

基于动态时空适应图神经网络的 电网线路参数辨识方法

杨秀¹, 傅骞¹, 汤波^{1*}, 陈宏福², 韩政², 王治华²

(1. 上海电力大学电气工程学院, 上海市 杨浦区 200090;

2. 国网上海市电力公司, 上海市 浦东新区 200122)

Parameter Identification for Power Grid Line Based on Dynamic Spatiotemporal Adaptive Graph Neural Network

YANG Xiu¹, FU Qian¹, TANG Bo^{1*}, CHEN Hongfu², HAN Zheng², WANG Zhihua²

(1. School of Electrical Engineering, Shanghai University of Electric Power, Yangpu District, Shanghai 200090, China;

2. State Grid Shanghai Municipal Electric Power Company, Pudong New Area, Shanghai 200122, China)

ABSTRACT: Accurate identification of line parameters is crucial for the stable operation and optimization of power grids. With the rapid advancement of artificial intelligence, deep learning-based methods for power grid line parameter identification have demonstrated significant advantages in effectiveness and robustness. However, these methods often overlook historical trends and topological relationships of network branches, resulting in models that fail to fully learn critical spatiotemporal information, thereby decreasing parameter identification accuracy. To address this, we propose a dynamic spatiotemporal adaptive graph neural network-based method for power grid line parameter identification. It utilizes the maximum information coefficient and Bayesian optimization based on the tree-structured Parzen estimator to automatically select the most relevant input measurement features while adjusting model hyperparameters, and constructs a spatiotemporal graph dataset based on historical branch features and topological information. The method employs graph convolutional networks and temporal convolutional networks to extract line features, enhanced by a dynamic spatiotemporal adaptive module to capture each line's unique characteristics. In case studies on the IEEE 39-bus system, the method shows improved accuracy and robustness against measurement noise, data loss, and topology changes compared to existing algorithms.

KEY WORDS: power grid line parameter identification; spatiotemporal information integration; maximum information coefficient; Bayesian optimization; graph convolutional networks; temporal convolutional networks; dynamic spatiotemporal adaptive module

摘要: 线路参数的准确辨识对于电网的稳定运行与优化至关重要。随着人工智能技术的快速发展,以深度学习为代表的电网线路参数辨识技术在辨识有效性和鲁棒性上具备显著优势,但这些方法往往忽视网架分支的历史趋势和拓扑关系,导致模型未能充分学习到关键的时空信息,进一步造成参数辨识精度的下降。为此,提出一种基于动态时空适应图神经网络的电网线路参数辨识方法。首先,关注传统的特征选择和手动调参方法过于依赖专家经验的局限,结合最大信息系数和基于树形结构 Parzen 估计器的贝叶斯优化技术,对模型超参数进行调优的同时,自动筛选出对电网参数辨识性能贡献最大的 SCADA 系统量测特征;进一步,依据支路历史特征及电网拓扑信息,构建适用于输电线路参数辨识任务的时空图数据集,利用图卷积网络和时间卷积网络提取图数据集中线路的时空特征,结合动态时空适应模块,精确学习每条线路在不同辨识场景下的独特时空行为。这些组件整合构成了一个高效全面的电网线路参数辨识模型;最后,在 IEEE 39 节点系统上搭建多种量测场景,并进行算例分析。与现有算法相比,所提方法在应对量测噪声、数据缺失以及多拓扑变化的场景下展示了更优的辨识精度和鲁棒性。

基金项目: 国家自然科学基金项目(52177098); 国网上海市电力公司科技项目(520900230014)。

Project Supported by National Natural Science Foundation of China (52177098); Science and Technology Project of State Grid Shanghai Municipal Electric Power Company (520900230014).

关键词: 电网线路参数辨识; 时空信息融合; 最大信息系数; 贝叶斯优化; 图卷积网络; 时间卷积网络; 动态时空适应模块

0 引言

输电线路参数的准确性是各类电网分析和计算的基础。在实际运行环境中,气候、地理环境以及运行工况等随机因素会随着时间的推移不断影响输电线路的参数值,使线路参数经历动态变化^[1]。此外,由于线路长度估计错误、数据库更新不及时或人为操作失误等因素,电网数据库中的参数值常常无法准确反映实际线路参数^[2],进而影响状态估计、暂态分析、继电保护整定等电网计算程序的可信度。因此,研究实用化的参数辨识方法具有重要的意义^[3-4]。

在输电线路参数辨识方法的研究初期,主要依赖于理论计算^[5]和现场参数实测^[6]来进行参数估计。随着技术的发展,残差分析法^[7]、增广状态估计法^[4]、卡尔曼滤波估计法^[8]以及拉格朗日乘子法^[9-10]等线路参数估计方法相继被提出。同时,一些现代的优化技术也被引入到参数辨识领域,如遗传算法^[11]、粒子群优化法^[12]和 Tabu 搜索法^[13]等。最初,参数辨识方法主要基于数据采集与监控(supervisory control and data acquisition, SCADA)系统的量测信息进行。随着广域测量系统的出现,具有准确时标且能提供相角量测的相量量测单元(phasor measurement unit, PMU)为电网线路参数的精确辨识带来更多可能。王茂海等^[14]开发了一种基于 PMU 数据和正态分布理论的输电线路参数在线估计方法。李钦等^[15]利用 SCADA 和 PMU 的多时段量测信息,开发了 5 种不同独立线路的约束最小二乘参数估计模型。薛安成等^[16]提出一种基于 PMU 数据的输电线路正序参数自适应抗差最小二乘在线辨识方法,显著提升了对量测数据噪声和不良数据的处理能力。然而,PMU 测量数据在实际应用中面临时间同步问题^[17]和设备安装数量限制^[18],使得基于 PMU 的线路参数估计方法难以广泛应用于现实场景。总的来说,传统的电网线路参数辨识方法存在明显局限性:一方面,这些方法依赖于高精度的量测数据,而量测设备一旦受损或受到外部环境的干扰,就可能导致参数辨识结果出现偏差;另一方面,传统方法未能有效利用电力系统中的大量历史数据,造成潜在信息资源的浪费。

随着人工智能技术的快速发展及计算能力的显著提升,机器学习和深度学习算法已开始广泛应用于电力系统线路参数辨识领域。Zhang 等^[19]联合

线性回归和模型驱动的方法计算线路参数。Qu 等^[20]提出一种基于灰色支持向量回归(GM-SVR)的传输线参数动态优化方法。此外,一些经典的深度学习算法,如 BP 神经网络^[21]、径向基神经网络^[22]和长短期记忆神经网络^[23](long-short term memory neural network, LSTM)也被逐步用于电网线路的参数辨识任务中。XUE 等^[24]提出一种自适应线性神经元(adaptive linear neuron, ADALINE)与传统的鲁棒 IGG 方法相结合的策略,基于模拟和实测数据实现了电网线路参数的“三段”鲁棒辨识,展现出良好的工程实用性。Lu 等^[25]开发一种基于交叉神经网络(cross neural network, CRSNet)的参数辨识模型,通过交叉感知来更新模型参数,使神经网络能够考虑电网中其他节点的特征信息,极大提升了模型的拟合精度和鲁棒性。尽管上述数据驱动的参数辨识方法有效利用了电网中的大量历史量测信息,但在特征工程和模型调参上还过度依赖于专家经验,特别是在人工干预的情况下可能导致信息丢失或噪声,从而降低模型的辨识精度。此外,这些线路参数辨识方法未能充分考虑电网节点间的连接关系,忽视了电网整体的结构特性,特别是在部分电网线路特征含有噪声的情况下,仅考虑独立线路特征的参数辨识模型鲁棒性不足,容易导致显著的辨识偏差。

近年来,图神经网络(graph convolutional network, GCN)已被广泛应用于电力系统的各种场景中^[26-29]。Wang 等^[30]考虑到电网拓扑中支路间的关联性,提出一种基于多任务图卷积网络的电网支路参数辨识方法,以提高参数辨识的估计精度。Huang 等^[31]在此基础上加入一种自权衡损失模块,进一步增强了参数辨识模型在噪声数据下的鲁棒性。然而,线路参数的变化还跟时间维度存在一定相关性,上述方法的图模型仅考虑了单一空域信息,因此在挖掘线路参数的时间上下文语义方面仍表现不足,难以有效捕捉其中的时域动态变化。此外,电网为了实现更好的运行操作,可能会经历相对频繁的拓扑变化^[32],而现有电网线路参数辨识方法中尚未验证在多拓扑变化场景下的性能。

针对上述问题,本文提出一种基于动态时空适应图神经网络的电网线路参数辨识方法,旨在通过深入学习和挖掘每条线路潜在的时空动态特征来提高参数辨识的精度及复杂环境下的鲁棒性。为进一步说明,本文的主要研究内容如下:

1) 电网线路参数辨识特征选择: 利用最大信息系数(maximum information coefficient, MIC)确定量测特征与目标参数之间的相关性, 并结合树形结构 Parzen 估计器(tree-structured Parzen estimator, TPE)的贝叶斯优化技术, 自动筛选最优的输入量测特征及模型结构超参数;

2) 输电线路的时空图数据构建: 根据筛选的输入量测特征, 结合历史量测数据和电网拓扑信息, 构建时空图数据集;

3) 电网线路参数辨识模型: 通过结合图卷积网络、时间卷积网络(temporal convolutional network, TCN)和动态时空适应模块(dynamic spatiotemporal adaptive module, DSTAM), 构建一个综合的时空序列模型(TCNGCN-DSTAM)。该模型能有效捕获电网线路的空间领域信息及其时变动态特征, 从而实现对每条线路的时空特征差异化增强。为了证明所提方法的有效性, 在 IEEE 39 节点系统中进行多场景仿真, 验证了所提方法在应对噪声干扰、量测数据缺失和多拓扑变化等复杂电网场景下的高辨识精度和强大鲁棒性。

1 电网线路参数辨识的特征选择及图数据构建

1.1 电网线路参数辨识任务描述

本文选择 SCADA 系统记录的多个时间断面的线路量测数据作为参数辨识模型的输入, 进而预测下一时间步长的线路电抗参数。选择线路电抗作为模型的拟合目标, 主要基于以下考虑:

1) 线路电阻受温度影响较大^[33], 在缺乏温度特征数据的情况下, 仅依赖支路的量测信息进行电阻参数的辨识可能会导致辨识精度的降低;

2) 在高压电网中, 潮流计算主要受线路电抗影响, 而电阻和电容的影响则相对较小^[3]。在将量测功率等变量作为模型输入时, 选择电抗作为线路参数可以提升模型对目标的映射能力, 并节省计算资源。

1.2 基于 MIC-TPE 的特征选择

SCADA 系统记录了包括电压幅值、注入功率、支路潮流等多种类型的量测变量。在参数辨识任务中, 量测特征的选择不仅影响模型的处理能力和复杂性, 而且直接决定训练的有效性。过多的特征可能导致模型处理不必要的信息噪声, 增加计算负担, 而特征过少则可能忽略重要的信息, 从而影响

模型的预测性能。因此, 本文提出一种基于 MIC-TPE 的特征选择方法, 从众多量测特征中筛选出最具代表性和相关性的特征, 成为提高模型性能的关键步骤。其整体流程如图 1 所示。




图 1 基于 MIC-TPE 的特征选择流程

Fig. 1 Process of feature selection method based on MIC-TPE

首先, 采用最大信息系数^[34]来计算目标变量与输入特征变量之间的相关性, 通过计算每个量测特征与线路参数之间的 MIC 值, 并将结果进行降序排列, 进而筛选出相关性最强的特征, 形成特征子集 X_D , D 为输入特征的维度。比如当 $D=5$ 时, 输入特征将包括与目标参数高度相关的前 5 个量测特征。计算最大信息系数的公式如下:

$$M_{IC}(V_1, V_2) = \max_{\alpha, \beta < \lambda} \frac{I(V_1, V_2)}{\log_2 \min(\alpha, \beta)} \quad (1)$$

$$I(V_1, V_2) = \int p(V_1, V_2) \log_2 \frac{p(V_1, V_2)}{p(V_1)p(V_2)} dV_1 dV_2 \quad (2)$$

式中: α 和 β 分别为在 V_1 和 V_2 方向上的网格划分数; $p(V_1, V_2)$ 为变量 V_1 和 V_2 的联合概率密度; $p(V_1)$ 和 $p(V_2)$ 分别为变量 V_1 和 V_2 的边缘概率密度; λ 为一个控制参数, 本文中设置为经验值 0.6^[35]。

然后, 采用 TPE 贝叶斯优化算法对量测特征进行有效筛选。TPE 算法是针对贝叶斯优化方法的一种有效扩展, 克服了传统贝叶斯优化在处理混合型变量方面的局限^[36]。在 TPE 优化过程中, 视模型的输入特征维度 D 为优化参数, 进一步纳入贝叶斯优化过程中, 目的是利用贝叶斯优化算法自动确定对于电网线路参数辨识任务关联性最强的特征集, 从而有效解决参数辨识的特征筛选问题, 实现了电

网线路参数辨识过程的全链路智能化。

设电网线路参数辨识模型为 M ，模型的超参数空间为 Θ ，其中包括输入特征维度 D 、学习率等。定义模型的损失函数 L 为预测参数值与参数真实值 Y 之间的平均绝对误差。然后，设定贝叶斯优化的目标函数 f 为基于超参数配置 x 的模型损失函数值，即 $f(x) = L[M(X_D; x), Y]$ ，其中 $x \in \Theta$ 。在寻优过程中，采用期望改进(expected improvement, EI)作为采集函数，通过模型超参数的迭代优化，最终得到一组最优超参数，使得目标损失函数最小化。EI 计算公式如下：

$$EI_{L^*}(x) = \int_{-\infty}^{L^*} (L^* - L) p(L | x) dL = \frac{\gamma L^* l(x) - l(x) \int_{-\infty}^{L^*} p(L) dL}{\gamma l(x) + (1 - \gamma) g(x)} \quad (3)$$

式中： L^* 为优化定义的阈值； $l(x)$ 为损失函数值低于 L^* 时的条件概率密度函数，通常表示为“较好”结果的密度函数； $g(x)$ 为损失函数值高于或等于 L^* 时的条件概率密度函数，通常表示“较差”结果的密度函数。对于阈值 L^* 的选择是通过设定一个满足条件 $p(L < L^*) = \gamma$ 的参数 γ ，该参数是 L 的分位数，本文按照经验值将 γ 设置为 0.25。

1.3 电网线路参数辨识时空图及其构建

图卷积神经网络的处理对象是图数据，其中图 $G=(V, E, A)$ 由节点集合 V 、边集合 E 和邻接矩阵 A 构成，其中 A 所含的元素 0 和 1 分别表示节点间的无连接和有连接状态。在电力系统的应用场景中，图神经网络一般将母线视为节点，将线路视为边来构建图。而在电网线路参数辨识任务中，线路参数及线路功率量测均集中于支路上，只有电压幅值量测和注入功率量测是以母线为单位的特征。因此，本文充分考虑电网线路参数辨识任务的特殊性，提出一种结合母线特征与线路特征的时空图数据构建方法。

经过基于 MIC-TPE 的特征筛选后，将筛选出的母线特征与线路特征进行有效结合，再针对各时间断面的输入数据，以电网支路为单位建立图数据的节点嵌入向量，该向量不仅包括线路本身的特征，还加入该线路两端母线的量测特征。对于输出数据，选取线路上的参数特征作为图数据的节点目标。最终，建立一个适用于电网线路参数辨识的时空图 $G=(V, E, A)$ ，每个节点对应电网中的一条线路，而边仅代表电网线路之间的连接关系，不承载

任何特征信息。邻接矩阵 A 的维度为 $N \times N$ ， N 代表电网的线路数量。此外，将每条线路连续记录的量测断面信息作为图的节点表征，进而构成量测特征矩阵 $X_D \in \mathbb{R}^{N \times S \times D}$ ，其中 S 代表特征的时间窗口步长。以 IEEE 5 节点系统为例的时空图构建过程如图 2 所示。可以看出，线路 5 及其两端母线的特征经过特征筛选后，选取了线路两端的母线电压特征，以及线路两侧的有功功率、无功功率特征，这些特征共同构成图数据节点 5 的量测向量表征。图中的特征工程仅作示例演示，与本文最终的算例结果无关。




图 2 时空图构建过程

Fig. 2 Process of spatiotemporal graph construction

2 基于 TCNGCN-DSTAM 的电网线路参数辨识模型

2.1 图卷积网络

在电力系统的线路参数辨识任务中，GCN 通过邻接矩阵 A 挖掘支路间的结构关系，从而有效捕捉电网拓扑的空间信息。此外，GCN 在处理图数据时采用基于拉普拉斯矩阵 $L_{lap} = D_{deg} - A$ (D_{deg} 为度矩阵) 的卷积核操作。通常对 L_{lap} 进行归一化处理得到 L_{sym} ，并在此基础上进行特征分解，如下式所示：

$$L_{sym} = I - D_{deg}^{-1/2} A D_{deg}^{-1/2} \quad (4)$$

式中 I 为单位矩阵。

为了降低模型在图卷积操作中的时间复杂度，采用切比雪夫多项式替代传统的卷积核。根据切比雪夫多项式的定义，图神经网络的卷积操作可以被近似定义为

$$X * g_{\theta} = \tilde{D}_{deg}^{-1/2} \tilde{A} \tilde{D}_{deg}^{-1/2} X \quad (5)$$

式中： X 为节点信号； $\tilde{A}$ 为添加了自环的邻接矩阵，即 $\tilde{A} = A + I$ ； $\tilde{D}_{deg}$ 为 $\tilde{A}$ 的度矩阵。

通过堆叠多个 GCN 层，模型能够通过逐层迭代来更新节点特征，从而有效捕捉和学习图的深层结构。这种多层架构允许每一层节点处理其直接邻居的信息，而通过多层传递，每个节点能够间接接

收并融合更远距离节点的信息。隐藏层特征的表达式如下:

$$\mathbf{H}^{(l+1)} = F(\mathbf{H}^{(l)}, \mathbf{A}) = \sigma_{\text{act}}(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (6)$$

式中: $\mathbf{H}^{(l+1)}$ 为第 $l+1$ 层的节点特征矩阵; $\mathbf{H}^{(l)}$ 为第 l 层的节点特征矩阵; σ_{act} 为非线性激活函数; $\mathbf{W}^{(l)}$ 为第 l 层的可训练权重矩阵。

2.2 时间卷积网络

本文采用时间卷积网络^[37]提取线路的历史量测信息。该模型由多层一维卷积神经网络(convolutional neural network, CNN)构成,每一层的卷积操作被视为一个滤波器,通过使用多个滤波器提取历史量测序列的时间特征。随着网络层数的增加,卷积扩张因子呈指数增长,显著扩大了模型的感受野,并提高了 TCN 的处理能力。通过在不同层选择不同跨度的数据进行扩张因果卷积,TCN 避免了梯度消失或梯度爆炸的问题,并减少了网络训练的时间成本。此外,扩张因果卷积通过在输入中加入零填充保持时间上的因果顺序,确保当前时间步的预测仅依赖于历史信息。

为进一步提升 TCN 处理量测序列数据的能力,本文模型中引入了门控机制的时间卷积网络^[38],以增强对复杂时间依赖性的学习能力。该机制通过元素乘积控制信息流,门控层的计算式如下:

$$\mathbf{H}^{(l+1)} = \tanh(\mathbf{W}_1 * \mathbf{H}^{(l)} + \mathbf{b}_1) \odot \sigma(\mathbf{W}_2 * \mathbf{H}^{(l)} + \mathbf{b}_2) \quad (7)$$

式中: $*$ 为卷积操作符; $\mathbf{W}_1$ 、 $\mathbf{W}_2$ 、 $\mathbf{b}_1$ 、 $\mathbf{b}_2$ 分别为模型可学习的参数; $\odot$ 为元素乘积; $\tanh$ 和 σ 分别为双曲正切激活函数和 Sigmoid 激活函数。

2.3 动态时空适应模块

电力系统中,由于地理位置、线路型号、使用环境等因素的不同,每条线路的参数,其数值大小和变化趋势都会有所不同。因此为电网中的每条线路引入了一个可供模型学习的节点嵌入向量,共同组成一个节点嵌入矩阵 $\mathbf{E}_G \in \mathbf{R}^{N \times d}$, 其中, d 为节点嵌入向量的维度。基于此,本文设计并实现了动态时空适应模块,该模块的核心功能是使模型能够为每条线路自主学习其独特的时空适应性。

基于 TCNGCN-DSTAM 的电网线路参数辨识模型框架如图 3 所示,可以看出, DSTAM 的具体实现过程。首先,对图的节点嵌入矩阵 $\mathbf{E}_G$ 进行线性变换,以生成图节点查询 $\mathbf{Q} = \mathbf{E}_G \mathbf{W}_Q$, 为模型提供每个节点在全图中的查询基础,其中转换矩阵 $\mathbf{W}_Q \in \mathbf{R}^{d \times C}$, C 为隐藏层的特征维度。接着,对 TCN

模块的输出 $\mathbf{H}_T^{(l)}$ 进行线性变化,得到时间维度下的节点键值 $\mathbf{K}_T^{(l)} = \mathbf{H}_T^{(l)} \mathbf{W}_T$, 其中 $\mathbf{W}_T \in \mathbf{R}^{C \times C}$ 。采用同样的方法得到空间维度下的节点键值 $\mathbf{K}_S^{(l)} = \mathbf{H}_S^{(l)} \mathbf{W}_S$, 其中 $\mathbf{H}_S^{(l)}$ 为 GCN 模块的输出,空间转换矩阵 $\mathbf{W}_S \in \mathbf{R}^{C \times C}$ 。随后,计算节点的空间与时间注意力分数^[39],如下式所示:

$$\mathbf{A}_T^{(l)} = \frac{Q(\mathbf{K}_T^{(l)})^T}{\sqrt{C}} \quad (8)$$

$$\mathbf{A}_S^{(l)} = \frac{Q(\mathbf{K}_S^{(l)})^T}{\sqrt{C}} \quad (9)$$




图 3 基于 TCNGCN-DSTAM 的参数辨识模型框架
Fig. 3 Parameter identification model framework based on TCNGCN-DSTAM

最终,对式(8)和(9)应用 Softmax 归一化,分别生成时空注意力权重,再计算得到模型最终的输出,如下式所示:

$$\mathbf{A}_{tT}^{(l)} = \frac{\exp(\mathbf{A}_T^{(l)})}{\sum_{r \in \{T, S\}} \exp(\mathbf{A}_r^{(l)})} \quad (10)$$

$$\mathbf{A}_{tS}^{(l)} = \frac{\exp(\mathbf{A}_S^{(l)})}{\sum_{r \in \{T, S\}} \exp(\mathbf{A}_r^{(l)})} \quad (11)$$

$$\mathbf{H}_{\text{output}}^{(l)} = \mathbf{A}_{tT}^{(l)} \cdot \mathbf{H}_T^{(l)} + \mathbf{A}_{tS}^{(l)} \cdot \mathbf{H}_S^{(l)} \quad (12)$$

2.4 基于 TCNGCN-DSTAM 的线路参数辨识模型

由图 3 所示,基于 TCNGCN-DSTAM 的电网线路参数辨识模型由多个时空网络层组成,每层由 TCN 模块、GCN 模块和 DSTAM 模块构成。前两个模块分别用于提取输入量测数据的时空信息,

DSTAM 模块则用于学习不同线路的动态时空适应性。在每个时空层中, 先将输入的量测特征矩阵 $X_D \in R^{N \times S \times D}$ 通过一个线性层得到高维的时空特征张量 $H \in R^{N \times S \times C}$, 再将该张量输入到 TCN 模块, 对量测序列进行时间维度上的特征捕捉, 得到时间特征张量 $H_T \in R^{N \times S' \times C}$, 其中 S' 为经过 TCN 膨胀卷积缩减后的时间维度^[40]。然后, 将时间特征张量 H_T 输入到 GCN 模块, 进一步得到空间特征张量 $H_S \in R^{N \times S' \times C}$, 再分别将 H_T 和 H_S 输入到 DSTAM 模块中, 按照 2.3 节所述方法计算得到该层网络的输出张量 $H_{\text{output}} \in R^{N \times S' \times C}$ 。最后, 由于该框架使用图 WaveNet 模型^[41]的跳跃机制来处理每层的输出特征, 因此将每层的输出张量 H_{output} 进行加和处理, 并通过两个线性层将综合特征映射到最终的参数辨识结果。

2.5 基于 TCNGCN-DSTAM 的线路参数辨识流程

本文提出一种融合电网线路时空信息的参数辨识方法, 旨在提高线路参数预测的准确性与实用性。该方法的整体框架流程如图 4 所示, 主要包括以下 5 个步骤。




图 4 参数辨识方法整体框架流程

Fig. 4 Overall framework and process of the parameter identification method

1) 生成数据样本: 利用 Pandapower 电力系统分析工具^[42]在仿真电网的不同拓扑中生成多断面的潮流数据, 再附上高斯白噪声, 模拟得到量测数据。同时, 同步抽取各线路的实时参数值, 为后

续的计算提供目标数据。

2) 特征选择: 通过计算各量测特征与线路参数之间的最大信息系数, 评估他们之间的相关性。基于 MIC 结果, 将量测特征按相关性从高到低进行排序, 并构建多个维度下相关性最强的量测特征数据集 X_D 。

3) 构建图数据: 依据 1.3 节所述方法, 首先采集不同拓扑的结构信息, 结合量测特征数据集 X_D 构建时空图数据 $G_D=(V_D, E, A)$ 。通过设置时间窗口, 形成在 S 个历史时间断面下 N 条线路的量测图数据集 $X_D^{t-S+1:t} \in R^{N \times S \times D}$, 并将目标参数图数据集表示为 $P^{t+1} \in R^{N \times 1}$ 。线路参数辨识模型的核心任务是学习一个映射函数 F , 使其能够预测下一时间断面 $t+1$ 的 N 条线路参数, 具体如下式所示:

$$P^{t+1} = F(X_D^{t-S+1:t}, X_D^{t-S+2:t}, \dots, X_D^t, G_D) \quad (13)$$

4) 贝叶斯优化: 对模型的输入特征维度 D 、时间窗口长度 S 、学习率等超参数进行空间配置。利用概率代理模型拟合目标函数, 并根据 EI 采集函数选择候选超参数组合。这些参数配置随后被用于模型的迭代学习过程中, 并根据验证集上的平均绝对百分比误差评价指标进行优化。此过程循环进行, 直至评价指标满足预设的阈值或达到模型的预定终止轮数。

5) 线路参数辨识应用: 根据贝叶斯优化过程确定的最优超参数配置, 建立了最终模型。将此模型部署在测试集上, 评估其在仿真电网线路参数辨识场景中的有效性与鲁棒性。

3 算例分析与测试

3.1 数据集样本生成与评价指标

本文在 IEEE 39 节点系统上对线路参数辨识模型进行应用性能评估和对比较验证。为确保模型能适应不同的电力负荷场景, 将系统的负荷水平设置在原始负荷的 80%~120%, 并随机调整个别节点的负荷, 以代表不同的负荷需求。同时, 调整发电机出力以满足电网潮流约束。对于线路电抗参数, 设定其在原始值的 80%~120% 随机变化。接着, 多次改变电网的拓扑结构, 生成不同拓扑下的电网潮流数据, 从而形成历史数据库。拓扑设置如表 1 所示。对于每类拓扑, 生成 2 820 个样本, 假设在量测传输间隔为 5 min 的情况下, 相当于每类拓扑采集了 235 h 的量测数据。最后, 采用 Z-score 归一化对图数据集的非零样本处理后, 按照 8:1:1 划分训练集、

验证集和测试集。

表 1 拓扑信息设置

Table 1 Configuration of topology information

拓扑编号	支路断开情况
0	原拓扑
1	断开支路 21-16
2	断开支路 8-9、支路 16-17
3	断开支路 23-24
4	断开支路 21-22、支路 17-27、支路 10-11

为了证明本文所提方法在真实环境中的有效性,向数据集加入 3 种噪声设置,以进一步模拟实际情况中 SCADA 系统的量测环境:

1) 添加 45、40 及 35 dB 3 种高斯白噪声,噪声符合均值为 0,标准差为 $\sigma_{\text{noise}} = 10^{-S_{\text{NR}}/20}$ 的高斯分布^[43]。

2) 随机设置部分线路在连续断面的量测信息丢失,用 1×10^{-5} 代替量测丢失线路的断面量测特征。

3) 随机设置部分线路在所有断面的量测信息丢失,用 1×10^{-5} 代替无量测线路的量测特征。

以上数据噪声设置中,1) 在训练集、验证集及测试集中设置,2) 和 3) 仅在测试集中设置。算例分析的所有场景设置情况见附图 A1。

在对线路参数辨识模型进行验证和测试时,为确保各模型预测效果的准确性和一致性,引入如文献[32]设置的 4 种评价指标:均方根误差(root mean squared error, δ_{RMSE})、平均绝对误差(mean absolute error, δ_{MAE})、平均绝对百分比误差(mean absolute percentage error, δ_{MAPE})以及决定系数(R^2)。其中, δ_{RMSE} 、 δ_{MAE} 、 δ_{MAPE} 越小,则说明模型的参数辨识精度越高, R^2 越接近 1,则说明模型对线路参数的解释能力越强。

3.2 基于 MIC-TPE 的特征选择与参数寻优

针对电网线路参数的辨识问题,选择合适的输入特征是模型构建的首要步骤。本文通过对所有 SCADA 系统的量测特征进行 MIC 分析,初步识别出与线路参数高度相关的特征,再对其进行降序排列,结果如图 5 所示。为了避免遗漏关键的映射信息,同时节省计算资源,本文构建特征维度在 4~8 之间的输入特征数据集。随后,将模型的输入特征维度纳入到贝叶斯优化过程中,通过贝叶斯优化动态调整输入特征的维度,寻找最佳的特征组合。




图 5 各量测特征与线路参数的 MIC 排列结果

Fig. 5 MIC result between each measurement feature and line parameter

在贝叶斯优化过程中,除了输入特征维度,还有一些重要的超参数对模型辨识性能具有较高的敏感度,比如图卷积层数和时间窗口步长。增加图卷积层数可增强模型的空间解析能力,以适应更复杂的网络结构,但过多的层次也会带来信息过平滑问题,导致节点特征趋于均一。另外,较长时间窗口可以提供丰富的历史信息,有助于模型理解更加复杂的时间依赖关系,但同时可能会引入不相关的噪声,影响模型的辨识精度。因此,通过贝叶斯网络对模型的图卷积层数、时间窗口长度及一些常见的模型结构超参数进行优化,以提高线路参数辨识模型的预测精度。贝叶斯优化的超参数及其对应验证集 δ_{MAPE} 如图 6 所示,其中红点标注的是模型最




图 6 基于 TPE 贝叶斯优化的超参数结果

Fig. 6 Hyperparameter results based on TPE bayesian optimization

终确定的最优超参数。具体的最优超参数结果如表 2 所示。

表 2 模型最优超参数结果
Table 2 Optimal value of model hyperparameter

超参数名称	人工调参	TPE 贝叶斯优化
输入特征维度	6	5
时间窗口步长	6	5
图卷积层数	2	3
学习率	0.001	0.000 2
批次大小	32	4
隐藏层特征维度	32	128
网络层数	2	5
卷积核大小	2	2
时间卷积层数	2	2
梯度裁剪阈值	5	6
随机丢弃率	0.3	0.4
权重衰减系数	0.000 1	0.000 01
验证集 $\delta_{MAPE}/\%$	3.74	1.56

为了验证 TPE 贝叶斯优化在线路参数辨识的效果, 本文将其性能与基于经验的人工调参方法进行对比。在没有噪声的数据集上, 对两种方法的验证集 δ_{MAPE} 进行了评估, 结果如表 2 所示。采用 TPE 贝叶斯优化算法的 δ_{MAPE} 比人工调参方法提高了 2.18%, 表明采用贝叶斯优化的线路参数辨识模型具有更好的辨识精度和泛化性能。

由表 2 和图 6 可得, 模型的最终输入由待预测参数断面的前 5 个采样点的历史量测值构成, 其中量测值包括线路末端电压幅值 U_j , 线路首端电压幅值 U_i , 线路首端有功功率 P_{ij} , 线路末端有功功率 P_{ji} 以及线路末端无功功率 Q_{ji} 。

为验证本文所提方法的有效性, 选取 CNN(常用)、TCN(时域)、GCN(空域)以及图 WaveNet(时空)与本文算法进行对比。其中, 通过与图 WaveNet 的对比验证, 可以进一步说明本文引入 DSTAM 后在各种场景下的改进效果。对比模型所涉及的超参数取值均采用表 2 中经过贝叶斯寻优后的超参数结果, 以保持与本文算法的一致性。此外, 为了防止模型可能出现的过拟合问题, 在模型训练时引入了 10 个迭代内验证集 δ_{MAPE} 不再减少时停止训练的早停机制。

3.3 噪声环境下的参数辨识模型测试

在现实的量测环境中, 往往存在一定的噪声干扰。因此, 使用 3.1 节介绍的方法为量测数据集分别添加不同程度的高斯噪声, 以验证本文算法在量测数据噪声下的抗差性。在原始拓扑下, 各参数辨

识模型在不同信噪比环境下的计算结果如附表 B1 所示, δ_{MAPE} 柱状图如图 7 所示。




图 7 各模型在不同噪声情景下的 δ_{MAPE} 结果

Fig. 7 Identification δ_{MAPE} of various models under different noise situations

由附表 B1 和图 7 可以看出, 在所有噪声环境中, 本文算法均能保持较高的估计精度。随着量测噪声的增大, 没有考虑空间信息的 CNN、TCN 辨识精度显著下降, δ_{MAPE} 波动较大, 而考虑了空间信息的算法性能则相对稳定。以最严重的 35 dB 噪声集为例, 考虑了时空信息的算法性能较好, 而本文算法在加入 DSTAM 后比图 WaveNet 算法的 δ_{MAPE} 降低了 0.25%, 辨识性能最优。为了模拟现实中的量测环境, 在接下来的算例分析中均采用 45 dB 的噪声数据集对参数辨识模型进行测试和验证。

3.4 参数辨识模型的鲁棒性测试

在电力系统运行过程中, 往往会存在没有安装量测采集点的线路以及一些线路的量测信息短暂丢失的情况, 为了验证本文算法在这些情况的鲁棒性, 在测试集中设置如 3.1 节所述的数据丢失, 以验证不同参数辨识模型的有效性。考虑到电网内各线路参数的差异性, 为了更准确地评估模型在实验线路的表现, 在接下来的算例分析中仅选择 δ_{MAPE} 作为主要评价指标。

3.4.1 量测丢失时的模型性能测试

为了验证参数辨识算法在面对量测丢失时的辨识性能, 设置了在原始拓扑下两种不同的线路量测丢失案例: 1) 支路 4-5 量测丢失; 2) 支路 1-39 和支路 39-9 量测丢失。各类算法在两种案例中随时间的参数辨识结果分别如图 8 和附图 B1 所示, 具体的 δ_{MAPE} 结果则如表 3 和附表 B2 所示。

由图 8 可知, 在支路 4-5 发生量测丢失时, 除




图 8 各模型在量测丢失案例 1 的支路 4-5 参数辨识结果

Fig. 8 Identification result of various models for branch 4-5 under measurement loss case 1

表 3 量测丢失案例 1 的参数辨识结果

Table 3 Parameter identification results under measurement loss case 1

对比算法	左侧量测丢失 区间的 $\delta_{MAPE}/\%$	右侧量测丢失 区间的 $\delta_{MAPE}/\%$	总体 $\delta_{MAPE}/\%$
CNN	6.82	7.26	5.77
TCN	3.48	3.23	2.14
GCN	4.41	3.88	2.40
图 WaveNet	3.00	2.95	2.04
本文算法	2.51	2.38	1.96

了本文提出的算法外,其他各类算法的辨识误差均有所增大。其中 CNN、TCN、GCN 受影响较为显著。由表 3 可知,GCN 和 TCN 在量测丢失时的 δ_{MAPE} 均能够维持在 4.5% 以内,主要得益于 GCN 在处理线路信息时能有效聚合邻近正常支路的量测特征,而 TCN 则依赖于对历史正常信息的捕获。在案例 2 中,通过对两条相邻支路同时设置量测丢失的情况,进一步削弱 GCN 可用的有效空间信息。由附图 B1 可得,GCN 在量测丢失时的辨识性能显著下降,因为实验支路在量测丢失时,原拓扑中仅剩一条附带有有效信息的相邻支路,可能导致 GCN 的聚合机制引入不必要的噪声,进而影响整体的参数辨识准确性。

由于图 WaveNet 和本文算法融合了时空信息的特点,在两个案例中均取得了较好的辨识精度和抗差性能,但图 WaveNet 模型在面对历史数据时,对时间信息的统一处理可能会引入因量测丢失产生的噪声。相较之下,本文算法通过引入动态时空适应模块,能够更加精确地调整对于量测丢失支路的时空关注。由附表 B2 可得,在支路 39-9 发生量测丢失时,本文算法的 δ_{MAPE} 在各量测丢失区间比图 WaveNet 分别降低了 1.44%、0.47%、0.76%,在所有时间断面总体 δ_{MAPE} 上降低了 0.53%。可见,本

文算法即使在面对严重量测丢失的情况下,仍能保持一定的鲁棒性和较好的辨识精度。

3.4.2 量测点缺失时的模型性能测试

当实际线路量测设备数少于训练数据集的量测设备数时,为了验证参数辨识算法的有效性,设置了两种不同的线路无量测案例:1) 原始拓扑下支路 4-5、支路 25-26 缺少量测采样点。2) 训练集拓扑 1 下支路 3-4 缺少量测采样点。各类算法在两种案例中各线路的参数辨识结果分别如图 9 和附图 B2 所示。




图 9 各模型在无量测案例 1 的线路参数辨识结果

Fig. 9 Line identification result of various models under none measurement case 1

由图 9 可知,在支路 4-5(编号为 6)和支路 25-26(编号为 29)缺少量测特征的情况下,各类模型的辨识误差均显著增加。在这些模型中,TCN 的辨识误差最大,其次是 CNN。这种现象可能是由于 TCN 在缺少相应支路的历史数据时,无法有效捕获相关信息,从而导致性能显著下降。与此同时,本文提出的方法即使在量测信息缺失的情况下,也展示出较好的辨识能力。各算法在所有时间断面对于无量测支路的 δ_{MAPE} 统计结果如附图 B3 所示,可以发现,本文算法在两条实验支路上的箱线图较窄,表明模型的辨识误差波动较小,具备在量测点缺失情况下参数辨识的稳定性。同时本文算法的误差水平维持在一个较低的范围内, δ_{MAPE} 中位数在 1.7% 附近, δ_{MAPE} 最大值不超过 2.66%。

案例 2 旨在测试缺乏量测信息时模型在不同拓扑下的有效性。附图 B4 为实验支路在正常运行状态和缺少量测信息情况下各模型辨识结果与实际参数的对比图,结合附图 B2 分析可得,在支路 3-4(编号为 4)缺少量测特征的情况下,GCN 由于其优异的邻接支路信息聚合能力,辨识误差增幅比 TCN、CNN 要小很多,其 δ_{MAPE} 保持在 5% 以内。此外,考虑了时空信息的模型在所有参数辨识模型

中展示出更高的辨识精度。通过比较图 WaveNet 和本文算法的 δ_{MAPE} ，进一步验证了本文算法在面对量测信息缺失时的强大鲁棒性。这是由于图 WaveNet 模型统一处理遇到的所有时间信息和空间信息，在面对无量测支路时可能会误将数据缺失的噪声作为有效信息来处理，从而导致辨识精度受到影响。图 10 展示了本文提出的 TCNGCN-DSTAM

参数辨识算法在模型时间窗口内各支路的时空信息注意力分布情况。可以看出，引入 DSTAM 后，当面对缺失信息的支路(编号为 4)时，模型会更加关注其空间信息而非时间信息，赋予相邻有效线路特征更多的注意力权重，减少对该支路自身历史数据的依赖，从而让模型关注到更重要的特征，同时避免噪声的引入，提高线路参数辨识的预测精度。




图 10 本文算法在无量测案例二中各支路的时空注意力分布情况

Fig. 10 Spatiotemporal attention distribution of each branch by TCNGCN-DSTAM under none measurement case 2

3.5 不同拓扑下的参数辨识模型测试

为了验证线路参数辨识算法在电网拓扑变化时的辨识性能，在测试集中设定如 3.1 节所述的包括原拓扑在内的 5 种训练集拓扑类型。同时，选定支路 22-23 为训练集拓扑实验的观察支路。5 种拓扑类型中，拓扑 3 和 4 的变动支路为观察支路的邻接支路，拓扑的变化会对观察支路产生较强的影响。相反，拓扑 1 和 2 对观察支路的影响则相对较小。此外，对测试集设置了除训练集拓扑之外的两种新拓扑，以验证参数辨识模型对未见拓扑的泛化能力。新拓扑 1 中支路 16-24 和 14-15 被断开，而新拓扑 2 中则是支路 2-3 和 5-6 被断开。未见拓扑测试实验的观察支路为支路 15-16，其中新拓扑 1 对观察支路的影响较强，新拓扑 2 的影响则较弱。

在训练集所含的拓扑下，不同算法的线路参数辨识效果如附图 B5 所示，具体在每个拓扑下的 δ_{MAPE} 结果如表 4 所示。由附图 B5 和表 4 可得，本文算法即使在拓扑发生变化的情况下也能保持稳定的高辨识精度，在所有拓扑下的平均 δ_{MAPE} 最低，仅为 0.67%，特别是在与算例观察支路相关性较强的拓扑变化情况(拓扑 3 和 4)下，其最高 δ_{MAPE} 也未超过 1.5%，比仅考虑空间信息的 GCN 分别低

表 4 训练集拓扑下支路 22-23 的 $\delta_{MAPE}(\%)$ 结果

Table 4 Identification $\delta_{MAPE}(\%)$ for branch 22-23 under the training set topologies

对比算法	原拓扑	拓扑 1	拓扑 2	拓扑 3	拓扑 4
CNN	4.17	2.82	2.76	3.04	4.65
TCN	1.75	1.68	1.53	1.85	3.73
GCN	1.14	1.26	1.31	1.74	2.70
图 WaveNet	0.52	0.64	0.86	1.21	1.95
本文算法	0.34	0.34	0.46	0.84	1.39

0.90%和 1.31%，突显了其显著的辨识性能优势。

此外，由图 10 可以看到，在拓扑结构中心位置且连接多条支路的关键节点，例如与节点 16 相连的支路(编号 19—23)，模型更倾向于关注这些支路的空间信息。具体表现为，在这些空间信息丰富的线路上，模型会赋予更多的空间特征注意力，而时间注意力则相应减少。这种动态调整策略使得本文模型在处理拓扑变化时显示出显著的优势。

图 11 为各参数辨识模型在两个未见拓扑情景的辨识结果。由图可得，在与观察支路关联较强的新拓扑 1 中，依赖单一信息的传统参数辨识模型得到较大的 δ_{MAE} 和 δ_{MAPE} ，表明这些模型在未见拓扑下的辨识能力有限。相反，综合考虑时空信息的模型则展现出更高的辨识精度。本文提出的算法通过引入 DSTAM，能够更灵活地捕捉时空信息之间的

耦合关联性,进而学习到有助于提高模型辨识精度的特征。在两种新拓扑的测试中,本文算法的 δ_{MAPE} 相较于图 WaveNet 分别降低了 0.56%和 0.23%,展现出较好的泛化性能。




图 11 各模型在未见拓扑下支路 15-16 的参数辨识结果

Fig. 11 Identification result of various models for branch 15-16 under unseen topologies

相较于其他数据驱动的辨识算法,本文提出的 TCNGCN-DSTAM 线路参数辨识方法利用系统拓扑信息与历史量测信息,深入挖掘历史信息 and 拓扑信息之间的时空关联性,以增强算法在不同拓扑之间的适应性和估计性能。与此同时,传统算法通常只关注到单一状态的量测信息,当面对新拓扑的变化时,这些算法往往难以充分学习和利用各拓扑之间的关键空间特征,导致其参数辨识性能下降。

4 结论

本文提出一种基于动态时空适应图神经网络的电网线路参数辨识方法,以仿真电网场景为对象构建时空图模型 TCNGCN-DSTAM,以有效捕获电网线路参数的时空变化规律和特异性。主要总结如下:

1) 针对传统手动特征选择方法在特定条件下表现过于依赖且泛化能力不足的问题,本文提出一种基于 MIC-TPE 的特征筛选策略。通过智能筛选与电网线路参数高度相关的量测特征作为模型输入,显著增强了模型的参数辨识精度。

2) 考虑到电网数据与图数据的结构不匹配问题,提出一种适用于电网线路参数辨识任务的时空图数据构建方法,通过有效结合线路特征与母线特征,为 GCN 模块在各类参数辨识场景下的训练和学习提供了坚实的基础。

3) 本文提出的 TCNGCN-DSTAM 电网线路参数辨识模型有效突破了传统模型依赖单一时域或

空域数据的局限,基于构建的时空图数据,实现对电网拓扑空间特征和历史数据时序特征的综合学习,极大优化了模型实时跟踪线路参数变化趋势的能力。

4) 本文方法具有较好的噪声抗差性能。结合 DSTAM 模块,模型可以更好学习每条线路独特的时空信息倾向度。经算例分析验证,在量测丢失、缺少量测采样点等情况下仍能保持较高的辨识精度和稳定的辨识能力。此外,TCNGCN-DSTAM 参数辨识模型在电网拓扑频繁变化的应用场景中也表现出良好的适应性和泛化能力。

参考文献

- [1] YAO Rui, SUN Kai. Toward simulation and risk assessment of weather-related outages[J]. IEEE Transactions on Smart Grid, 2019, 10(4): 4391-4400.
- [2] ABUR A, EXPOSITO A G. Power system state estimation: theory and implementation[M]. Boca Raton: CRC Press, 2004.
- [3] 于尔铿. 电力系统状态估计[M]. 北京: 水利电力出版社, 1985.
YU Erkeng. Power system state estimation[M]. Beijing: China Water & Power Press, 1985(in Chinese).
- [4] 王心丰. 电力系统的参数估计和结构识别[D]. 北京: 清华大学, 1981.
WANG Xinfeng. Parameter estimation and structure identification of power systems[D]. Beijing: Tsinghua University, 1981(in Chinese).
- [5] GRAINGER J J, STEVENSON JR W D. Power system analysis[M]. New York: McGraw-Hill, 1994.
- [6] 胡志坚, 陈允平, 徐玮, 等. 基于微分方程的互感线路参数带电测量研究与实现[J]. 中国电机工程学报, 2005, 25(2): 28-33.
HU Zhijian, CHEN Yunping, XU Wei, et al. Principles and realization of live line measurement of parameters of transmission lines with mutual inductance based on differential equations[J]. Proceedings of the CSEE, 2005, 25(2): 28-33(in Chinese).
- [7] LIU W H E, LIM S L. Parameter error identification and estimation in power system state estimation [J]. IEEE Transactions on Power Systems, 1995, 10(1): 200-209.
- [8] SLUTSKER I W, MOKHTARI S, CLEMENTS K A. Real time recursive parameter estimation in energy management systems[J]. IEEE Transactions on Power

- Systems, 1996, 11(3): 1393-1399.
- [9] ZHU Jun, ABUR A. Identification of network parameter errors[J]. IEEE Transactions on Power Systems, 2006, 21(2): 586-592.
- [10] 郭焯, 吴文传, 张伯明, 等. 拉格朗日乘子法电力系统网络参数错误辨识研究[J]. 中国电机工程学报, 2013, 33(7): 86-91.
- GUO Ye, WU Wenchuan, ZHANG Boming, et al. Power system network parameter error identification by Lagrange multiplier based method [J]. Proceedings of the CSEE, 2013, 33(7): 86-91(in Chinese).
- [11] STACCHINI DE SOUZA J C, DO COUTTO FILHO M B, MEZA E B M. Treatment of multiple network parameter errors through a genetic-based algorithm [J]. Electric Power Systems Research, 2009, 79(11): 1546-1552.
- [12] 卞晓猛, 邱家驹, 许旭峰. 电力系统静态线路参数启发式估计[J]. 中国电机工程学报, 2008, 28(1): 41-46.
- BIAN Xiaomeng, QIU Jiaju, XU Xufeng. A heuristic method for static line parameter estimation in power systems[J]. Proceedings of the CSEE, 2008, 28(1): 41-46(in Chinese).
- [13] 宁辽逸, 孙宏斌, 吴文传, 等. 基于状态估计的电网支路参数估计方法[J]. 中国电机工程学报, 2009, 29(1): 7-13.
- NING Liaoyi, SUN Hongbin, WU Wenchuan, et al. State estimation based branch parameter estimation method for power grid[J]. Proceedings of the CSEE, 2009, 29(1): 7-13(in Chinese).
- [14] 王茂海, 鲍捷, 齐霞, 等. 基于 PMU 实测数据的输电线路参数在线估计方法[J]. 电力系统自动化, 2010, 34(1): 25-27, 31.
- WANG Maohai, BAO Jie, QI Xia, et al. Online estimation of transmission line parameters based on PMU measurements[J]. Automation of Electric Power Systems, 2010, 34(1): 25-27, 31(in Chinese).
- [15] 李钦, 项凤雏, 颜伟, 等. 基于 SCADA 及 PMU 多时段量测信息的独立线路参数估计方法[J]. 电网技术, 2011, 35(2): 105-109.
- LI Qin, XIANG Fengchu, YAN Wei, et al. An approach to estimate parameters of single transmission line based on multi-interval information measured by SCADA and phasor measurement units[J]. Power System Technology, 2011, 35(2): 105-109(in Chinese).
- [16] 薛安成, 张兆阳, 毕天姝. 基于自适应抗差最小二乘的线路正序参数在线辨识方法[J]. 电工技术学报, 2015, 30(8): 202-209.
- XUE Ancheng, ZHANG Zhaoyang, BI Tianshu. Online identification of transmission line positive-sequence parameters based on adaptive robust least squares[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 202-209(in Chinese).
- [17] XUE Ancheng, XU Feiyang, XU Jingsong, et al. Correction of phasor measurements independent of transmission line parameters[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 346-356.
- [18] WANG Yang, XU W, SHEN J. Online tracking of transmission-line parameters using SCADA data[J]. IEEE Transactions on Power Delivery, 2016, 31(2): 674-682.
- [19] ZHANG Jiawei, WANG Yi, WENG Yang, et al. Topology identification and line parameter estimation for non-PMU distribution network: a numerical method[J]. IEEE Transactions on Smart Grid, 2020, 11(5): 4440-4453.
- [20] QU Zhaoyang, LI Miao, ZHANG Zhenming, et al. Dynamic optimization method of transmission line parameters based on grey support vector regression[J]. Frontiers in Energy Research, 2021, 9: 634207.
- [21] LU Min, JIN Xueqi, WANG Xiaozhong, et al. A robust identification method for transmission line parameters based on BP neural network and modified SCADA data[C]//2020 IEEE International Conference on Energy Internet(ICEI). Sydney: IEEE, 2020: 92-97.
- [22] YAN Yi. A robust transmission line parameters identification based on RBF neural network and modified SCADA data[C]//2020 10th International Conference on Power and Energy Systems(ICPES). Chengdu: IEEE, 2020: 251-255.
- [23] QUE Lingyan, YANG Liqiang, QIAN Haifeng, et al. A robust line parameter identification method based on LSTM and modified SCADA data[C]//2020 IEEE 4th Conference on Energy Internet and Energy System Integration(EI2). Wuhan: IEEE, 2020: 2981-2986.
- [24] XUE Ancheng, KONG He, LAO Yongzhao, et al. A new robust identification method for transmission line parameters based on ADALINE and IGG method[J]. IEEE Access, 2020, 8: 132960-132969.
- [25] LU Min, QUE Lingyan, JIN Xueqi, et al. Parameter prediction of power grid branch based on cross neural

- network[C]//2021 International Conference on Artificial Intelligence, Big Data and Algorithms(CAIBDA). Xi'an: IEEE, 2021: 145-149.
- [26] 王新迎, 闫冬, 施展, 等. 机器学习赋能的优化算法及其在新型电力系统中的应用与展望[J]. 中国电机工程学报, 2024, 44(16): 6367-6384.
- WANG Xinying, YAN Dong, SHI Zhan, et al. Machine learning empowered optimization algorithms and their applications and prospects in new type power system[J]. Proceedings of the CSEE, 2024, 44(16): 6367-6384(in Chinese).
- [27] 冯双, 彭祥佳, 陈佳宁, 等. 基于时空图卷积神经网络的强迫振荡定位与传播预测[J]. 中国电机工程学报, 2024, 44(4): 1298-1309.
- FENG Shuang, PENG Xiangjia, CHEN Jianing, et al. Forced oscillation location and propagation prediction based on temporal graph convolutional network[J]. Proceedings of the CSEE, 2024, 44(4): 1298-1309(in Chinese).
- [28] 陈志威, 吴毓峰, 潘振宁, 等. 基于图表示学习和特征引导的电力系统运行场景生成方法[J]. 中国电机工程学报, 2024, 44(24): 9521-9532.
- CHEN Zhiwei, WU Yufeng, PAN Zhenning, et al. A power system operating scenario generation method based on graph representation learning and feature guidance[J]. Proceedings of the CSEE, 2024, 44(24): 9521-9532(in Chinese).
- [29] 林俊杰, 涂明权, 朱利鹏, 等. 基于时空多视图学习算法的PMU电压数据重构方法[J]. 中国电机工程学报, 2024, 44(24): 9533-9545.
- LIN Junjie, TU Mingquan, ZHU Lipeng, et al. PMU voltage data reconstruction method based on spatiotemporal multi-view learning algorithm[J]. Proceedings of the CSEE, 2024, 44(24): 9533-9545(in Chinese).
- [30] WANG Zhiwei, XIA Min, LU Min, et al. Parameter identification in power transmission systems based on graph convolution network[J]. IEEE Transactions on Power Delivery, 2022, 37(4): 3155-3163.
- [31] HUANG Zhenkai, XIA Min, LU Min, et al. AWL-GCN: branch parameter identification considering grid spatial structure constraints[J]. IEEE Transactions on Industrial Informatics, 2023, 19(5): 6939-6949.
- [32] RUDIN C, WALTZ D, ANDERSON R N, et al. Machine learning for the New York City power grid[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(2): 328-345.
- [33] 于学良, 张恒旭, 王孟夏. 考虑线路温度的电网状态估计方法[J]. 中国电机工程学报, 2018, 38(9): 2561-2570.
- YU Xueliang, ZHANG Hengxu, WANG Mengxia. An algorithm for power system state estimation considering line temperature[J]. Proceedings of the CSEE, 2018, 38(9): 2561-2570(in Chinese).
- [34] RESHEF D N, RESHEF Y A, FINUCANE H K, et al. Detecting novel associations in large data sets[J]. Science, 2011, 334(6062): 1518-1524.
- [35] LIU Jiayang, WANG Xiaosun, XIE Fuqi, et al. Condition monitoring of wind turbines with the implementation of spatio-temporal graph neural network[J]. Engineering Applications of Artificial Intelligence, 2023, 121: 106000.
- [36] YANG Li, SHAMI A. On hyperparameter optimization of machine learning algorithms: theory and practice[J]. Neurocomputing, 2020, 415: 295-316.
- [37] LEA C, FLYNN M D, VIDAL R, et al. Temporal convolutional networks for action segmentation and detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Honolulu: IEEE, 2017: 1003-1012.
- [38] DAUPHIN Y N, FAN A, AULI M, et al. Language modeling with gated convolutional networks[C]//Proceedings of the 34th International Conference on Machine Learning. Sydney: JMLR, 2017: 933-941.
- [39] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017: 6000-6010.
- [40] BAI Shaojie, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. arXiv: 1803.01271, 2018.
- [41] WU Zonghan, PAN Shirui, LONG Guodong, et al. Graph wavenet for deep spatial-temporal graph modeling[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao, China: ACM, 2019: 1907-1913.
- [42] THURNER L, SCHEIDLER A, SCHÄFER F, et al. Pandapower—an open-source python tool for convenient modeling, analysis, and optimization of electric power

systems[J]. IEEE Transactions on Power Systems, 2018, 33(6): 6510-6521.

[43] CHEN Kunjin, HU Jun, ZHANG Yu, et al. Fault location in power distribution systems via deep graph convolutional networks[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(1): 119-131.

附录 A 算例场景设置




图 A1 IEEE 39 节点系统算例分析场景设置


Fig. A1 Scenario configuration for case study analysis on the IEEE 39-bus system

附录 B 算例分析结果


表 B1 不同噪声数据的参数辨识结果

Table B1 Identification results of different noise data

对比模型	SNR/dB	δ_{MAE}	$\delta_{MAPE}/\%$	δ_{RMSE}	R^2
CNN	0	0.502 2	2.58	0.836 9	0.997 0
	45	1.092 9	4.30	2.262 9	0.979 3
	40	1.473 8	8.69	2.480 6	0.975 0
	35	1.665 6	11.76	2.507 1	0.974 5
TCN	0	0.295 8	1.63	0.450 6	0.999 1
	45	0.715 1	3.12	1.452 6	0.990 9
	40	1.260 8	6.14	2.276 8	0.978 4
	35	1.452 0	6.91	2.724 6	0.969 5
GCN	0	0.443 2	2.34	0.671 9	0.998 1
	45	0.815 0	3.57	1.391 3	0.991 8
	40	0.838 5	3.82	1.396 2	0.991 8
	35	0.848 2	3.97	1.641 4	0.988 9
图 WaveNet	0	0.229 4	1.18	0.346 5	0.999 5
	45	0.620 8	2.72	1.288 4	0.992 6
	40	0.761 2	3.44	1.319 4	0.992 6
	35	0.770 3	3.56	1.346 3	0.991 9
本文算法	0	0.197 0	1.06	0.292 9	0.999 6
	45	0.615 9	2.65	1.259 6	0.993 0
	40	0.663 0	3.23	1.205 4	0.993 9
	35	0.680 6	3.31	1.244 8	0.993 5



(a) 支路1-39的参数辨识结果



(b) 支路39-9的参数辨识结果

图 B1 各模型在量测丢失案例 2 的参数辨识结果

Fig. B1 Identification results of various models under measurement loss case 2

表 B2 量测丢失案例 2 的参数辨识结果

Table B2 Parameter identification results under measurement loss case 2

断 开支路	对比算法	左侧量测丢失区间	中间量测丢失区间	右侧量测丢失区间	总体 $\delta_{MAPE}/\%$
		$\delta_{MAPE}/\%$	$\delta_{MAPE}/\%$	$\delta_{MAPE}/\%$	
支路 1-39	CNN	2.27	2.07	1.66	1.93
	TCN	1.41	1.97	1.35	1.05
	GCN	4.17	3.89	3.66	1.74
	图 WaveNet	0.49	1.38	0.61	0.97
	本文算法	0.63	1.02	0.32	0.70
支路 39-9	CNN	8.67	3.99	6.41	5.93
	TCN	6.15	2.41	3.64	3.66
	GCN	8.65	6.06	7.28	4.71
	图 WaveNet	4.99	1.66	3.07	3.01
	本文算法	3.55	1.19	2.31	2.48




图 B2 各模型在无量测案例 2 的线路参数辨识结果

Fig. B2 Line identification result of various models under none measurement case 2






图 B3 各模型在无量测案例 1 的参数辨识统计结果

Fig. B3 Identification statistical result of various models under none measurement case 1



(a) 支路3-4在正常状态下的参数对比结果



(b) 支路3-4在量测信息丢失时的参数对比结果

图 B4 各模型在量测丢失案例 2 的参数对比结果

Fig. B4 Comparison results of various models under measurement loss case 2


图 B5 不同模型在训练集拓扑下
支路 22-23 的参数辨识结果

Fig. B5 Identification result of various models for branch 22-23 under the training set topologies



杨秀

在线出版日期: 2024-10-08。

收稿日期: 2024-06-18。

作者简介:

杨秀(1974), 男, 教授, 博士生导师, 主要研究方向为分布式发电与微电网技术、电力大数据应用、HVDC 与 FACTS 的运行与控制等, yangxiu721102@126.com;

*通信作者: 汤波(1984), 男, 博士, 高级工程师, 副教授, 主要研究方向为配电网规划运行与评估、电力数据挖掘与分析、电能质量方向等, Tangbo@shiep.edu.cn。

(责任编辑 邱丽萍)