

基于时间卷积和自适应图卷积网络的 电力系统暂态稳定评估

肖龙¹, 张靖¹, 何宇¹, 刘影², 叶永春³

- (1. 贵州大学电气工程学院, 贵州省 贵阳市 550025;
2. 贵州电网有限责任公司电网规划研究中心, 贵州省 贵阳市 550002;
3. 贵州电力设计院有限公司, 贵州省 贵阳市 550081)

Power System Transient Stability Assessment Based on Temporal Convolution and Adaptive Graph Convolution Network

XIAO Long¹, ZHANG Jing¹, HE Yu¹, LIU Ying², YE Yongchun³

- (1. College of Electrical Engineering, Guizhou University, Guiyang 550025, Guizhou Province, China;
2. Power Grid Planning and Research Center of Guizhou Power Grid Co., Ltd., Guiyang 550002, Guizhou Province, China;
3. Guizhou Electric Power Design Institute Co., Ltd., Guiyang 550081, Guizhou Province, China)

ABSTRACT: Accurate and fast assessment of power system transient stability is essential for maintaining the safe and stable operation of the power grid. A transient stability assessment method based on temporal convolutional network (TCN) and adaptive graph convolutional network (AGCN) is proposed to enhance the accuracy of assessing power system transient stability. This method models the transient stability assessment as a sample space mapping problem. The amplitude and phase angle of the bus voltage before, during and after the fault are taken as the input. The time convolution network is used to extract the time series characteristics of the transient data, and the adaptive graph convolution network is used to process the topology information between the grid nodes to mine its spatial structure characteristics to realize the fast and accurate judgment of the transient stability of the system. In addition, in model training, the focal loss (FL) function is used as the objective function to improve the model tendency problem caused by the inherent class imbalance of transient samples and the error-prone problem of difficult-to-classify samples in the stable boundary region. Finally, the proposed method's effectiveness is validated through simulation analysis using the IEEE 39 and IEEE 145 bus systems.

KEY WORDS: transient stability assessment; temporal convolutional network; adaptive graph convolutional network; focal loss; sample imbalance

摘要: 准确、快速的电力系统暂态稳定评估对电网的安全稳定运行至关重要。为提高电力系统暂态稳定评估的准确率,提出一种基于时间卷积网络(temporal convolutional network, TCN)和自适应图卷积网络(adaptive graph convolutional network, AGCN)的暂态稳定评估方法。该方法将暂态稳定评估建模为样本空间映射问题,以故障前、故障中和故障后的母线电压幅值和相角作为输入,采用时间卷积网络提取暂态数据的时序特征,并通过自适应图卷积网络来处理电网节点间的拓扑关系,以挖掘其空间结构特征,进而实现系统暂态稳定的快速准确判断。此外,在模型训练过程中,采用焦点损失函数(focal loss, FL)作为目标函数,以改善暂态样本固有的类别不平衡所造成的模型倾向性问题和处于稳定边界区域的难分类样本易错判问题。最后,在IEEE 39和IEEE 145节点系统算例中进行仿真分析,验证了所提方法的有效性。

关键词: 暂态稳定评估; 时间卷积网络; 自适应图卷积网络; 焦点损失函数; 样本不平衡

DOI: 10.13335/j.1000-3673.pst.2024.1724

0 引言

电力系统暂态失稳是造成电网大停电事故的重要诱因和导火索^[1-2]。在系统遭受大扰动后,及时评估电力系统的运行状态能够为运行人员提供制定预控措施的依据,防止进一步的连锁故障。因此,电力系统暂态稳定评估(transient stability assessment, TSA)对电力系统的安全稳定运行至关

基金项目: 国家自然科学基金项目(51867005); 黔科合支撑[2022]一般 013; 黔科合平台人才-GCC[2022]016-1; 黔教技[2022]043号。

Project Supported by National Natural Science Foundation of China (51867005); The Science and Technology Foundation of Guizhou Province ([2022] general013); The Science and Technology Foundation of Guizhou Province (GCC[2022]016-1); Educational Technology Foundation of Guizhou Province ([2022]043).

重要。传统的 TSA 方法分为时域仿真法^[3]和直接法^[4]。其中,时域仿真法对系统进行精确建模,评估精度高,但由于计算耗时长,无法满足在线评估的快速性要求。直接法可以快速给出稳定评估结果,但构造系统能量函数的过程较为困难,不能适用于复杂的电力系统。随着电力系统结构和安全稳定运行机理日趋复杂,传统 TSA 方法更是受到限制,探索适用于现代电力系统的 TSA 方法成为挑战。

人工智能和底层量测数据采集技术的快速发展为电力系统 TSA 提供了新思路。相比于传统的 TSA 方法,基于数据驱动的 TSA 无需求解电力系统复杂的数学模型,也不用构造系统的暂态能量函数,只需通过离线训练,建立输入数据与暂态稳定性之间的非线性映射模型,在线评估时将经过预处理的采集数据输入给映射模型,可快速得到暂态结果。基于数据驱动的 TSA 方法包括传统机器学习和深度学习。传统机器学习如随机森林^[5](random forest, RF)、决策树^[6](decision tree, DT)、支持向量机^[7](support vector machine, SVM)、贝叶斯神经网络^[8](bayesian neural network, BNN)等已成功应用于电力系统 TSA 领域。这类方法虽能实现快速评估,但由于其浅层网络结构的特征提取能力不足,往往需要专家经验辅助设计输入特征,这就造成所训练的模型具有一定的主观性,其结果推广性不强。随着深度学习技术在自然语言、图像处理领域等取得突破性进展,很多学者已将其引入电力系统 TSA 领域。深度学习由于其强大的数据理解能力,可以直接面向底层量测数据,自动提取出高维特征表示,避免了传统机器学习所带来的主观性。目前,应用到电力系统 TSA 的深度学习模型主要涉及卷积神经网络^[9-10](convolutional neural network, CNN)、深度置信网络^[11](deep belief network, DBN)、长短期记忆网络^[12](long short-term memory, LSTM)、堆叠自动编码器^[13](stacked auto encoder, SAE)、深度残差网络^[14](deep residual network, DRN)等。暂态稳定数据本质上是一种时间序列,具有较强的时序性,上述研究是从暂态数据的时序性出发,设计相应网络结构充分提取其时序特征,取得了不错的评估效果。然而,电网运行时的拓扑结构对系统的动态特性和暂态稳定性有显著影响,如果只考虑捕捉暂态数据的时序特征,潜在的问题是当电力系统的拓扑结构发生变化时,此类模型的性能会受到影响。

为此,有学者将深度学习和迁移学习(transfer learning, TL)相结合以增强模型的泛化能力。迁移

学习包括模型迁移^[15]和样本迁移^[16],其核心思想是在系统拓扑变化前(源域)训练得到预训练模型,在系统拓扑变化后(目标域)更新预训练模型以适应新拓扑下的暂态稳定评估。更具体来说,文献[15]在系统运行工况和拓扑结构有较大变化时,将预训练模型迁移至目标域后,利用目标域中少量仿真样本对模型的分类层进行微调;文献[16]则是对源域和目标域样本间的欧式距离进行排序,根据样本相似度从源域中选择迁移样本,并将迁移样本与目标域中少量仿真样本融合后对预训练模型进行更新。这种思路在大幅度降低模型再训练耗时的同时,还可使得模型评估性能恢复到较高水平,但其受迁移策略的影响较大,并且在每种拓扑下仍需要进行时域仿真以获得目标域样本。另一种思路是直接对电网拓扑结构进行建模,利用图神经网络挖掘电网拓扑的空间结构特征。文献[17]建立了基于图注意力网络(graph attention network, GAT)的暂态评估模型,利用注意力系数和特征聚合描述节点之间的拓扑关系。文献[18]将图卷积网络(graph convolutional network, GCN)引入电力系统 TSA 领域,挖掘电网拓扑的空间结构特征。文献[19]利用消息传递图神经网络(message passing neural network, MPNN)提取图拓扑的空间变化特征来判断暂态稳定性。上述研究均对电网拓扑结构进行建模,所得 TSA 模型对系统拓扑变化具有一定的泛化能力。总体而言,在电力系统暂态过程中,不仅系统的电气量会随着时间的推移而变化,系统的拓扑结构还会直接影响系统对扰动的响应能力。因此,研究一种能够同时提取暂态数据时序特征和电网拓扑空间结构特征的评估模型,是提高基于数据驱动的 TSA 模型性能的重要途径。

另一方面,暂态样本固有的类别不平衡性质和稳定边界区域的存在会影响模型性能。文献[20-21]利用生成对抗网络(generative adversarial networks, GAN)或其变体生成失稳样本,以减小失稳样本和稳定样本的数量差异。虽然 GAN 生成的虚拟样本满足少数类样本分布,但却无法保证其是否满足电力系统实际工况。文献[22]采用加权交叉熵损失函数来指导模型训练,对失稳样本赋予较大权重以降低稳定样本参与参数调节的频率,改善了类别不平衡导致的模型倾向性问题,但没有考虑到暂态样本中存在处于稳定边界的难分类样本和非稳定边界的易分类样本,大量的易分类样本会主导梯度更新方向,导致无效学习,模型可能无法训练至最优。

针对上述问题,本文提出一种结合时间卷积网

络(temporal convolutional network, TCN)和 AGCN 的电力系统 TSA 方法。通过 TCN 提取暂态数据的时序特征, AGCN 挖掘电网拓扑的空间结构特征, 充分利用暂态数据的时空特征, 构建具有更高性能的评估模型。另外, 采用焦点损失函数指导模型训练, 其通过引入样本类别权重因子平衡样本类别差异, 并引入难易样本调制因子增加对稳定边界样本的关注度, 以改善暂态样本固有的类别不平衡性质所造成的模型倾向性问题和处于稳定边界区域的难分类样本易错判问题。最后, 在 IEEE 39 和 IEEE 145 节点系统算例中进行仿真分析, 验证所提 TSA 方法的有效性。

1 TCN-AGCN 原理

1.1 时间卷积网络

时间卷积网络(TCN)的核心技术在于采用因果扩张卷积作为时间卷积层, 以提取时间序列的时序特征。在因果卷积中, 时间维度上的所有数据都遵循严格的因果关系, 这种设计保证了时间序列信息的顺序性。然而, 若要增强模型对时间序列的记忆能力, 通常需要增加卷积层的深度或扩大卷积核的尺寸, 这会导致模型参数数量增加, 使得模型训练难度增大。扩张卷积可以有效地解决因果卷积存在的局限性, 其通过引入扩张因子, 在较长的时间窗口内实现不连续的卷积操作, 使得卷积核能够覆盖比其自身长度更广的时间窗口, 从而在保持较少卷积层数的情况下, 提取到更长时间跨度的时序特征。因果扩张卷积的具体公式可表示为

$$\mathbf{G}(t) = \sum_{r=0}^{s-1} F_n(r) \mathbf{x}_{t-dr} \quad (1)$$

式中: $\mathbf{G}(t)$ 表示卷积层的第 t 时刻的输出; $F_n(r)$ 表示第 r 个滤波器; $\mathbf{x}_{t-dr}$ 表示卷积层的第 $t-dr$ 时刻的输入; d 表示扩张因子; s 表示卷积核的大小。

TCN 由堆叠残差块构成, 其网络结构如图 1 所示。每个残差块由两个相同的卷积单元构成, 而每个卷积单元的组成包括因果扩张卷积、权重归一化单元、ReLU 单元、Dropout 单元。为解决深层神经网络的梯度消失问题, 残差块中引入了残差连接, 利用残差连接将输入数据和深层神经网络的输出求和作为下一阶段的输入。

电力系统暂态过程从时间顺序来看, 可分为波过程、电磁暂态过程和机电暂态过程, 此过程中, 电力系统的物理量如母线电压幅值和相角具有明显的时变特性, 其本质是一种时间序列。TCN 和 LSTM 在处理时间序列数据方面都具有较大的优




图 1 时间卷积网络结构

Fig. 1 Temporal convolution network structure

势, 但 TCN 内部没有复杂的门控机制和循环结构, 相比于 LSTM, TCN 的计算代价较小, 训练稳定性也更好。因此, 本文针对电力系统暂态数据的时序特征, 采用 TCN 对其进行充分提取, 以保证模型评估性能。

1.2 自适应图卷积网络

电力系统中各母线通过线路相连, 母线之间相互影响, 本质上是一种图网络结构。若将各母线视为节点, 连接线路视为边, 则电力系统的拓扑结构可描述为 $G=(V, E)$, 其中 V 表示节点集合, E 表示边集合。各节点之间的连接关系则使用邻接矩阵 $A \in \mathbb{R}^{N \times N}$ 表示, N 表示节点数量, 矩阵 A 中元素取值原则为

$$a_{ij} = \begin{cases} 1, & (i, j) \in E \\ 0, & \text{其他} \end{cases} \quad (2)$$

图卷积网络(GCN)是以节点特征矩阵和邻接矩阵作为输入, 经过多层卷积后输出高维节点特征表示, 其层间传播可表示为

$$\mathbf{H}^{(l+1)} = f(\mathbf{H}^{(l)}, \mathbf{A}), \quad l = 0, 1, 2, \dots, L \quad (3)$$

式中: $f(\cdot)$ 表示非线性映射函数; L 为隐藏层层数; $\mathbf{H}^{(l)}$ 表示第 l 层隐藏层输出的节点特征矩阵。若 $l=0$, 则 $\mathbf{H}^{(0)} = \mathbf{X}$ 。

对于每一层图卷积层, 其过程都是将邻接矩阵 A 和节点特征矩阵 $\mathbf{H}^{(l)}$ 相乘后, 利用可训练的参数矩阵 $\mathbf{W}^{(l)}$ 进行线性变换, 即层间传播可写为

$$\mathbf{H}^{(l+1)} = f(\mathbf{H}^{(l)}, \mathbf{A}) = \sigma(\mathbf{A}\mathbf{H}^{(l)}\mathbf{W}^{(l)}) \quad (4)$$

式中: $\sigma(\cdot)$ 表示激活函数。由于拓扑图中构建邻接矩阵时, 节点本身不存在自连接, 无法注意到节点自身特征, 这不利于节点特征表达, 因此将节点特征矩阵与 N 阶单位矩阵相加, 邻接矩阵的对角线元

素全部变为 1, 相当于给各节点增加了自连接, 即:

$$\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I} \quad (5)$$

式中: $\tilde{\mathbf{A}}$ 为添加自连接后的邻接矩阵; $\mathbf{I}$ 为 N 阶单位矩阵。注意到 $\tilde{\mathbf{A}}$ 没有进行归一化处理, 层间传播时会引入数值不稳定, 因此需要进一步对 $\tilde{\mathbf{A}}$ 做对称归一化处理, 即:

$$\tilde{\mathbf{A}}' = \tilde{\mathbf{D}}^{-(1/2)} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-(1/2)} \quad (6)$$

式中: $\tilde{\mathbf{D}}$ 为邻接矩阵 $\tilde{\mathbf{A}}$ 的度矩阵, 是一个对角矩阵, 其对角线元素取值满足 $\tilde{d}_{ii} = \sum_j \tilde{a}_{ij}$ 。至此, GCN 层间传播过程可描述为

$$\mathbf{H}^{(l+1)} = f(\mathbf{H}^{(l)}, \tilde{\mathbf{A}}') = \sigma(\tilde{\mathbf{A}}' \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (7)$$

利用 GCN 网络挖掘电网拓扑的空间结构特征, 构建图的邻接矩阵至关重要。对于电力系统而言, 各母线之间相互影响的程度不同, 且即使没有实际连接关系的两条母线之间也可能存在相互影响关系, 若采用式(2)的取值原则生成邻接矩阵, 潜在的问题是无法全面表征节点之间的相互影响关系。因此本文采用一种自适应的图卷积网络(AGCN)以挖掘电网拓扑的空间结构特征, 其自适应体现在利用内部的图学习层自动从数据中学习图的邻接矩阵, 具体过程如下:

$$\mathbf{M}_1 = \tanh(\alpha \mathbf{E}_1 \mathbf{\Theta}_1) \quad (8)$$

$$\mathbf{M}_2 = \tanh(\alpha \mathbf{E}_2 \mathbf{\Theta}_2) \quad (9)$$

$$\mathbf{A}_{\text{adp}} = \text{ReLU}(\tanh(\alpha (\mathbf{M}_1 \mathbf{M}_2^T - \mathbf{M}_2 \mathbf{M}_1^T))) \quad (10)$$

$$\text{for } i = 1, 2, 3, \dots, N$$

$$i_{dx} = \text{argtopm}(\mathbf{A}_{\text{adp}}[i,:]) \quad (11)$$

$$\mathbf{A}_{\text{adp}}[i, -i_{dx}] = 0$$

式中: $\mathbf{E}_1, \mathbf{E}_2$ 为随机初始化的节点嵌入特征, $\mathbf{\Theta}_1, \mathbf{\Theta}_2$ 表示模型的可训练参数; α 为超参数, 用于控制激活函数的饱和率。通过计算 $\mathbf{M}_1 \mathbf{M}_2^T - \mathbf{M}_2 \mathbf{M}_1^T$, 可以得到节点之间的相似度矩阵, 再将其经激活函数进行非线性操作后得到邻接矩阵, 该矩阵中的元素取值处于(0,1)内, 相互影响程度高的节点对在该矩阵中的取值越接近 1。argtopm($\cdot$) 表示返回离中心节点最近的 m 个邻居节点的向量索引, 并将其余位置的元素置零, 目的是稀疏化邻接矩阵, 从而降低计算复杂度。

此外, 为防止 AGCN 网络在层间传播过程中收敛到单个点导致信息丢失, 考虑在传播过程中保留节点的部分原始状态, 则传播过程可描述为

$$\mathbf{H}^{(l+1)} = f(\mathbf{H}^{(l)}, \tilde{\mathbf{A}}'_{\text{adp}}) = \beta \mathbf{H}_{in} + \sigma((1 - \beta) \tilde{\mathbf{A}}'_{\text{adp}} \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (12)$$

式中: $\mathbf{H}_{in}$ 表示输入给 AGCN 网络的原始节点特征矩阵; $\tilde{\mathbf{A}}'_{\text{adp}}$ 表示对 $\mathbf{A}_{\text{adp}}$ 进行自连接和对称归一化处

理后的邻接矩阵; β 为特征保留率, 作为一个超参数用于控制原始节点特征的保留程度。

2 基于 TCN-AGCN 的暂态稳定评估模型

2.1 暂态稳定评估框架

文献[23]已经指出, 母线电压幅值和相角能有效地反映电力系统的暂态过程, 并易于实时采集。因此, 本文以系统中所有母线电压的幅值和相角作为模型的初始输入特征, 采样窗口涵盖故障前稳态、故障中和故障清除后。由于不同特征在不同阶段的量纲差异较大, 在输入给神经网络前需要先对其进行 min-max 归一化。基于 TCN-AGCN 的电力系统暂态稳定评估框架如图 2 所示。

经 min-max 归一化后的暂态数据先由 1×1 卷积处理至指定维度, 随后将其输入给 TCN-AGCN 模块, TCN 与 AGCN 交织构成时空特征提取层, 分别提取暂态数据的时序特征和空间结构特征。图学习层通过随机初始化的节点嵌入特征计算节点之间的相似度, 自适应地生成具有稀疏性的邻接矩阵, 对其进行自连接和对称归一化处理后, 结合 TCN 的输出一起输入给 AGCN 进行图卷积操作, 以实现暂态数据时空特征的提取。另外, 为防止梯度消失问题, 将 TCN 的输入和 AGCN 的输出进行残差连接后再作为下一个时空特征提取层的输入。同时在每一个 TCN 的输出添加跳跃连接, 其本质是 $1 \times L_i$ 卷积, L_i 表示第 i 个跳跃连接的输入序列长度, 依次对每一层跳跃连接进行求和, 直至最后一层跳跃连接结束后, 对模型提取到的时空特征进行非线性操作和全连接操作, 再结合暂态稳定指数(transient stability index, TSI)^[24]得到稳定/失稳评估结果。TSI 表达式如下:

$$\eta_{\text{TSI}} = \frac{180^\circ - |\Delta\delta_{\max}|}{180^\circ + |\Delta\delta_{\max}|} \quad (13)$$

式中: $\Delta\delta_{\max}$ 表示系统中任意两台发电机在仿真时长内的最大功角差。对于每个样本而言, 若 η_{TSI} 是正数, 则系统被判断为稳定, 样本标注为 1, 反之系统失稳, 样本标注为 0。其本质是通过计算系统中任意两台发电机在仿真时长内的最大功角差是否大于 180° 来判断系统的稳定性。

2.2 焦点损失函数

焦点损失函数(FL)的核心思想是通过样本类别权重因子和难易样本调制因子在模型训练过程中调节梯度更新方向, 是对加权交叉熵的改进。加权交叉熵损失函数可描述为




图2 基于TCN-AGCN的电力系统暂态稳定评估框架

Fig. 2 Power system transient stability assessment framework based on TCN-AGCN

$$L_{ce} = -w_s y \lg p_i - w_{us} (1 - y) \lg(1 - p_i) = \begin{cases} -w_s \lg p_i, & y = 1 \\ -w_{us} \lg(1 - p_i), & y = 0 \end{cases} \quad (14)$$

式中： y 为样本真实标签，1表示样本稳定，0表示样本失稳； p_i 为模型将样本预测为稳定的概率， $1 - p_i$ 为模型将样本预测为失稳的概率； w_{us} 、 w_s 分别表示失稳样本和稳定样本的权重因子，其取值通常根据样本集中失稳样本和稳定样本的比例进行确定。实际电力系统中除了样本类别不平衡问题外，还有部分样本处于稳定边界，这类样本分类难度较大，在设计损失函数时应增加其所占损失比重，同时降低易分类样本的损失比重。FL在加权交叉熵的基础上引入了难易样本调制因子以改善稳定边界难分类样本易错判问题，FL的表达式为

$$L_{fl} = \begin{cases} -w_s (1 - p_i)^\gamma \lg p_i, & y = 1 \\ -w_{us} p_i^\gamma \lg(1 - p_i), & y = 0 \end{cases} \quad (15)$$

式中： γ 为难易样本调制因子。当 p_i 趋于1，则 $1 - p_i$ 趋于0，模型更容易判断样本为稳定。反之，当 p_i 趋于0，则 $1 - p_i$ 趋于1，模型更容易判断样本为失稳。可以看到，无论 p_i 趋于1还是0，其对应的损失值都趋于0，保证了模型不过多关注这些易分类样本。然而，当 p_i 趋于0.5时， $1 - p_i$ 也趋于0.5，模型难以确定样本的稳定状态，会导致这些难分类样本易错判。FL函数通过设置合适的 γ 值动态调整损失，以控制对难分类和易分类样本的关注度，可增强模型对难分类样本的学习并弱化易分类样本的影响。

2.3 模型评价指标

暂态稳定评估本质上是二分类问题，且暂态样本存在类别不平衡情况，若只采用全局评估准确率作为模型的评价指标，难以全面反映模型性能。另外考虑到失稳样本判断为稳定的代价比稳定样本判断为失稳大，评价指标应更多关注失稳样本的评估准确率。因此本文借助机器学习分类任务中的混淆矩阵^[25]，采用准确率(A_{cc})、召回率(R_{cc})、精度(P_{re})和 F_1 分数来综合评价模型的评估性能，混淆矩阵如表1所示。

其中， T_s 、 T_{us} 分别表示被正确评估的稳定样本和失稳样本的数量， F_s 表示被错误分类为稳定的失稳样本的数量(漏判)， F_{us} 表示被错误分类为失稳的稳定样本的数量(误判)。各项评价指标的数学定义如式(16)–(19)所示。

表1 TSA混淆矩阵		
Table 1 TSA confusion matrix		
预测标签	实际标签	
	稳定	失稳
稳定	T_s	F_s
失稳	F_{us}	T_{us}

$$A_{cc} = \frac{T_s + T_{us}}{T_s + F_s + T_{us} + F_{us}} \quad (16)$$

$$R_{cc} = \frac{T_{us}}{T_{us} + F_s} \quad (17)$$

$$P_{re} = \frac{T_s}{T_s + F_{us}} \quad (18)$$

$$F_1 = \frac{2P_{re}R_{cc}}{P_{re} + R_{cc}} \quad (19)$$

式中: A_{cc} 表征的是被正确评估的样本占总样本的比例, 反映模型评估的全局准确率; R_{cc} 表征被正确评估的失稳样本占实际失稳样本的比例, R_{cc} 越高, 表明失稳样本被漏判为稳定样本的个数越少; P_{re} 表征被正确评估的失稳样本占评估为失稳样本的比例, F_1 为 R_{cc} 和 P_{re} 的调和平均, 用以综合衡量二者。

2.4 暂态稳定评估流程

基于 TCN-AGCN 的电力系统暂态稳定评估流程如图 3 所示。整个评估流程包括 3 个阶段, 分别是样本生成、离线训练和在线评估。

1) 样本生成阶段。首先, 在时域仿真软件中搭建算例系统, 并在多种负荷水平下设置故障条件(包括不同故障线路、不同线路故障位置以及不同故障持续时间), 从而获取大量暂态样本。其次, 利用 TSI 为每个样本贴上标签, 并选取各样本中所有母线电压的幅值和相角作为模型的初始输入特征。为保证选取数据的质量, 采用“三段式”采样, 即采样窗口涵盖故障前稳态、故障中和故障后。然后, 将所选取数据经过 min-max 归一化处理后划分为训练集、验证集和测试集。

2) 离线训练阶段。将训练集输入给 TCN-AGCN 模型进行训练, 此过程中, 采用 FL 函数作为损失函数, 训练目标为最小化损失函数值, 同时, 在每个训练 epoch 中, 记录训练模型在验证集上的损失值, 直至训练损失和验证损失都收敛并低于设定值




图3 基于 TCN-AGCN 的暂态稳定评估流程

Fig. 3 Transient stability assessment process based on TCN-AGCN

时, 模型训练完成。否则调整模型的超参数重新进行训练。

3) 在线应用阶段。测试集在离线训练过程中完全未知。在线评估时, 可将其模拟为相量测量单元(phase measurement unit, PMU)的实时量测数据, 并输入给最优模型, 可快速得到评估结果。

3 算例分析

为验证所提方法的有效性, 本文采用 PSD-BPA 仿真软件生成样本集, 并基于 python3.8 下的 PyTorch 框架搭建 TCN-AGCN 评估模型。鉴于深度神经网络的超参数对模型性能有较大影响, 目前又尚无完善的理论来指导超参数选取, 因此本文参考文献[24], 经多次实验测试以确定模型的超参数。设置时空特征提取层的网络层数为 3; 在 TCN 的每一层隐藏层后添加 dropout 以防止过拟合, dropout 的值设为 0.3, 扩张因子设为 2; AGCN 网络深度设为 3, 邻居节点个数设为 8, 激活函数的饱和率 $\alpha = 3$, 特征保留率 $\beta = 0.05$; 失稳样本权重因子 $w_{us} = 0.75$, 稳定样本权重因子 $w_s = 0.25$, 难易样本调制因子 $\gamma = 2$; 训练批量大小设为 128, 训练轮次设为 120, 初始学习率设为 0.001, 优化算法采用 Adam。部分超参数对模型性能的影响详见附录 A。

3.1 样本集生成

在 PSD-BPA 仿真软件中搭建 IEEE 39 节点系统, 负荷水平分别设置为基准负荷的 75%~120%, 并以 5% 的步长增加, 同时调整机组出力, 保证潮流收敛。故障类型为三相短路, 故障位置分别设置在 34 条输电线路的 10%~90% 处, 并以 10% 的步长增加。故障持续时间分别设置为 0.1s, 0.14s, 0.18s, 0.22s, 仿真时长设为 6s。去除部分异常样本, 共计生成 12200 个样本, 利用式(13)为样本贴上稳定/失稳标签。其中, 稳定样本数量为 9223, 失稳样本数量为 2977, 稳定样本和失稳样本的比例约为 3:1。最后按照 8:1:1 的比例将样本集划分为训练集, 验证集和测试集。

3.2 损失函数效果对比

二元交叉熵和加权交叉熵损失函数常用于指导深度学习评估模型训练, 将二者和 FL 函数分别用于指导模型训练, 所得训练模型在测试集上的性能指标如表 2 和图 4 所示。

结合表 2 和图 4 可知, 采用 FL 函数训练时的 TSA 模型性能最好, 漏判样本和误判样本的数量都是最少的。这是因为 FL 函数中引入了样本类别权重因子, 降低稳定样本参与模型参数调节的频率,

表 2 不同损失函数的评估结果				
Table 2 Test results of different loss functions				
损失函数	$A_{cc}/\%$	$R_{cc}/\%$	$P_{re}/\%$	$F_1/\%$
二元交叉熵	98.85	97.08	97.79	97.44
加权交叉熵	99.26	98.18	98.53	98.35
FL	99.51	98.54	99.26	98.90




图 4 不同损失函数的混淆矩阵

Fig. 4 Confusion matrix of different loss functions

改善了模型将未知样本倾向于评估为稳定样本这一问题。同时，其难易样本调制因子的存在，使得模型在训练过程中更多地关注处于稳定边界的难分类样本，增强了对这类样本的学习。

为进一步验证 FL 函数的有效性，考虑从样本集中选取 8000 个样本，保证稳定样本与失稳样本的比例分别接近 4:1、5:1、6:1、7:1、8:1、9:1，并按照 8:1:1 的比例将样本集划分为训练集，验证集和测试集。训练过程中，加权交叉熵函数和 FL 函数的样本类别权重因子根据样本不平衡比例进行调整，FL 的难易样本调制因子保持不变。3 种损失函数在测试集上的性能如图 5 所示。

可以看出，经 FL 函数训练所得 TSA 模型在不同比例样本不平衡下的表现均优于其他两者。二元交叉熵函数没有考虑稳定样本和失稳样本的数量差异，导致对失稳样本的学习不足，因而其训练所得模型的评估性能随着样本不平衡比例增大而急速下降。加权交叉熵函数引入了样本类别权重因子，改善了模型倾向性问题，因而其评估性能介于二元交叉熵函数和 FL 函数之间。在后续分析中，TCN-AGCN 模型均是指使用 FL 函数进行训练得到的模型。

3.3 模型评估性能对比

采用相同的样本集构建 DT、SVM、CNN、LSTM、TCN、GCN、GAT、AGCN 等深度学习评估模型，并将其与本文所提评估模型进行对比，以




图 5 不同比例样本不平衡下模型评估性能

Fig. 5 Model assessment performance under different sample imbalance ratios

验证本文所提评估模型的有效性。其中，DT 选择 C5.0 算法，置信因子采用默认值 0.25；SVM 采用径向基函数，通过网格搜索法和五折交叉验证寻找相关参数最优值；CNN 设置两个卷积层和两个全连接层，卷积核大小设置为 3；LSTM 的隐藏层神经元个数为{64, 128, 32}，并设置一个全连接层；GCN 的邻接矩阵采用实际连接关系构建，卷积层数设置为 3；GAT 多头注意力设置为 4，聚合方式采用取平均值。各模型在相同测试集上的评估性能如表 3 所示。

由表 3 可知，DT、SVM 等浅层神经网络对底层数据的理解能力有限，准确率最差，且 F_1 分数都未达到 90%。CNN、LSTM 等深度学习算法的特征

表 3 不同评估模型测试结果				
Table 3 Test results of different assessment models				
模型	$A_{cc}/\%$	$R_{cc}/\%$	$P_{re}/\%$	$F_1/\%$
DT	94.92	86.13	90.77	88.39
SVM	95.41	87.59	91.60	89.55
CNN	96.72	90.51	94.66	92.54
LSTM	98.03	94.89	96.30	95.59
TCN	98.28	95.62	96.68	96.15
GCN	98.35	95.99	96.69	96.34
GAT	98.44	96.70	96.35	96.53
AGCN	98.93	97.08	98.15	97.61
本文	99.51	98.54	99.26	98.90


提取能力比浅层神经网络好,因而相应模型的评估性能也更高。GCN、GAT 相比于 AGCN,其评估性能稍差,这是由于 AGCN 在层间传播过程中保留了节点的部分原始状态,同时,其邻接矩阵能反映节点之间的连接强度,这使得 AGCN 提取到的特征信息更为丰富。本文所提 TCN-AGCN 评估模型充分融合了暂态数据的时序特征和电网拓扑的空间结构特征,其各项评估指标均优于 TCN 和 AGCN,准确率、 F_1 分数分别达到 99.51%和 98.9%。尤其是召回率达到 98.54%,这说明所提模型将失稳样本漏判为稳定样本的个数最少,保证了失稳样本的评估准确率。

3.4 PMU 测量数据含噪声情况下的评估结果分析


在实际电力系统中,PMU 采集到的数据可能存在测量误差。根据 IEEE 电力系统同步数据传输标准^[26],PMU 测量误差应小于 1%。测量误差与信噪比的转换公式如下:

$$\eta = 10 \lg(P_s / P_n) \quad (20)$$

式中: P_s 为信号有效功率; P_n 为噪声有效功率; η 为信噪比; 信噪比越小,说明噪声干扰越严重。本文考虑 0.2%, 0.4%, 0.6%, 0.8%的测量误差,对应的噪声信噪比分别为 26.99、23.98、22.22、20.97dB,将加入噪声后的测试集用于测试各模型的评估性能,测试结果如图 6 所示。



(a) 不同噪声水平下各模型准确率



(b) 不同噪声水平下各模型 F_1 分数

图 6 不同噪声水平下各模型评估性能

Fig. 6 Assessment performance of each model under different noise levels


从图 6 中可以看出,在加入噪声后,各模型的评估性能都有所下降,且噪声越严重,各模型的准确率和 F_1 分数下降得越多。本文所提 TCN-AGCN 模型即使在 20.97dB 的噪声水平下,其准确率仍能维持在 98.17%,相比于无噪声情况仅下降了 1.34%, F_1 分数仍能达到 96%,相比于无噪声情况下降了 2.89%。这是因为所提模型通过聚合邻居节点的信息来更新节点特征表示,这种聚合机制意味着每个节点的特征表示不仅依赖于自身,还依赖于其邻居节点的特征,即使某个节点的特征含有噪声,其邻居节点可以一定程度上平滑噪声的影响。与其他几组对照模型相比,在各噪声水平下,所提评估模型的性能都是最优的,这说明所提模型对于噪声具有较强的鲁棒性。

3.5 电网拓扑结构变化下的适应性分析


在电力系统运行中,通常会由于线路检修或者故障造成系统不再能维持全拓扑结构。若模型对电网的拓扑变化具有较强的泛化能力,即在电力系统拓扑发生变化后模型仍具有较好的评估性能,可避免更新模型过程,从而降低计算代价。因此,本节将通过比较不同模型在电网拓扑结构变化下的泛化能力,以验证所提出的评估模型在电网拓扑变化后的性能优势。

电网拓扑结构变化考虑在 IEEE 39 节点系统中随机断开 1-2 条输电线路,形成 N-1、N-2 拓扑(后文中称为新拓扑),并保证系统的节点数不发生变化。由于新拓扑的运行方式组合太多,完全遍历的代价太大,因此,本文随机选取 40 种拓扑组合(详见附录 B)并设置故障进行时域仿真。故障设置条件参照 3.1 节,共计生成仿真样本 4080 个,其中稳定样本数量为 2448,失稳样本数量为 1632。将该样本集作为测试集,用于测试各模型的评估性能,测试结果如图 7 所示。

可以看出,本文所提 TCN-AGCN 模型在新拓扑下具有最好的评估性能,准确率、 F_1 分数分别为 98.43%和 98.03%,均优于其他几组对照模型,这表明所提模型对系统的拓扑变化具有良好的泛化能力。GCN、GAT、AGCN 等图神经网络模型在新拓扑下的性能次于 TCN-AGCN,优于 DT、SVM、CNN、LSTM 和 TCN 模型,原因在于这类模型可以挖掘到电网拓扑的空间结构特征,当电网拓扑结构发生变化时,会反映在输入给模型的邻接矩阵中,因而其性能受拓扑变化的影响较小。TCN-AGCN 在 AGCN 的基础上进一步考虑了暂态数据的时序特征,所以在原拓扑和新拓扑测试集上的性



(a) 不同电网拓扑下各模型准确率



(b) 不同电网拓扑下各模型 F_1 分数

图 7 不同电网拓扑下各模型的评估性能
Fig. 7 Assessment performance of each model under different topologies

能都要优于 AGCN。其他常规的深度学习和浅层神经网络模型由于无法揭示系统拓扑结构的变化，导致在新拓扑测试集上的性能表现不佳。

3.6 不同规模系统模型有效性分析

为进一步验证所提模型在更大规模系统上的评估性能，采用 IEEE 145 节点系统作为算例进行仿真分析，该系统含 50 台发电机、145 条母线、453 条支路。随机选取部分线路分别设置三相短路故障，故障条件参照 3.1 节。共计生成 8670 个样本，稳定样本 7159 个，失稳样本 1601 个。由于系统规模增大，网络的节点数增加，所提模型在训练过程中需要将节点数更改为 145，并适当调整中心节点的邻居节点个数，其他实验流程参照 3.3 节。各模型在 IEEE 145 节点系统上的测试结果如表 4 所示。

可以看出，所提模型在 IEEE 145 节点系统上的表现均优于其他几组对照模型，准确率和 F_1 分数分别维持在 99.31%和 98.43%，具有较高的评估性能。这说明所提模型对于更大规模的系统同样具有适用性。

表 4 不同评估模型在 IEEE 145 节点系统上的测试结果
Table 4 Testing results of different assessment models on the IEEE 145-node system

模型	$A_{cc}/\%$	$R_{cc}/\%$	$P_{re}/\%$	$F_1/\%$
DT	93.19	80.21	88.00	83.92
SVM	94.69	82.29	92.94	87.29
CNN	96.54	88.54	95.51	91.89
LSTM	97.69	92.71	96.74	94.68
TCN	97.92	93.75	96.77	95.24
GCN	98.15	95.31	96.32	95.81
GAT	98.50	95.83	97.35	96.59
AGCN	98.85	96.35	98.40	97.37
本文	99.31	97.92	98.95	98.43

3.7 模型耗时分析

为体现本文所提 TCN-AGCN 评估模型的时间效率，将其与常规深度学习模型(以 CNN 和 LSTM 为例)的训练耗时和在线评估耗时进行对比分析。其中，离线训练耗时为训练集训练模型和验证集寻找最佳损失值耗时之和。测试结果如表 5 所示。

表 5 不同模型时间效率对比
Table 5 Comparison of time efficiency of different models

系统	模型	训练耗时/s	评估耗时/s	单个样本评估耗时/ms
IEEE 39	CNN	97.32	0.035	0.029
	LSTM	100.26	0.040	0.033
	本文	1462.47	0.390	0.320
IEEE 145	CNN	121.48	0.042	0.048
	LSTM	151.25	0.045	0.052
	本文	2559.83	0.394	0.454

可以看出，本文所提 TCN-AGCN 的离线训练耗时远大于 CNN 和 LSTM 模型，这是由于 TCN-AGCN 模型中涉及到通过节点间的连接来更新特征表示，这增加了信息传递过程中的计算量，从而造成模型训练时间的增加。值得注意的是，TCN-AGCN 模型进行在线评估时，两个系统的平均单个样本的评估耗时仅为 0.32 和 0.454ms，虽略高于常规深度学习模型，但相比于时域仿真方法可忽略不计。故本文所提 TCN-AGCN 模型是一种能满足在线评估要求的 TSA 模型。

4 结论

本文针对电力系统暂态数据的时序特征和电网拓扑的空间结构特征，提出一种基于 TCN-AGCN 的电力系统暂态稳定评估方法，并采用焦点损失函数指导模型训练。本文所提方法在 IEEE 39 和 IEEE 145 节点系统上进行了仿真研究，得到如下结论：

1) 焦点损失函数中引入了样本类别权重因子和难易样本调制因子，有效改善了样本类别不平衡所造成的模型倾向性问题，同时还能专注于稳定边界难分类样本的学习，使得模型的准确率得以提高，失稳样本漏判为稳定的个数减少。

2) 本文所提方法充分挖掘了暂态数据的时序特征和电网拓扑的空间结构特征,保证了模型的评估性能。并且在数据存在噪声和电网拓扑发生变化的情况下,模型的评估性能仍能维持在较高水平,对噪声和电网拓扑变化具有较强的泛化能力。

3) 虽然所提模型在训练时间上要大于常规深度学习模型,但其在线评估耗时与常规深度学习模型相差不大,与时域仿真耗时相比可忽略不计,故所提模型是一种能满足在线评估要求的 TSA 模型。

附录见本刊网络版 (<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

参考文献

- [1] HATZIARGYRIOU N, MILANOVIC J, RAHMANN C, et al. Definition and classification of power system stability-revisited & extended[J]. IEEE Transactions on Power Systems, 2021, 36(4): 3271-3281.
- [2] 王扬, 张靖, 何宇, 等. 虚拟同步发电机暂态稳定协同控制[J]. 电力自动化设备, 2018, 38(12): 181-185.
WANG Yang, ZHANG Jing, HE Yu, et al. Transient stability synergetic control of virtual synchronous generator[J]. Electric Power Automation Equipment, 2018, 38(12): 181-185(in Chinese).
- [3] 李永康, 刘宝柱, 胡俊杰. 基于数据驱动与时域仿真融合的电力系统暂态稳定快速评估[J]. 电网技术, 2023, 47(11): 4386-4395.
LI Yongkang, LIU Baozhu, HU Junjie. Rapid evaluation of power system transient stability based on fusion of data-driven and time-domain simulation[J]. Power System Technology, 2023, 47(11): 4386-4395(in Chinese).
- [4] GHAEDI S, ABAZARI S, ARAB MARKADEH G. Transient stability improvement of power system with UPFC control by using transient energy function and sliding mode observer based on locally measurable information[J]. Measurement, 2021, 183: 109842.
- [5] 武宇翔, 韩肖清, 牛哲文, 等. 基于变权重随机森林的暂态稳定评估方法及其可解释性分析[J]. 电力系统自动化, 2023, 47(14): 93-104.
WU Yuxiang, HAN Xiaoqing, NIU Zhewen, et al. Transient stability assessment method based on variable weight random forest and its interpretability analysis[J]. Automation of Electric Power Systems, 2023, 47(14): 93-104(in Chinese).
- [6] 石访, 张林林, 胡熊伟, 等. 基于多属性决策树的电网暂态稳定规则提取方法[J]. 电工技术学报, 2019, 34(11): 2364-2374.
SHI Fang, ZHANG Linlin, HU Xiongwei, et al. Power system transient stability rules extraction based on multi-attribute decision tree[J]. Transactions of China Electrotechnical Society, 2019, 34(11): 2364-2374(in Chinese).
- [7] WANG Huaiyuan, HU Litao, ZHANG Yang. SVM based imbalanced correction method for power systems transient stability evaluation[J]. ISA Transactions, 2023, 136: 245-253.
- [8] ZHANG Shiyao, YU J J Q. Bayesian deep learning for dynamic power system state prediction considering renewable energy uncertainty[J]. Journal of Modern Power Systems and Clean Energy, 2022, 10(4): 913-922.
- [9] NIE Xianglun, ZHANG Jing, HE Yu, et al. Ground fault detection based on fault data stitching and image generation of resonant grounding distribution systems[J]. Energies, 2023, 16(7): 2937.
- [10] SHI Zhongtuo, YAO Wei, ZENG Linggang, et al. Convolutional neural network-based power system transient stability assessment and instability mode prediction[J]. Applied Energy, 2020, 263: 114586.
- [11] 邵美阳, 吴俊勇, 李宝琴, 等. 基于两阶段集成深度置信网络的电力系统暂态稳定评估[J]. 电网技术, 2020, 44(5): 1776-1787.
SHAO Meiyang, WU Junyong, LI Baoqin, et al. Transient stability assessment of power system based on two-stage ensemble deep belief network[J]. Power System Technology, 2020, 44(5): 1776-1787(in Chinese).
- [12] 解治军, 张东霞, 韩肖清, 等. 基于改进长短期记忆网络的电力系统暂态稳定评估方法研究[J]. 电网技术, 2024, 48(3): 998-1007.
XIE Zhijun, ZHANG Dongxia, HAN Xiaoqing, et al. Research on transient stability assessment method of power system based on improved long short term memory network[J]. Power System Technology, 2024, 48(3): 998-1007(in Chinese).
- [13] 朱乔木, 陈金富, 李弘毅, 等. 基于堆叠自动编码器的电力系统暂态稳定评估[J]. 中国电机工程学报, 2018, 38(10): 2937-2946, 3144.
ZHU Qiaomu, CHEN Jinfu, LI Hongyi, et al. Transient stability assessment based on stacked autoencoder[J]. Proceedings of the CSEE, 2018, 38(10): 2937-2946, 3144(in Chinese).
- [14] ZHAN Xianwen, HAN Song, RONG Na, et al. A two-stage transient stability prediction method using convolutional residual memory network and gated recurrent unit[J]. International Journal of Electrical Power & Energy Systems, 2022, 138: 107973.
- [15] 张若愚, 吴俊勇, 李宝琴, 等. 基于迁移学习的电力系统暂态稳定自适应预测[J]. 电网技术, 2020, 44(6): 2196-2203.
ZHANG Ruoyu, WU Junyong, LI Baoqin, et al. Self-adaptive power system transient stability prediction based on transfer learning[J]. Power System Technology, 2020, 44(6): 2196-2203(in Chinese).
- [16] 周子涵, 卜广全, 马士聪, 等. 基于特征分离型神经网络的电力系统暂态稳定性评估与优化方法[J]. 电网技术, 2021, 45(9): 3658-3666.
ZHOU Zihan, BU Guangquan, MA Shicong, et al. Assessment and optimization of power system transient stability based on feature-separated neural networks[J]. Power System Technology, 2021, 45(9): 3658-3666(in Chinese).
- [17] 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(in Chinese).
- [18] HUANG Jiyu, GUAN Lin, SU Yinsheng, et al. A topology adaptive high-speed transient stability assessment scheme based on multi-graph attention network with residual structure[J]. International Journal of Electrical Power & Energy Systems, 2021, 130: 106948.
- [19] 王铮澄, 周艳真, 郭庆来, 等. 考虑电力系统拓扑变化的消息传递图神经网络暂态稳定评估[J]. 中国电机工程学报, 2021, 41(7): 2341-2349.
WANG Zhengcheng, ZHOU Yanzen, GUO Qinglai, et al. Transient stability assessment of power system considering topological change: a message passing neural network-based approach[J]. Proceedings of the CSEE, 2021, 41(7): 2341-2349(in Chinese).
- [20] 李宝琴, 吴俊勇, 强子玥, 等. 基于改进 DCGAN 的电力系统暂态稳定增强型自适应评估[J]. 电力系统自动化, 2022, 46(2): 73-82.
LI Baoqin, WU Junyong, QIANG Ziyue, et al. Enhanced adaptive assessment on transient stability of power system based on improved

- deep convolutional generative adversarial network[J]. Automation of Electric Power Systems, 2022, 46(2): 73-82(in Chinese).
- [21] ZHAN Xianwen, HAN Song, RONG Na, et al. A hybrid transfer learning method for transient stability prediction considering sample imbalance[J]. Applied Energy, 2023, 333: 120573.
- [22] 李宝琴, 吴俊勇, 邵美阳, 等. 基于集成深度置信网络的精细化电力系统暂态稳定评估[J]. 电力系统自动化, 2020, 44(6): 17-26.
- LI Baoqin, WU Junyong, SHAO Meiyang, et al. Refined transient stability evaluation for power system based on ensemble deep belief network[J]. Automation of Electric Power Systems, 2020, 44(6): 17-26(in Chinese).
- [23] 周宇, 肖健梅, 王锡淮. 基于 GCN 和 HGP-SL 的电力系统暂态稳定评估[J]. 电气工程学报, 2024, 19(4): 246-254.
- ZHOU Yu, XIAO Jianmei, WANG Xihuai. Power system transient stability assessment based on graph convolutional network and hierarchical graph pooling with structure learning[J]. Journal of Electrical Engineering, 2024, 19(4): 246-254(in Chinese).
- [24] 孙黎霞, 白景涛, 周照宇, 等. 基于双向长短期记忆网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2020, 44(13): 64-72.
- SUN Lixia, BAI Jingtao, ZHOU Zhaoyu, et al. Transient stability assessment of power system based on bi-directional long-short-term memory network[J]. Automation of Electric Power Systems, 2020, 44(13): 64-72(in Chinese).
- [25] CHENG Shan, YU Zihao, LIU Ye, et al. Power system transient stability assessment based on the multiple paralleled convolutional neural network and gated recurrent unit[J]. Protection and Control of Modern Power Systems, 2022, 7(3): 1-16.
- [26] MARTIN K E., BRUNELLO G, ADAMIAK M G, et al. An overview of the IEEE standard C37. 118. 2—synchrophasor data transfer for power systems[J]. IEEE Transactions on Smart Grid, 2014, 5(4): 1980-1984.



肖龙

在线出版日期: 2024-11-28。

收稿日期: 2024-09-18。

作者简介:

肖龙(2000), 男, 硕士研究生, 研究方向为基于深度学习的电力系统暂态稳定评估, E-mail: 2874712213@qq.com;

张靖(1979), 男, 教授, 博士生导师, 通信作者, 研究方向为电力系统分析、稳定和控制等, E-mail: zhangjing@gzu.edu.cn。

(责任编辑 赵梓含)




图 A1 邻居节点个数对模型性能的影响

Fig. A1 The impact of the number of neighboring nodes on model performance




图 A2 激活函数饱和率对模型性能的影响

Fig. A2 The impact of activation function saturation on model performance




图 A3 特征保留率对模型性能的影响

Fig. A3 The impact of feature retention rate on model performance




图 A4 难易样本调制因子对模型性能的影响

Fig. A4 The impact of difficulty sample modulation factor on model performance




图 B1 IEEE 39 节点系统结构图
Fig. B1 Structure diagram of the IEEE 39-node system

表 B1 新拓扑运行方式
Table B1 New topology operating modes

拓扑方式	断开输电线路	拓扑方式	断开输电线路	拓扑方式	断开输电线路	拓扑方式	断开输电线路
1	1-2	11	17-18	21	1-2、17-18	31	6-11、17-18
2	7-8	12	17-27	22	1-2、17-27	32	2-25、17-27
3	8-9	13	21-22	23	1-2、21-22	33	10-11、21-22
4	2-25	14	22-23	24	7-8、22-23	34	13-14、22-23
5	6-11	15	23-24	25	7-8、23-24	35	15-16、23-24
6	10-11	16	25-26	26	7-8、25-26	36	16-19、25-26
7	13-14	17	26-27	27	8-9、26-27	37	16-21、26-27
8	15-16	18	26-28	28	8-9、26-28	38	8-9、21-22
9	16-19	19	26-29	29	8-9、26-29	39	16-19、13-14
10	16-21	20	28-29	30	2-25、28-29	40	10-11、15-16