

DOI:10.11784/tdxbz202407017

基于分类时序生成对抗插补网络的可解释配电网拓扑辨识

苏鑫¹, 颜伟¹, 张栩², 谭洪³

(1. 输配电装备技术全国重点实验室(重庆大学), 重庆 400044;

2. 中国科学院深圳先进技术研究院, 深圳 518000; 3. 三峡大学电气与新能源学院, 宜昌 443002)

摘要: 有源配电网的量测噪声和通讯故障会导致量测数据缺乏精确性和完整性, 而深度学习模型应用于配电网拓扑辨识又存在“黑盒”模型导致的可信度偏低问题。为了解决这些问题, 提出了一种基于分类时序生成对抗插补网络(CTGAIN)的可解释配电网拓扑辨识方法。该方法采用节点注入功率伪量测和局部电流向量的时序量测数据, 设计了由两个级联的神经网络构成的 CTGAIN。其基于双向循环 GRU(Bi-GRU)构建生成器, 并利用序列数据的前向和后向信息结合缺失掩码进行缺失值插补; 基于 Transformer 构建判别器, 通过多头注意力机制对生成器的插补结果进行拓扑辨识与缺失掩码预测; 再通过复合损失函数对 CTGAIN 进行联合优化, 从而在保持插补精度的同时提升拓扑辨识的准确性。此外, 在 Transformer 中引入双重注意力机制和多标签积分梯度, 实现了拓扑状态关联特征的重要性评价与解释。其中, 双重注意力机制实时优化注意力权重, 动态衡量特征重要性; 积分梯度则通过累积特征梯度, 精准识别与开关状态相关的重要特征。最后, 对修改后的 IEEE 33 节点和 69 节点算例进行仿真实验。在不同噪声水平下, 其相较次佳模型辨识正确率平均提高了 3%; 在量测特征值随机缺失 50%时, 其能保持 95%以上的辨识正确率; 在分布式电源(DER)渗透率为 70%的情况下, 其能保持 90%以上的辨识正确率。实验结果验证了该方法对不同噪声水平、不同量测特征值缺失和不同比例的分布式电源渗透率的适应性。

关键词: 配电网; 拓扑辨识; 时序生成对抗插补网络; 可解释

中图分类号: TM711

文献标志码: A

文章编号: 0493-2137(2025)07-0704-12

Interpretable Distribution Network Topology Identification Classification-Based Temporal Generative Adversarial Imputation Network

Su Xin¹, Yan Wei¹, Zhang Xu², Tan Hong³

(1. State Key Laboratory of Power Transmission Equipment Technology (Chongqing University), Chongqing 400044,

China; 2. Shenzhen Institute of Advanced Technology, China Academy of Sciences, Shenzhen 518000, China;

3. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: Measurement noise and communication failures in active distribution networks compromise the accuracy and completeness of measurement data. Deep learning models for topology identification often lack credibility due to their “black-box” nature. To address these issues, an interpretable topology identification method utilizing the classification-based temporal generative adversarial imputation network (CTGAIN) was proposed. This method leverages temporal data, including pseudo-measurements of nodal injected power and local current vectors. CTGAIN consists of two cascaded neural networks: a generator based on a bidirectional gated recurrent unit (Bi-GRU), which utilizes forward and backward sequence information and includes a missing mask for value imputation, and a discriminator built with a Transformer that employs multi-head attention mechanisms to identify topology and predict missing masks based on the generator’s imputed results. A composite loss function jointly optimizes CTGAIN, enhancing both imputation precision and topology identification accuracy. The Transformer incorporates dual attention

收稿日期: 2024-07-25; 修回日期: 2024-11-29.

作者简介: 苏鑫(1992—), 男, 博士研究生, 396729982@qq.com.

通信作者: 颜伟, cqyanwei@cqu.edu.cn.

基金项目: 南方电网公司科技资助项目(031900KK5222204).

Supported by the Science and Technology Project of CSG (No. 031900KK5222204).

mechanisms and multilabel integrated gradients to evaluate and interpret the importance of features related to topology states. The dual attention mechanisms dynamically adjust attention weights to assess feature importance in real time, while the integrated gradients accumulate feature gradients to highlight critical features associated with switch states. Simulations on modified IEEE 33-bus and 69-bus systems show that the proposed method achieves an average identification accuracy 3% higher than the second-best model across various noise levels. It maintains over 95% accuracy even when 50% of measurement features are randomly missing and achieves over 90% accuracy with a distributed energy resource (DER) penetration rate of 70%. These results demonstrate the method's adaptability to different noise levels, missing measurement features, and DER penetration rates.

Keywords: distribution network; topology identification; temporal generative adversarial imputation network (TGAIN); interpretable

随着分布式发电、可控负载、电动汽车接入配电网及需求响应技术的应用,配电网拓扑变化愈发频繁^[1]。然而,实际配电网中量测噪声和通讯故障会导致量测数据缺乏精确性和完整性,且由于成本原因,配电网中难以配置足够多的高级量测设备。因此,在误差大、缺失数据多、可观性弱的量测条件下实现配电网拓扑的可解释鲁棒辨识,是配网拓扑辨识方法研究亟待解决的一个关键问题。

现有配电网拓扑辨识方法主要分为两类,第1类是基于电力系统状态估计的拓扑辨识方法^[2-3],该方法需要满足系统可观条件,且存在计算效率低、实时性差等问题^[4]。难以在量测冗余度低且拓扑频繁变化的条件下,满足配电网拓扑辨识的准确性和快速性要求。相比之下,第2类是基于配电网量测数据驱动的拓扑辨识方法^[4-9]。文献[5-6]使用局部电流向量和源荷功率伪量测,将拓扑辨识问题简化为构建混合整数规划方程来求解未知开关状态。文献[6-9]分别使用深度神经网络、一维卷积神经网络、二维卷积神经网络、树模型进行拓扑辨识。然而,这些方法没有考虑量测数据缺失问题,而量测数据的缺失会显著影响拓扑辨识的精度。文献[10]提出使用 iTransformer 进行量测数据缺失值的插补,并使用多层感知机进行拓扑辨识。文献[11]提出采用时序降噪自编码器进行量测插补,并使用卷积神经网络进行拓扑辨识。但上述方法是两阶段的拓扑辨识,插补和分类是两个独立的优化过程。现实中有些缺失数据对拓扑辨识精度影响较大,有些缺失数据对拓扑辨识精度影响较小,不仅是要提高缺失数据插补的总体准确性,更是要提高对辨识精度影响较大的缺失数据插补准确性。文献[12]提出了结合生成对抗网络与马尔可夫毯模型的拓扑辨识方法的拓扑辨识方法,通过构建马尔可夫毯模型判别器引导量测插补,同时量测插补能提升拓扑辨识分类的精确性,但该方法量测插补中未考虑时序关系,不适用于多量测断面输入。Transformer 因其强

大的时间序列建模能力,已被应用于电力系统负荷预测、故障诊断等电力领域中^[13-14],而利用其进行拓扑辨识的研究尚少。现有基于深度学习的拓扑辨识方法具有“黑箱”结构,缺乏对其内部提取特征的显示和解释,研究人员只能获得拓扑辨识结果,却无法感知和解释影响拓扑结果的关键特征量。因此,有必要研究可解释^[15]的无模型数据驱动拓扑辨识方法。

为此,本文提出了基于分类时序生成插补网络(CTGAIN)的可解释配电网拓扑辨识方法。首先,采用时序量测数据,以提升配电网拓扑辨识在应对噪声和缺失数据方面的鲁棒性。然后,提出了结合双向循环 GRU (Bi-GRU) 生成器与 Transformer 判别器的插补辨识融合策略,通过多任务协同训练,以确保插补数据能稳定提升辨识精度。最后,在插补辨识融合策略基础上,设计了双重注意力机制和多标签积分梯度,实现了拓扑关联特征量重要性的准确解释。

1 时序量测数据模型及其缺失值插补问题

在 n 节点配电网中,单断面时序量测可以描述为 $\mathbf{X}_t = [p'_1, \dots, p'_n, q'_1, \dots, q'_n, I'_1, \dots, I'_k]$, 其中 \mathbf{X}_t 表示 $t \in [0, T]$ 时刻的断面量测,包含 n 个节点在 t 时刻的有功功率、无功功率和 k 个局部电流向量量测(包含电压幅值和相角), n 是配电网节点数量。因此,单断面时序量测的特征序量 $F = 2(n+k)$, 即 $\mathbf{X}_t \in \mathbf{R}_1^{2F}$ 。

假设在时间窗口内的拓扑保持不变,通过滑动时间窗口对时序量测进行划分,得到时窗样本 \mathbf{V}_i 为

$$\mathbf{V}_i = \begin{bmatrix} \mathbf{X}_t \\ \mathbf{X}_{t+1} \\ \vdots \\ \mathbf{X}_{t+W-1} \end{bmatrix} = \begin{bmatrix} x_{t,1} & x_{t,2} & \cdots & x_{t,F} \\ x_{t+1,1} & x_{t+1,2} & \cdots & x_{t+1,F} \\ \vdots & \vdots & \cdots & \vdots \\ x_{t+W-1,1} & x_{t+W-1,2} & \cdots & x_{t+W-1,F} \end{bmatrix} \quad (1)$$

式中: $x_{t,l}$ 为时窗样本 \mathbf{V}_i 中元素, $x_{t,l} \in \{0,1\}$, $t \in [0, T-W+1]$, $l \in [1, F]$; W 表示每个时窗样本包含的

连续量测断面数量(时间窗口长度); $i \in [1, N]$, N 是时间序列分割后的样本数量; $V_i \in \mathbf{R}^{W \times F}$. 预测目标是该时窗样本的各开关状态 $Y_i \in [0, 1, \dots, 1]$, 其反映了配网的拓扑. 神经网络用于建模量测数据与拓扑之间的映射关系, 并输出该时窗样本的拓扑.

$$Y_i = f(V_i) \quad (2)$$

式中: V_i 为第 i 个时窗样本; f 为映射函数; Y_i 为时窗样本下 f 预测的拓扑.

时序量测的缺失值插补问题可以描述为: 定义缺失掩码矩阵表示为 M_i 与时窗样本 V_i 同构, 则有

$$M_i = \begin{bmatrix} m_{i,1} & m_{i,2} & \dots & m_{i,F} \\ m_{i+1,1} & m_{i+1,2} & \dots & m_{i+1,F} \\ \vdots & \vdots & \dots & \vdots \\ m_{i+W-1,1} & m_{i+W-1,2} & \dots & m_{i+W-1,F} \end{bmatrix} \quad (3)$$

式中: $m_{i,l}$ 表示缺失掩码矩阵 M_i 中元素, $m_{i,l} \in \{0, 1\}$, $t \in [0, T - W + 1]$, $l \in [1, F]$, $m_{i,l} = 0$ 表示 $x_{i,l}$ 为缺失值; $m_{i,l} = 1$ 表示为 $x_{i,l}$ 为正常值. 缺失值插补即构建模型 F 使得

$$\hat{V}_i = M_i \odot V_i + (1 - M_i) \odot F(V_i) \quad (4)$$

式中: \odot 表示逐元素乘法; V_i 表示时窗样本; $M_i \odot V_i$ 表示当 M_i 中元素为 1 时, 使用原始数据中未缺失部分; $(1 - M_i) \odot F(V_i)$ 表示当 M_i 中元素为 0 时, 用插补模型 $F(V_i)$ 的结果; \hat{V}_i 表示最终重构的样本.

2 基于 Bi-GRU 与 Transformer 网络的时序生成对抗插补网络

2.1 分类时序生成插补网络的整体框架

生成插补网络 (generative adversarial imputation network, GAIN)^[16] 是一种生成式模型, 由生成器 (G) 和判别器 (D) 组成. 生成器 (G) 根据真实数据中已观测到的分量, 估算缺失的分量, 输出一个完整的向量. 判别器 (D) 接收这个完整的向量, 识别其中哪些分量是生成的估算值, 哪些是实际观测值. 但传统的生成插补网络未考虑时序关系, 也未与下游任务相关联. 这可能导致插补数据的不准确, 继而影响拓扑辨识精度. 因此, 本文将时序插补方法与拓扑辨识方法结合, 实现了端到端的缺失值插补与拓扑辨识. 图 1 展示了分类时序生成插补网络 (CTGAIN) 作用机理.

CTGAIN 模型是基于生成对抗网络的联合优化架构, 由两个级联的生成器和判别器组成. 首先, 生成器通过双向 GRU 对含缺失数据的时间窗样本并结合缺失掩码矩阵进行缺失值插补. 接着, 将插补结果与缺失掩码矩阵结合, 重构完整样本输入判别器. 然

后, 判别器通过多头注意力机制对重构样本进行拓扑辨识并预测缺失掩码矩阵. 最后, 生成器和判别器交替训练实现纳什均衡.




图 1 分类时序生成插补网络原理

Fig.1 Principle of the classification-based temporal generative adversarial imputation network

2.2 基于 Bi-GRU 的生成器插补模型

Bi-GRU 生成器插补模型如图 2 所示. 文献[17]提出了双向时序循环插补网络用于时序缺失数据补充, 考虑到循环神经网络存在训练参数较多、训练效率低、容易发生过拟合等问题, 本文利用 GRU^[18] 替换了循环神经网络 (RNN), 降低了网络参数量, 减少了训练时间, 提升了插补精度. 在双向 GRU 中, 正向 GRU 和反向 GRU 需要分别处理相同形状的输入序列, 且它们的处理公式一致. 正向 GRU 按照时间顺序从历史到未来进行处理, 而反向 GRU 则通过反转输入序列的时间断面, 按未来到历史顺序进行处理.




图 2 Bi-GRU 的生成器插补模型

Fig.2 Imputation model of Bi-GRU generator

首先, 输入含缺失的时窗样本 V_i , 每个时窗样本 V_i 包含若干个时间断面 X_t , 用全连接层对 V_i 的每个时间断面 X_t 生成插补的回归分量, 即

$$X'_t = W_n X_t + b_n \quad (5)$$

$$X_t^c = m_t \odot X_t + (1 - m_t) \odot X'_t \quad (6)$$

式中: W_n 、 b_n 分别代表全连接层可学习权重和偏差向量; m_t 为缺失掩码矩阵 M_i 的第 t 行掩码向量, 每个元素表示时间断面 X_t 的对应特征是否缺失, $m_t \in \{0, 1\}$; X'_t 为缺失数据的回归分量预测, 与 X_t 中的未缺失值相结合构成循环分量的输入 X_t^c .

接着,用 Bi-GRU 网络构建循环分量,其隐藏层输出状态 h_t 可以用公式描述为

$$h_t = \sigma(W_h[h_{t-1} \odot \gamma_t] + U_h[X_t^c \odot m_t] + b_h) \quad (7)$$

式中: W_h 、 U_h 和 b_h 均为隐藏层可学习权重; σ 为 Sigmoid 激活函数; h_{t-1} 为上一时刻的 GRU 神经网络输出; γ_t 为时间衰减因子,当存在连续缺失数据,则上一状态的 γ_t 相应降低; h_t 为缺失数据的插补预测,同时考虑了回归分量和循环分量。

最后,在预测层中,通过正向 GRU 计算正向插补损失;通过反向 GRU 计算反向插补损失;并考虑二者的预测差异计算了插补一致性损失,最终构成完整重构损失为

$$\ell_{\text{Re}} = \mathcal{L}(X_t, \hat{X}_t^f) + \mathcal{L}(X_t, \hat{X}_t^b) + \mathcal{L}(\hat{X}_t^f, \hat{X}_t^b) \quad (8)$$

式中: \mathcal{L} 为平均绝对误差; \hat{X}_t^f 和 \hat{X}_t^b 分别表示前向和后向 GRU 神经网络插补结果。

2.3 基于双重注意力 Transformer 模型判别器

判别器结构如图 3 所示, L 为超参数。

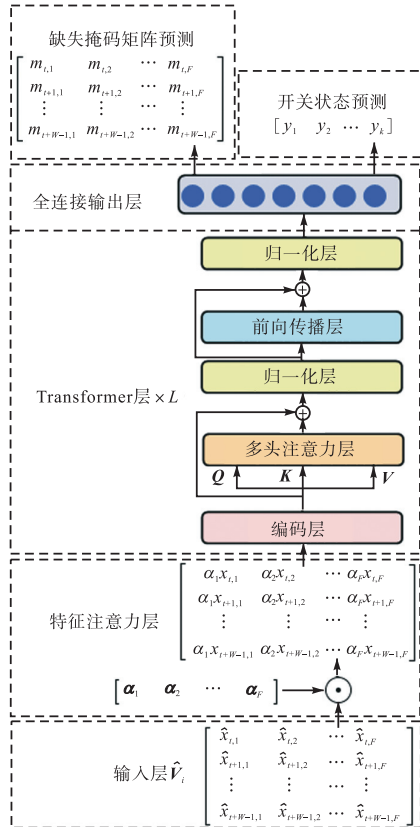


图 3 双重注意力的 Transformer 判别器

Fig.3 Transformer discriminator with dual-attention

首先,利用生成器的插补结果 $G(V_i)$ 来重构时窗样本 \hat{V}_i ,其公式为

$$\hat{V}_i = M_i \odot V_i + (1 - M_i) \odot G(V_i) \quad (9)$$

式中 $G(\cdot)$ 表示生成器输出。

其次,将重构的时窗样本 \hat{V}_i 输入到特征注意力层。在特征注意力层中,通过权重向量 α 对 \hat{V}_i 的每个时间断面 \hat{X}_t 动态分配注意力,将注意力集中于重要特征,减少甚至忽略无关特征。采用单层神经网络计算 t 时间断面的特征注意力系数向量 E_t 。

$$E_t = \sigma(W_{t2}\hat{X}_t + b_{t2}) \quad (10)$$

$$\alpha_{j,t} = \exp(e_{j,t}) / \sum_{j=1}^F e_{j,t} \quad (11)$$

式中: $E_t = [e_{1,t}, e_{2,t}, \dots, e_{F,t}]$; W_{t2} 和 b_{t2} 为可训练的特征注意力系数矩阵和偏置向量。通过式(11)对特征注意力系数进行归一化,获得各特征的注意力权重 $\alpha_{j,t}$ 。输入特征乘以注意力权重可得到特征注意力层输出 X_d 。

接着,Transformer 层进行特征提取和计算时序注意力权重。时序注意力权重表征各个时间断面量测对拓扑辨识结果的贡献程度,其核心为多头自注意力,第 r 个注意力头描述为

$$Q_r^{\text{att}} = X_d W_r^{Q,\text{att}}, K_r^{\text{att}} = X_d W_r^{K,\text{att}}, V_r^{\text{att}} = X_d W_r^{V,\text{att}} \quad (12)$$

$$A_r = \text{Softmax}\left(Q_r^{\text{att}} [K_r^{\text{att}}]^T / \sqrt{d_g}\right) V_r^{\text{att}} \quad (13)$$

式中: X_d 为特征注意力层的输出; Q_r^{att} 为查询矩阵; K_r^{att} 为键矩阵; V_r^{att} 为值矩阵; $W_r^{Q,\text{att}}$ 、 $W_r^{K,\text{att}}$ 、 $W_r^{V,\text{att}}$ 为注意力权重矩阵; d_g 为查询或键向量的维度,用于缩放以防止点积值过大。式(13)计算查询矩阵与键矩阵的缩放点积,Softmax 函数将结果归一化,得到权重矩阵 A_r 。权重矩阵 A_r 表征不同时间断面量测对结果的贡献。

最后,在线性层预测缺失掩码矩阵和开关状态。考虑到开关状态间存在不平衡,即开关闭合和开关断开的数量不是均等的。这会导致模型训练过程中倾向预测数量多的开关状态,称为类别不平衡问题。为了应对这种不平衡,采用基于零界对数与指数的成对排序损失函数(ZLPR)^[19]通过动态调整不同开关状态的损失权重,确保模型在训练时更加关注数量较少的开关状态,从而改善其学习能力。

$$\ell_{\text{Class}} = \ln\left(1 + \sum_{i \in \Omega_{\text{neg}}} e^{s_i}\right) + \ln\left(1 + \sum_{j \in \Omega_{\text{pos}}} e^{-s_j}\right) \quad (14)$$

式中: Ω_{pos} 、 Ω_{neg} 分别为阳性标签(开关状态为 1)和阴性标签(开关状态为 0)集合; s_i 和 s_j 为第 i 类和第 j 类标签得分。式(14)根据标签真值属于不同的正标签集合和负标签集合有不同的损失计算方式,动态调整了不同标签的损失权重。

2.4 插补辨识融合策略及复合损失函数

本文提出了一种插补辨识的融合策略,首先,构建双向时序的 Bi-GRU 生成器,生成时序量测数据的插补样本;其次,Transformer 的多头注意力机制可以有效提取插补样本的关键信息,通过对抗训练向生成器反馈额外的监督信息指导生成器在训练过程中通过标签感知来估算缺失值,协同提高含缺失数据的拓扑辨识精度和插补样本质量。

为了进一步优化网络性能并确保辨识结果的准确性,本文采用一种复合损失函数,这一损失函数结合了重构损失、多标签分类损失和对抗损失。重构损失实现了生成的数据在时序趋势上与原数据尽可能一致;多标签分类损失确保了插补结果不会丢失分类特征;对抗损失降低了生成数据和真实数据之间的分布差异,从而实现分布一致性。复合损失函数包含生成器损失和判别器损失,其计算式分别为

$$L_G = E_V \left[\mathbf{M}_i^T \cdot \gamma \ell_{\text{Re}} - (1 - \mathbf{M}_i)^T \ln(D(G(\mathbf{V}_i))) \right] \quad (15)$$

$$L_D = \beta \ell_{\text{Class}} - E_V \left[\mathbf{M}_i^T \ln(D(G(\mathbf{V}_i))) + (1 - \mathbf{M}_i)^T \ln(1 - D(G(\mathbf{V}_i))) \right] \quad (16)$$

式中: $D(\cdot)$ 为判别器输出; E_V 为 V_i 的期望函数。

在生成器损失中,对于非缺失位置,生成器计算重构损失 ℓ_{Re} (式(8)),使插补样本服从时序关系;对于缺失位置,生成器计算对抗损失,通过最大化 $\ln(D(G(\mathbf{V}_i)))$ 来实现。

在判别器损失中, ℓ_{Class} 表示判别器的开关状态的预测损失(见式(14)),使插补结果不丢失其分类特征。第 2 项表示判别器的对抗损失,对于非缺失位置,判别器的目标是最大化 $\ln(D(\mathbf{V}_i))$,即希望判别器输出接近 1;对于缺失位置,判别器的目标是最大化 $\ln(1 - D(G(\mathbf{V}_i)))$,即希望判别器输出接近于 0。在上述损失函数中, β 和 γ 属于超参数,通过网格搜索寻优 $\beta = 1$ 和 $\gamma = 2$ 时效果最佳。

3 基于双重注意力和多标签积分梯度的拓扑辨识结果解释

3.1 基于 Transformer 模型的双重注意力

拓扑辨识模型可解释性的关键在于捕获不同量测特征间的相关关系。为此,本文引入双重注意力机制(见第 2.3 节)。其中特征注意力层捕获特征间的空间相关关系,而自注意力机制则捕获不同量测断面间的相关关系。

3.2 基于 Transformer 模型的多标签积分梯度

为了知道哪些特征导致模型预测了不同开关状态,本文提出了开关状态的多标签积分梯度解释方法。对于给定输入 x 及拓扑辨识模型 $F(x)$,基于梯度的方法以泰勒级数展开为

$$F(x + \Delta x) - F(x) \approx \sum_i [\nabla_x F(x)]_i \Delta x_i \quad (17)$$

式中 $[\nabla_x F(x)]_i$ 衡量了模型输出对输入的第 i 个分量的敏感程度。但这些梯度值仅反映了模型输出对输入的瞬时敏感性,而未评估输入特征在整个模型决策过程中的总体影响。因此,为了更准确地判断输入分量的实际重要性,文献[3]提出了积分梯度(integrated gradients)方法。该方法满足两个重要的公理,这使得它成为一种有效且理论上具有良好基础的模型解释方法。它将输入从一个基准点(通常为零向量)逐渐平滑地移动到实际输入,通过沿路径累积梯度,计算特征的总体贡献。用这种方法可以克服单点梯度分析的局限,更全面地衡量特征的重要性。可以表示为

$$F(\bar{x}) - F(x) \approx \sum_i [\nabla_x F(x)]_i [\bar{x} - x]_i \quad (18)$$

式中 $F(\cdot)$ 表示模型输出函数,设基准值 $\bar{x} = 0$, $F(\bar{x}) - F(x)$ 表示每个分量从基准值移动到量测值的成本。设 $\gamma(\alpha)$ ($\alpha \in [0, 1]$) 代表连接 x 和 \bar{x} 的一条路径曲线,则有

$$F(\bar{x}) - F(x) = \sum_i \int_0^1 [\nabla_{\gamma} F(\gamma(\alpha))]_i [\gamma'(\alpha)]_i d\alpha \quad (19)$$

式(17)通过路径积分的形式将路径上每一点的梯度进行平均,作为特征的重要性评估。多标签积分梯度的拓扑辨识模型解释方法,是将多标签输出转化为多个单标签输出,对每个开关状态 j 应用积分梯度可以表示为

$$F(\bar{x})_j - F(x)_j = \sum_i \int_0^1 [\nabla_{\gamma} F_j(\gamma(\alpha))]_i [\gamma'(\alpha)]_i d\alpha \quad (20)$$

式中: $F(\bar{x})_j$ 为基准值的第 j 个开关状态的模型输出; $F(x)_j$ 为实际输入 x 下的第 j 个开关状态的模型输出。式(20)可以得到每个输入特征 \bar{x} 到实际状态 x 的转变中,对开关状态输出的累积贡献。

4 可解释配电网拓扑辨识流程及评估指标

4.1 基于 CTGAIN 模型的配电网拓扑辨识流程

辨识流程分为数据预处理、模型训练和模型测试及解释 3 个部分,如图 4 所示。

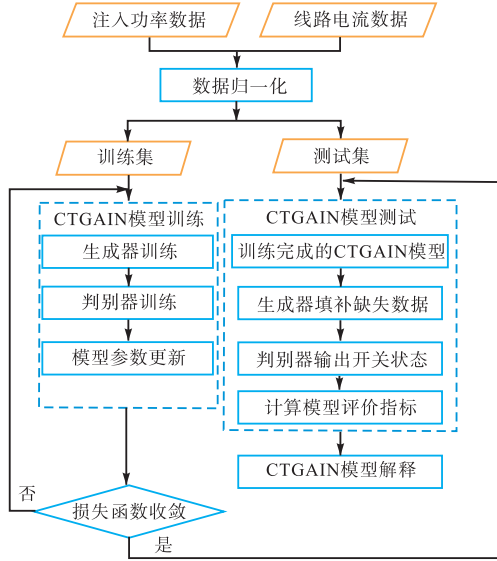


图4 可解释配电网拓扑辨识流程

Fig.4 Flow chart of interpretable distribution network topology identification

可解释配电网拓扑辨识具体步骤如下。

步骤 1 对节点注入功率伪量测和局部电流量进行预处理。首先，在时间维度上进行归一化，对所有时刻的量测数据进行归一化为

$$\mathbf{X}_t^* = (\mathbf{X}_t - \mathbf{X}_{\text{mean}}) / \mathbf{X}_{\text{std}} \quad (21)$$

式中： \mathbf{X}_t^* 为归一化后 t 时刻断面特征向量； \mathbf{X}_{mean} 和 \mathbf{X}_{std} 分别为所有时刻量测的均值和方差向量。其次，用滑动时间窗构建时窗样本 \mathbf{V} ，时窗样本维度为 $N \times W \times F$ 。将时窗样本 \mathbf{V} 划分为训练集和测试集，作为 CTGAIN 模型的输入。

步骤 2 模型训练。首先，将训练集 $\mathbf{V}_{\text{train}}$ 和缺失掩码矩阵 $\mathbf{M}_{\text{train}}$ 输入到 Bi-GRU 生成器，通过双向 GRU 层和全连接层协同预测缺失数据；其次，将插补样本输入到 Transformer 判别器，基于 Transformer 的自注意力机制提取插补样本的关键特征，并输出预测的开关状态和插补样本真伪；最后，根据复合损失函数下降的方向，交替训练生成器和判别器直至纳什均衡。

步骤 3 模型测试及解释。首先，将测试集 \mathbf{V}_{test} 和缺失掩码矩阵 \mathbf{M}_{test} 输入到已训练的生成器，输出插补样本；再将插补样本输入到已训练的判别器进行开关状态预测；然后，通过预测标签与真实标签进行对比，完成模型测试评估；最后，提取双重注意力 Transformer 的注意力权值并结合多标签积分梯度方法。量化不同量测特征对辨识结果影响程度和不同开关状态关联特征，提高模型辨识结果可信度。

4.2 模型评价指标

为量化本文模型性能，采用双重评价指标。首

先，为评估插补数据接近真实完整数据程度，本文以均方根误差（插补精度）作为评价指标，即

$$E_{\text{RMS}} = \sqrt{\frac{1}{H} \sum_{i=1}^H (y_i - \hat{y}_i)^2} \quad (22)$$

式中： y_i 为第 i 个观测值的真实值； \hat{y}_i 为第 i 个观测值的预测值； H 为观测值的总数。

其次，为评估插补后的数据比原数据更能提升拓扑辨识开关状态预测的准确率。本文以拓扑辨识多标签分类准确率作为模型的评价指标，即

$$A_{\text{conn}} = \frac{1}{N} \sum_{n=1}^N L \left(\sum_{j=1}^J d(z_{n,j}, y_{n,j}) \right) \quad (23)$$

式中： J 为每个样本中开关的数量； $z_{n,j}$ 为第 n 个样本的第 j 个开关的预测值； $y_{n,j}$ 为第 n 个样本的第 j 个开关的实际值； $d(\cdot)$ 是一个函数，用来判断预测值和实际值是否相同，如果相同，返回 1，否则返回 0； $L(\cdot)$ 是一个函数，用来判断该样本是否所有开关都判断正确，若都正确，返回 1，否则返回 0。

5 算例分析

5.1 算例数据

算例 1 修改后 IEEE 33 节点系统如图 5 所示，具体线路参数参见文献[20]，风、光分布式电源接入位置参见文献[21]。图中 1 号节点为电源节点，其余节点为负荷节点。红点表示线路电流传感器，布置原则参见文献[4]，红色圆圈加数字为待辨识的开关支路：(11, 12), (14, 15), (15, 16), (2, 19), (28, 29), (8, 21), (9, 15), (12, 22), (18, 33), (25, 29)，其余为普通支路。图中共计 10 个开关，有 2^{10} 种不同的拓扑，通过改变联络/分段开关状态生成了 81 种拓扑，其中 71 种为辐射拓扑，10 种为环网拓扑。输入量测包含每个节点的功率伪量测（有功功率和无功功率）及部分支路的线路电流量。




图5 修改后 IEEE 33 节点系统

Fig.5 Modified IEEE 33-node system

算例 2 修改后 IEEE 69 节点系统如图 6 所示，

具体线路参数参见文献[22], 风、光分布式电源接入位置参见文献[23]. 图中 0 号节点为电源节点, 其余节点为负荷节点. 红点表示线路电流传感器, 布置原则参见文献[4], 红色圆圈加数字为待辨识的开关支路: (14, 45), (13, 42), (2, 35), (49, 58), (48, 49), (57, 58), (12, 20), (26, 64), (20, 21), (3, 4), 其余为普通支路. 图中共计 10 个开关, 有 2^{10} 种不同的拓扑, 通过改变联络/分段开关状态生成了 81 种拓扑, 其中 71 种为辐射拓扑, 10 种为环网拓扑. 输入量测包含每个节点的功率伪量测(有功功率和无功功率)及部分支路的线路电流量.

在算例 1 和算例 2 中均采用文献[7]的源荷模拟策略, 通过潮流计算构建 74 000 组样本集、75% 训练集和 25% 测试集. 噪声场景构建如下: 场景 1 为线路电流量和节点注入功率分别添加 0 和 10% 方差的零均值高斯噪声; 场景 2 为线路电流量和节点注入功率分别添加 0 和 30% 方差的零均值高斯噪声; 场景 3 为线路电流量和节点注入功率分别添加 1% 和 50% 方差的零均值高斯噪声; 场景 4 为线路电流量和节点注入功率分别添加 3% 和 50% 方差的零均值高斯噪声.




图 6 修改后的 IEEE 69 节点系统
Fig.6 Modified IEEE 69-node system

5.2 模型结构参数确定

以算例 1 为基础, 在场景 4 下叠加 50% 的随机缺失值. 实验表明, CTGAIN 模型的辨识正确率和插补精度与时间窗口宽度和跳跃间隔有一定关系, 如图 7 和图 8 所示.

由图 7 和图 8 可知, 当跳跃间隔固定时, 随着时间窗口宽度的增加, 辨识精度逐渐增加. 说明增加量测断面数量提高了数据冗余度, 增加了辨识正确率. 当时间窗口宽度固定时, 跳跃间隔越大, 辨识正确率逐渐降低, 说明跳跃间隔增加会对辨识产生干扰信息. 从插补精度来看, 可以发现插补精度与辨识正确率并不完全匹配, 因为量测数据存在噪声, 仅依赖时序特征, 可能会过拟合噪声, 从而丧失分类特征. 综上, 选择时间窗口宽度为 10 和跳跃间隔为 1 作为模

型参数.




图 7 插补精度与时间窗口宽度及跳跃间隔关系图
Fig.7 Relational diagram among interpolation accuracy, time window width, and step interval




图 8 辨识正确率与时间窗口宽度及跳跃间隔关系图
Fig.8 Relational diagram among recognition accuracy, time window width, and step interval

训练中, 使用 Adam 优化器, 训练轮次 (epochs) 设置为 100, 复合损失函数作为训练损失函数. 学习率设置为 0.001, 批量大小 (batch size) 设置为 128, 随机失活率 (dropout) 设置为 0.1. 输入神经元个数设置为输入特征个数, 输出神经元个数分别为插补样本维度和待辨识开关数量, 具体 CTGAIN 结构参数如表 1 和表 2 所示. 实验基于 Python3.9 进行编程, 在配备 24 GB RAM 和 GTX3080 的 Windows10 电脑上进行.

5.3 模型有效性测试

基于算例 1 和算例 2 及其数据集, 分析不同缺失率的插补精度. 对比插补方法有均值插补 (Mean)、最近邻插补 (KNN)、生成插补网络 (GAIN)^[16] 和时序降

噪自编码插补网络 (TDAE)^[11].

表 1 生成器网络结构参数

Tab.1 Structural parameters of generator network

层名	参数名	取值
输入全连接层	神经元数量	特征数量 × 时间步长
	激活函数	Sigmoid
正向 GRU 层和 反向 GRU 层	输入神经元数	特征数量
	隐藏层大小	256
	时间步长	10
	层数	1
	随机失活率	0.1
输出全连接层	神经元数量 激活函数	特征数量 × 时间步长 LeakyRelu

表 2 判别器网络结构参数

Tab.2 Structural parameters of discriminator network

层名	参数名	取值
特征注意力层	神经元数量	特征数量
	激活函数	Sigmoid
	归一化函数	Softmax
Transformer 层	输入维度	256
	注意力头个数	2
	前馈网络维度	256
	随机失活率	0.1
	层数	1
插补输出层	神经元数量 激活函数	特征数量 × 时间步长 Sigmoid
分类输出层	神经元数量 激活函数	开关数量 Sigmoid

表 3 显示了在不同缺失数据比率下,修改的 IEEE 33 节点系统和 IEEE 69 节点系统中各算法的均方根误差 (E_{RMS}). 在这两个系统中, KNN 和 Mean 方法在处理高比例缺失数据时的 E_{RMS} 较高,其中 50% 缺失率时 KNN 的 E_{RMS} 为 0.52 和 0.61, Mean 的 E_{RMS} 为 0.86 和 0.95. 相比之下, GAIN^[16] 的 RMSE 分别为 0.21 和 0.36, 显示出较好的插补效果. 此外, 考虑时序关系的 TDAE^[11] 和 CTGAIN 算法的性能显著优于前述方法, CTGAIN 在 50% 缺失率下的 E_{RMS} 为 0.09 和 0.19, 相较于次高的 TDAE 方法, E_{RMS} 平均降低了 0.05 ~ 0.08. 这表明 CTGAIN 算法在时序数据插补中具有明显优势. 这是因为 TDAE 未考虑分类特征, 容易导致过拟合, 而本文的 CTGAIN 算法不仅考虑了时序关系, 还兼顾了分类损失和数据分布一致性, 进一步提升了插补精度. 接着, 采用 Transformer 拓扑辨识, 在不同数据缺失率下分析不同插补算法对拓扑辨识正确率影响.

由图 9 和图 10 可以看出, 均值填充方法随着缺失比例增加, 拓扑辨识正确率最低; 生成对抗插补网络和考虑时序的降噪自编码在数据缺失率为 30% 时, 拓扑辨识正确率只有 84%. 而本文所提方法在数

表 3 不同插补算法性能对比

Tab.3 Comparison of different imputation algorithms

算法	不同数据缺失率下的均方根误差 E_{RMS}					
	修改的 IEEE 33 节点系统			修改的 IEEE 69 节点系统		
	10%	30%	50%	10%	30%	50%
KNN	0.40	0.45	0.52	0.55	0.58	0.61
Mean	0.59	0.81	0.86	0.66	0.72	0.95
GAIN ^[16]	0.14	0.18	0.21	0.25	0.30	0.36
TDAE ^[11]	0.10	0.12	0.15	0.23	0.27	0.30
CTGAIN (本文算法)	0.05	0.07	0.09	0.10	0.15	0.19




图 9 算例 1 中不同插补算法对辨识正确率影响

Fig.9 Impact of different imputation algorithms on identification accuracy in case 1

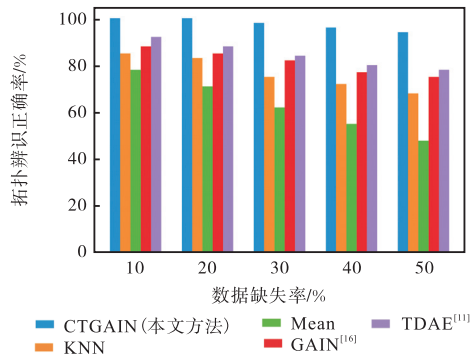


图 10 算例 2 中不同插补算法对辨识正确率影响

Fig.10 Impact of different imputation algorithms on identification accuracy in case 2

据缺失率 30% 以下能保持 98% 以上的辨识正确率; 在数据缺失率 50% 时能保持 95% 以上的辨识正确率. 这是因为插补的同时考虑了时序关系、分布特性和类别特征, 从而协同提高了拓扑辨识正确率.

5.4 模型的可解释性

在 CTGAIN 模型训练过程中, 通过注意力权重的动态分配, 能够实现对输入特征空间和时序重要性的评估. 通过可视化不同迭代次数的注意力权重, 能够对各特征和时刻的重要性变化趋势进行定量分析. 在 CTGAIN 模型测试过程中, 应用开关状态的多标签积分梯度进行可视化和定量分析. 本文在场景 2

下,基于算例 1,验证模型可解释性.

5.4.1 模型训练中的特征和时间权重解释

在模型在迭代训练过程中对不同输入特征动态分配注意力权重,并在训练结束时确定特征重要性排名.重要性高的特征对拓扑辨识结果有着更大贡献度,并会对辨识结果产生更大影响.图 11 给出了模型在第 0~190 次迭代时的特征注意力权重热力图.




图 11 不同迭代次数的特征注意力权重热力图

Fig.11 Heatmap of feature attention weights for different iteration numbers training

在图 11 中,其中横轴为迭代次数,间隔为每 10 次迭代输出的特征注意力.纵轴为输入特征,其中

P_i, Q_i 代表 i 节点注入功率; $I_{m,ij}$ 表示 ij 支路的线路电流幅值; $I_{a,ij}$ 表示 ij 支路的线路电流相角.色块深浅表示特征注意力权重大小,展示了特征注意力权重在模型迭代过程中的动态变化.开始迭代时,特征权重较为分散,随着迭代次数的增加逐渐聚焦到关键特征.关键特征主要有: $P_1, P_9, P_{14}, P_{17}, P_{18}, P_{30}, Q_1, \dot{I}_{13-14}, \dot{I}_{20-21}, \dot{I}_{24-25}, \dot{I}_{29-30}$, 权重较高的特征主要分布在待辨识开关两侧少量的节点注入功率、电源功率和所有的电流向量,其中电流幅值的重要性较电流相角略大.

对比不同的特征重要性评估方法 Lightgbm^[6]、Xgb^[8]、Catboost^[9]和皮尔森相关系数,用本文分类模型评估对拓扑辨识正确率的影响.图 12 中横坐标表示按特征重要性排名选择前 $K\%$ 特征, K 取值范围为 $[10, 100]$; 纵坐标表示对应的拓扑辨识正确率.当选取特征数量百分比大于 50% 时,各算法辨识精度都能达到接近 1.000 0.本算法选取特征数量百分比为 25% 时能达到 99% 辨识正确率,而其余评估方法达到相同辨识正确率都需要更多的特征数量.




图 12 不同特征重要性评估方法的辨识正确率

Fig.12 Identification accuracies of different feature importance evaluation methods

模型迭代训练过程中,时间注意力机制表征各量测断面对模型输出的贡献度,如图 13 所示.

图 13 展示了模型在第 0~190 次迭代时的样本时间注意力权重变化.横坐标表示迭代次数,纵坐标表示时间窗口中的断面编号.常识上每个量测断面对模型输出应有均等的权重,本文设置的时间窗口宽度是 10,因此每个断面的权重都在 0.10 附近,从时间重要性权重验证了本文模型是符合预期的.

5.4.2 模型测试中的开关状态对应特征解释

在场景 2 下,算例 1 利用多标签积分梯度可视化输出开关状态所关联的特征,验证模型的合理性,举例开关 2 和开关 9 进行可视化,如图 14 所示.

对于开关 2,积分梯度重要程度前 5 的特征有 $I_{a,13-14}, I_{m,13-14}, I_{m,29-30}, P_1$ 和 $I_{a,8-9}$; 对于开关 9 积分梯




图 13 不同迭代次数的时间注意力权重热力图

Fig.13 Temporal attention weights heatmap with different iteration numbers




图 14 开关 2 和 9 的多标签梯度积分可视化

Fig.14 Visualization of multi-label gradient integration for switches 2 and 9

度重要程度前 5 的特征有 $I_{m,29-30}$ 、 $I_{a,29-30}$ 、 P_1 、 $I_{a,12-13}$ 和 P_{15} 。经分析可知，模型判断开关状态，主要关注是开关相连支路的线路电流特征和电源节点注入功率，其特征的积分梯度也相对较高，符合物理常识。

为验证其正确性，选择开关 2 和开关 9 发生变化的样本。根据排名剔除以上关键特征，观察其辨识正确率变化，如图 15 所示。




图 15 开关辨识正确率随排除特征数量的变化

Fig.15 Variation of switch recognition accuracy with the number of excluded features

如图 15 所示，排除前 5 个关键特征后，识别精度显著下降(降至约 40%)，这表明这些特征在开关识别中至关重要，从而验证了积分梯度方法在识别开关重要特征方面的有效性。

5.5 模型适应性测试

5.5.1 不同量测噪声对拓扑辨识影响

基于算例 1 和算例 2 及其数据集，采用本文缺失值填充方法，分析不同量测噪声(见第 3.1 节)下的拓扑辨识正确率如表 4 所示。对比方法包括深度神经网络(deep neural network, DNN)^[6]、卷积神经网络(convolutional neural network, CNN)^[7]、基于分类增强决策树(Cat-boost)^[9]和基于物理模型的 MILP^[4]方法进行多项拓扑辨识算法性能比较结果。

表 4 不同量测噪声下拓扑辨识正确率

Tab.4 Topology identification accuracies under different measurement noise levels

系统	辨识方法	拓扑辨识正确率/%			
		场景 1	场景 2	场景 3	场景 4
算例 1	DNN ^[6]	86	83	75	73
	Catboost ^[9]	81	75	68	65
	CNN ^[7]	88	86	80	78
	MILP ^[4]	97	95	90	88
	CTGAIN(本文方法)	100	99	98	96
算例 2	DNN ^[6]	85	83	79	78
	Catboost ^[9]	80	75	72	66
	CNN ^[7]	85	83	79	78
	MILP ^[4]	94	93	88	87
	CTGAIN(本文方法)	100	99	97	95

由表 4 显示，算例 1 和算例 2 中，本文算法平均

辨识正确率最高,为 98%,MILP 平均辨识正确率次高,为 91%;Catboost 平均辨识正确率最差,为 72%。在场景 1 下 CTGAIN 拓扑辨识准确率为 100%,对比方法的准确率最高为 97%,最差为 86%。由此可以说明,本文方法的拓扑辨识准确率高于对比方法。原因是本文采用了 Transformer 提高了特征提取能力,且在插补任务时使用了 Transformer 引导插补,避免了累积误差。

5.5.2 不同量测噪声对拓扑辨识影响

基于算例 1 和算例 2 及其数据集,采用本文缺失值插补方法,在场景 3 下仿真分析不同 DER 渗透率的拓扑辨识正确率。考虑实际系统中接入的 DER,测试了 DER 渗透率在 10%~70%下各种算法的辨识效果,测试结果如图 16 和图 17 所示。

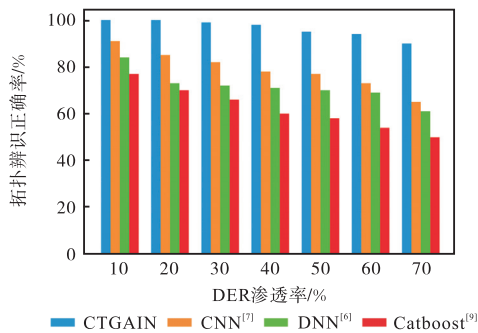


图 16 算例 1 中不同 DER 渗透率下的拓扑辨识正确率
Fig.16 Topology identification accuracies in case 1 under different DER penetration rates




图 17 算例 2 中不同 DER 渗透率下的拓扑辨识正确率
Fig.17 Topology identification accuracies in case 2 under different DER penetration rates

由图 16 和图 17 可知,本文算法在 DER 渗透率为 30%以下都能保持 99%以上的辨识正确率,当 DER 渗透率为 30%以上时出现了反向潮流,影响了辨识正确率,但在 DER 渗透率为 70%情况下,本文算法依旧能保持 90%以上的辨识正确率。

6 结 论

本文基于分类时序生成插补网络的可解释配电

网拓扑辨识算法,得到如下结论。

(1) 模型同时完成了缺失数据插补和拓扑辨识任务,通过构建复合损失函数,多任务协同作用下,提高了缺失数据插补精度和拓扑辨识正确率。

(2) 模型中的双注意力机制捕获了特征的空间和时间相关性,表明模型的主要关注特征是线路电流向量和开关两端的节点注入功率,各时间的量测断面有均等的贡献。通过多标签积分梯度对不同开关模型所关注的特征进行可解释分析,表明模型主要关注的是开关关联的线路电流特征。

综上所述,本文所提拓扑辨识模型在误差大、缺失数据多、可观性弱的量测条件下具有较强的鲁棒性,且所用量测采样周期短,模型辨识速度是毫秒级,适合于在线应用,具有较高的实际价值。

参考文献:

[1] Dehghanpour K, Wang Z Y, Wang J H, et al. A survey on state estimation techniques and challenges in smart distribution systems[J]. IEEE Transactions on Smart Grid, 2019, 10(2): 2312-2322.

[2] 周苏荃, 柳 焯. 新息图法拓扑错误辨识[J]. 电力系统自动化, 2000(4): 23-27.
Zhou Suquan, Liu Zhuo. An innovation graph approach to topology error identification[J]. Automation of Electric Power Systems, 2000(4): 23-27 (in Chinese).

[3] 梁 栋, 刘啸宇, 曾 林, 等. 基于潮流引导神经网络的配电网贝叶斯状态估计[J]. 高电压技术, 2024, 50(11): 4864-4874.
Liang Dong, Liu Xiaoyu, Zeng Lin, et al. Bayesian state estimation for distribution networks based on power flow-informed neural networks[J]. High Voltage Engineering, 2024, 50(11): 4864-4874 (in Chinese).

[4] Farajollahi M, Shahsavari A, Mohsenianrad H. Topology identification in distribution systems using line current sensors: An MILP approach[J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1159-1170.

[5] Fernandes T R, Venkatesh B, de Almeida M C. Distribution system topology identification via efficient MILP-based WLAV state estimation[J]. IEEE Transactions on Power Systems, 2023, 38(1): 75-84.

[6] 裴宇婷, 秦 超, 余贻鑫. 基于 LightGBM 和 DNN 的智能配电网在线拓扑辨识[J]. 天津大学学报(自然科学与工程技术版), 2020, 53(9): 939-950.
Pei Yuting, Qin Chao, Yu Yixin. Online topology identification for smart distribution grids based on LightGBM and deep neural networks[J]. Journal of Tianjin University (Science and Technology), 2020, 53(9): 939-

- 950 (in Chinese).
- [7] 龙寰, 石子晴, 赵景涛, 等. 基于多标签分类与卷积神经网络的配电网拓扑辨识[J]. 高电压技术, 2024, 50(10): 4520-4529.
- Long Huan, Shi Ziqing, Zhao Jingtao, et al. Topology identification of distribution network based on multi-label classification and CNN[J]. High Voltage Engineering, 2024, 50(10): 4520-4529 (in Chinese).
- [8] 潘毓笙, 秦超. 基于两阶段特征选择和格拉姆角场的配电网拓扑辨识方法[J]. 电力系统自动化, 2022, 46(16): 170-177.
- Pan Yusheng, Qin Chao. Identification method for distribution network topology based on two-stage feature selection and gramian angular field[J]. Automation of Electric Power Systems, 2022, 46(16): 170-177 (in Chinese).
- [9] 彭寒梅, 吴行, 胡磊, 等. 基于 Catboost 算法的配电网分区拓扑辨识[J]. 电力自动化设备, 2024, 44(5): 95-102.
- Peng Hanmei, Wu Xing, Hu Lei, et al. Partition topology identification of distribution network based on Catboost algorithm[J]. Electric Power Automation Equipment, 2024, 44(5): 95-102 (in Chinese).
- [10] Raghuvamsi Y, Teeparthi K, Kosana V. A novel deep learning architecture for distribution system topology identification with missing PMU measurements[J]. Results in Engineering, 2022, 15: 100543.
- [11] Raghuvamsi Y, Teeparthi K, Kosana V. Denoising autoencoder based topology identification in distribution systems with missing measurements[J]. International Journal of Electrical Power & Energy Systems, 2023, 154: 109464.
- [12] Wu H Y, Xu Z, Zhao J, et al. Gridtopo-GAN for distribution system topology identification[J]. IEEE Transactions on Industrial Informatics, 2023, 19(4): 5356-5366.
- [13] 李云松, 张智晟. 基于 GRU-TGTransformer 的综合能源系统多元负荷短期预测[J]. 电力系统保护与控制, 2023, 51(15): 33-41.
- Li Yunsong, Zhang Zhicheng. Multi load short-term forecasting of an integrated energy system based on a GRU-TGTransformer[J]. Power System Protection and Control, 2023, 51(15): 33-41 (in Chinese).
- [14] 王玥, 于越, 郭嘉辉, 等. 基于改进 Crossformer 伪量测构建的主动配电网预测辅助状态估计方法[J/OL]. 高电压技术, <https://doi.org/10.13336/j.1003-6520.hve.20240178>, 2024-06-11.
- Wang Yue, Yu Yue, Guo Jiahui, et al. Forecasting-aided state estimation method of active distribution network based on improved Crossformer Pseudo-measurements modeling[J/OL]. High Voltage Engineering, <https://doi.org/10.13336/j.1003-6520.hve.20240178>, 2024-06-11 (in Chinese).
- [15] 王小君, 窦嘉铭, 刘墨, 等. 可解释人工智能在电力系统中的应用综述与展望[J]. 电力系统自动化, 2024, 48(4): 169-191.
- Wang Xiaojun, Dou Jiaming, Liu Zhao, et al. Review and prospect of explainable artificial intelligence and its application in power systems[J]. Automation of Electric Power Systems, 2024, 48(4): 169-191 (in Chinese).
- [16] Yoon J, Jordon J, van der Schaar M. GAIN: Missing data imputation using generative adversarial nets [EB/OL]. <https://arxiv.org/abs/1806.02920>, 2018-06-07.
- [17] Cao W, Wang D, Li J, et al. BRITS: Bidirectional recurrent imputation for time series[C]//32nd Conference on Neural Information Processing Systems (NeurIPS 2018). Montréal, Canada, 2018: 6776-6786.
- [18] Chung J Y, Gulcehre C, Cho K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[EB/OL]. <http://arxiv.org/abs/1412.3555>, 2014-12-11.
- [19] Su J, Zhu M, Murtadha A, et al. ZLPR: A novel loss for multi-label classification[EB/OL]. <https://arxiv.org/abs/2208.02955>, 2022-08-05.
- [20] Baran M E, Wu F F. Network reconfiguration in distribution systems for loss reduction and load balancing[J]. IEEE Transactions on Power Delivery, 1989, 4(2): 1401-1407.
- [21] Dorostkar-Ghamsari M R, Fotuhi-Firuzabad M, Lehtonen M, et al. Value of distribution network reconfiguration in presence of renewable energy resources[J]. IEEE Transactions on Power Systems, 2016, 31(3): 1879-1888.
- [22] Baran M E, Wu F F. Optimal capacitor placement on radial distribution systems[J]. IEEE Transactions on Power Delivery, 1989, 4(1): 725-734.
- [23] 徐俊俊, 吴在军, 周力, 等. 考虑分布式电源不确定性的配电网鲁棒动态重构[J]. 中国电机工程学报, 2018, 38(16): 4715-4725, 4976.
- Xu Junjun, Wu Zaijun, Zhou Li, et al. Robust dynamic reconfiguration for distribution networks considering uncertainty of distributed generations[J]. Proceedings of the CSEE, 2018, 38(16): 4715-4725, 4976 (in Chinese).

(责任编辑: 孙立华)