状态估计方法[J].电力系统保护与控制,2024,52(3): 128-140.
ZHANG Wangyang, FAN Yanfang, HOU Junjie, et al. Distribution network distributed state estimation method based on an integrated deep neural network[J]. Power System Protection and Control, 2024, 52(3): 128-140.
- [30] 俞文帅,张晓华,卫志农,等.基于深度神经网络的电力系统

- 快速状态估计[J]. 电网技术, 2021, 45(7): 2551-2561.
- YU Wenshuai, ZHANG Xiaohua, WEI Zhinong, et al. Fast state estimation for power system based on deep neural network[J]. Power System Technology, 2021, 45(7): 2551-2561.
- [31] 梁伟宸, 王亚娟, 周放歌, 等. 基于多核图注意力网络的有源配电网故障定位方法[J]. 现代电力, 2025, 42(4): 788-798.
- LIANG Weichen, WANG Yajuan, ZHOU Fangge, et al. Fault location method for active distribution network based on graph kernels attention network[J]. Modern Electric Power, 2025, 42(4): 788-798.
- [32] 钟智, 管霖, 苏寅生, 等. 基于图注意力深度网络的电力系统暂态稳定评估[J]. 电网技术, 2021, 45(6): 2122-2130.
- ZHONG Zhi, GUAN Lin, SU Yinsheng, et al. Power system transient stability assessment based on graph attention deep network[J]. Power System Technology, 2021, 45(6): 2122-2130.
- [33] 吕奇峰, 陈颖, 肖潭南, 等. 基于图注意力网络的配电网超分辨率量测生成方法[J]. 电力系统自动化, 2023, 47(5): 26-34.
- LYU Qifeng, CHEN Ying, XIAO Tannan, et al. Super-resolution measurement generation method for distribution network based on graph attention network[J]. Automation of Electric Power Systems, 2023, 47(5): 26-34.

作者简介:



赵奇

赵奇(1989), 男, 学士, 高级工程师, 从事配电网自动化工作(E-mail: qzhao1989@163.com);

田江(1981), 男, 硕士, 高级工程师, 从事调度自动化工作;

徐秀之(1979), 男, 硕士, 工程师, 从事调度自动化工作。

Distribution network state estimation by fusing improved generative adversarial network and graph attention network

ZHAO Qi, TIAN Jiang, XU Xiuzhi, LÜ Yang

(State Grid Suzhou Power Supply Company of Jiangsu Electric Power Co., Ltd., Suzhou 215004, China)

Abstract: The distribution network is connected to new elements such as distributed new energy and controllable resources, and the traditional state estimation model is faced with new problems such as incomplete measurement information, frequent topology changes of the distribution network and load time series fluctuations, which lead to reduced accuracy of the model estimation. Therefore, a method of distribution network state estimation by fusing improved generative adversarial network and graph attention network is proposed in this paper. Firstly, topological parameters and measurement information in different historical time sections are selected to generate data sets. The incomplete measurement information is filled by introducing the bidirectional long short-term memory (BiLSTM) network into the generative adversarial network. Secondly, the graph attention network is used to capture the spatial dynamic relationship between the nodes adaptively, and the bidirectional long short-term memory network is used to fully excavate the time-coupling relationship of the cross-sectional sequence information in different time sections. These networks are concatenated to form the spatiotemporal feature expression of the measurement to the state, and the state estimation model of the improved graph neural network is obtained. Finally, simulation experiments are carried out in IEEE 118-bus system, and compared with other neural network algorithms such as convolutional neural network and graph attention network. The results show that the proposed algorithm has better performance in the case of missing data and time-varying topology than other neural network algorithms.

Keywords: state estimation; generative adversarial network; graph neural network; attention mechanism; bidirectional long short-term memory (BiLSTM) network; space-time modeling

(编辑 陆海霞)