



DOI:10.12404/j.issn.1671-1815.2407675

引用格式:侯一帆,徐天奇,李琰,等.基于Transformer-GAT并行特征融合的数据驱动的电力系统暂态稳定评估[J].科学技术与工程,2025,25(21):8945-8954.

Hou Yifan, Xu Tianqi, Li Yan, et al. Data-driven transient stability assessment of power systems based on Transformer-GAT parallel feature fusion[J]. Science Technology and Engineering, 2025, 25(21): 8945-8954.

基于Transformer-GAT并行特征融合的数据驱动的电力系统暂态稳定评估

侯一帆¹, 徐天奇^{1,2*}, 李琰¹, 李晓兰¹

(1. 云南民族大学电气信息工程学院云南省高校电力信息物理融合系统重点实验室, 昆明 650504;

2. 云南省无人自主系统重点实验室, 昆明 650504)

摘要 随着电力系统的快速发展,大规模新能源并网及源网荷储协同优化增加了电力电子设备的比重,使得电网稳定性,特别是暂态稳定性评估,变得尤为重要。针对传统方法在拓扑结构考虑不足的问题,提出了一种基于Transformer-图注意力网络(graph attention network, GAT)并行特征融合的深度学习方法,用于电力系统暂态稳定性评估。以母线电压幅值、相角及拓扑邻接矩阵作为输入特征,利用西门子仿真软件PSS/E生成批量数据,并通过Transformer和GAT并行提取特征,采用注意力机制进行加权融合。与其他方法的对比结果表明,该方法在IEEE 39节点系统中模拟了不同负荷条件和故障工况,结果表明评估精度和鲁棒性较高,能够有效提升电力系统的安全稳定性。

关键词 暂态稳定性; 数据驱动; 注意力机制; Transformer; 图注意力网络; 特征融合

中图分类号 TM732;

文献标志码 A

Data-driven Transient Stability Assessment of Power Systems Based on Transformer-GAT Parallel Feature Fusion

HOU Yi-fan¹, XU Tian-qi^{1,2*}, LI Yan¹, LI Xiao-lan¹

(1. Key Laboratory of Cyber-Physical Power System of Yunnan Universities, School of Electrical and Information Technology,

Yunnan Minzu University, Kunming 650504, China;

2. Yunnan Key Laboratory of Unmanned Autonomous System, Kunming 650504, China)

[Abstract] With the rapid development of the power system, the large-scale integration of new energy into the grid and the coordinated optimization of source-grid-load-storage have increased the proportion of power electronic equipment, making the stability of the power grid, especially the assessment of transient stability, particularly important. Aiming at the problem of insufficient consideration of topological structure in traditional methods, a deep learning method based on Transformer-graph attention network(GAT) parallel feature fusion was proposed for the transient stability evaluation of power systems. The busbar voltage amplitude, phase angle and topological adjacenciation matrix were taken as input features. Batch data were generated using the Siemens simulation software PSS/E, and features were extracted in parallel through Transformer and GAT. Weighted fusion was carried out using the attention mechanism. The comparison results with other methods show that this method simulates different load conditions and fault conditions in the IEEE 39-node system. The results indicate that the evaluation accuracy and robustness are relatively high, and it can effectively improve the safety and stability of the power system.

[Keywords] transient stability; data-driven; attention mechanism; Transformer; graph attention network; feature fusion

随着全球气候变化和环境问题加剧,实现“碳达峰、碳中和”已成为各国的紧迫任务。并且随着中国电力系统规模的不断扩大以及可再生能源,特别是风能和太阳能的快速发展,电力系统的运行模

式变得日益复杂。在这种背景下,传统的稳定性评估方法面临着许多挑战,如动态负荷波动、可再生能源的间歇性和不可预测性。这使得电力系统暂态稳定性评估不仅在技术上要求更高的精度,而且

收稿日期: 2024-10-15 修订日期: 2025-04-22

基金项目: 国家自然科学基金(62062068); 云南省中青年学术和技术带头人后备人才项目(202305AC160077)

第一作者: 侯一帆(2000—),男,汉族,甘肃庆阳人,硕士研究生。研究方向:数据驱动电力系统。E-mail:2856334034@qq.com。

*通信作者: 徐天奇(1978—),男,汉族,云南禄丰人,博士,教授。研究方向:韧性电网、新能源发电并网、电力信息物理系统。E-mail:xu.tianqi@ynu.edu.cn。

在实际应用中也需更加灵活和高效的解决方案。2006年7月1日,华中电网系统功率振荡^[1]最终导致系统失稳震荡,期间频率最低为49.11 Hz,华中东部电网与川渝电网解列,华中电网与西北电网直流闭锁、与华北电网解列,可见对系统的失稳情况及时进行评估不可或缺。同时,在此背景下,中国电力系统向源网荷储^[2]协同运行发展,新能源并网和电力电子器件的广泛应用使得暂态稳定性面临挑战,因此评估电力系统暂态稳定性尤为重要。传统的时域仿真法^[3]和直接法因复杂的电网拓扑和建模^[4]难题已无法满足需求。当前,更具时效性和可靠性的是数据驱动的暂态稳定性评估,早期采用机器学习如支持向量机(support vector machine, SVM)^[5]、 k -最近邻(k -nearest neighbors, kNN)、随机森林(random forest, RF)^[6]等,但因特征提取能力有限,现已逐渐转向深度学习驱动的评估方法。

文献[7]的卷积神经网络(convolutional neural network, CNN)暂态稳定性分析模型虽然采用了并行和串行融合,但忽略了电力系统网络的拓扑结构,缺乏时空特征提取,导致重要信息丢失。文献[8]采用主元分析和序列浮动后向算法筛选特征,并利用差分进化优化的极限学习机(extreme learning machine, ELM)进行暂态稳定评估,却未考虑拓扑信息。文献[9]基于 K 均值聚类(K -means clustering)聚类和多随机卷积核变换,灵活适应拓扑变化并高效提取时空特征。文献[10]提出了一种基于多层 CatBoost 的暂态稳定评估方法,利用 mRMR 特征选择和多数投票法,该方法在 IEEE 39 节点系统中具有高精度和良好的泛化能力,电力系统的空间结构并未考虑。文献[11]通过二维主成分分析(two-dimensional principal component analysis, 2D-PCA)降维时间序列图像并采用 CNN 进行稳定性预测,但未考虑拓扑结构影响。文献[12]提出的 CNN + GRU(gated recurrent unit)模型能够提取短期和长期特征,但忽视了空间特征。文献[13]提出了一种融合改进卷积神经网络(improved convolutional neural network, ICNN)与双向长短时记忆网络(bidirectional long short term memory network, BiLSTM)的暂态稳定评估方法,结合正则化和 Dropout 防止过拟合,但其特征量只考虑到了时序特征。文献[14]提出的 Transformer 编码器模型仅关注时序特征。文献[15]提出的 TSPM(transient stability program management)-CNN 方法有效提取时间序列和特征间相关性,但同样只考虑时序特征。文献[16]的 LSTM-SAF(long short-term memory with self-attention fusion)模型通过自注意机制提升了准确性,但忽视了空间信息。文献[17]基于 CNN 和极大似然

估计(maximum likelihood estimation, MLE)方法,仅利用测量的时间序列数据进行分析。文献[18]构建了基于 Transformer 编码器的电力系统暂态稳定评估方法,使模型快速捕获电力系统前后时刻间的全局状态依赖关系,故障识别准确率较高。

因此现针对以往研究考虑拓扑结构不足,不能同时考虑时间和空间的特征信息,提出一种基于 Transformer-GAT 并行特征融合的电力系统暂态稳定评估方法,能够有效捕捉输入序列中远距离时刻之间的依赖关系,而不受传统回归神经网络(recurrent neural network, RNN)或 Bi-LSTM^[19]的序列长度限制,图注意力网络(graph attention network, GAT)的空间结构信息捕捉能力突出^[20],该方法结合 Transformer 的时序特征捕捉能力和 GAT 的空间结构建模优势,有效处理电力系统的时空数据,提升评估准确性和鲁棒性。Transformer 通过注意力机制捕捉时间序列中的全局依赖,适用于电力系统动态响应的长时依赖分析。GAT 则利用自注意力机制捕捉电力系统拓扑结构中的节点关系及其相互影响,从而实现时空特征的联合建模。基于 Transformer-GAT 并行特征融合的方法在不同电力系统条件下有效评估暂态稳定性,避免类似于华中电网失稳的情况再次发生。为验证其可应用性,选取典型电力系统案例进行测试。最终在 IEEE-39 节点系统中来拟合中国电力系统的故障类型和负荷水平验证所提方法的有效性。

1 基于数据驱动的深度学习模型构建

1.1 图注意力网络概述

电力系统网络可以把母线抽象成节点,传输线路抽象成边,呈现出一种网状的数据结构,也就是非欧几里得结构,而图网络专门用来处理非欧几里得结构的网络拓扑图。因此电力系统网络就可以描述成 $G(\mathbf{X}, \mathbf{A})$, \mathbf{X} 为每个节点的特征, \mathbf{A} 为邻接矩阵,用来表示网络结构拓扑图。

$$\begin{cases} \mathbf{A}(p, q) = 1, \text{节点 } p, q \text{ 连接} \\ \mathbf{A}(p, q) = 0, \text{节点 } p, q \text{ 未连接} \end{cases} \quad (1)$$

而在 GAT^[21]中通过引入注意力机制,为每条边计算动态权重,从而调整邻居节点对中心节点的影响。尽管邻接矩阵仍是输入的一部分,但 GAT 不再依赖固定的邻接权重,而是基于注意力系数聚合节点特征。邻接矩阵定义了邻居节点集合,只有在矩阵中有边连接的节点才会被考虑。因此,邻接矩阵的信息在聚合过程中被间接利用。图注意力层输入的是一组节点特征 $\mathbf{x} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, $\mathbf{x}_i \in \mathbf{R}^F$, 其中 N 为节点数, F 为每个节点的特征。这层会产生新的节点特征 $\mathbf{x}' = \{\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_N\}$, $\mathbf{x}'_i \in \mathbf{R}^{F'}$ 作为输出。为

了更好提取特征, 需要将输入特征转换成更高维的特征, 至少需要一个可学习的线性变换层, 每个节点的线性变换参数是共享的, 该变换由权重矩阵 $\mathbf{W} \in \mathbf{R}^{F' \times F}$ 参数化, 之后在节点上进行自注意力-共享机制: $\mathbf{R}^{F'} \times \mathbf{R}^{F'} \rightarrow \mathbf{R}$ 计算注意力系数, 表达式为

$$e_{ij} = a(\mathbf{W} \mathbf{x}_i, \mathbf{W} \mathbf{x}_j) \quad (2)$$

式(2)表明节点 j 的特征对节点 i 的重要性。然后用 softmax 函数对在所有 j 的选择上进行归一化, 表达式为

$$\alpha_{ij} = \text{softmax}_j(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in N_i} \exp(e_{ik})} \quad (3)$$

注意力机制 a 是一个单层前馈神经网络, 由一个权重向量 $\mathbf{a} \in \mathbf{R}^{2F'}$ 参数化, 并应用了 LeakyReLU 非线性激活函数。完全展开后, 注意力机制(如图 1 所示)计算的系数可以表示为

$$\alpha_{ij} = \frac{\exp\{\text{LeakyReLU}[\mathbf{a}^T(\mathbf{W} \mathbf{x}_i \parallel \mathbf{W} \mathbf{x}_j)]\}}{\sum_{k \in N_i} \exp\{\text{LeakyReLU}[\mathbf{a}^T(\mathbf{W} \mathbf{x}_i \parallel \mathbf{W} \mathbf{x}_k)]\}} \quad (4)$$

式(4)中: 上角标^T表示转置; \parallel 表示拼接操作。

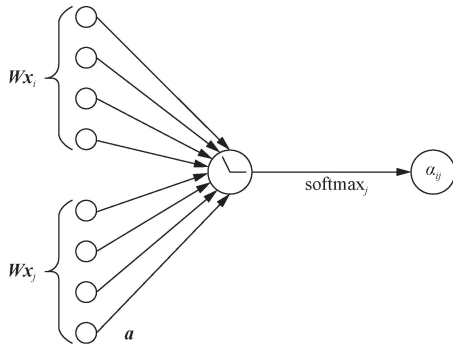


图1 图注意力机制

Fig. 1 Graph attention mechanism

得到归一化的注意力系数, 然后计算对应特征的线性组合, 以作为每个节点的输出特征, 即

$$\mathbf{x}_i = \sigma\left(\sum_{j \in N_i} \alpha_{ij} \mathbf{W} \mathbf{x}_j\right) \quad (5)$$

最终在预测层上通过多头注意力机制进行聚合过程, 如图 2 所示, 再用 softmax 进行分类评估。

1.2 Transformer 架构

在电力系统中, 电气量是具有时间序列的一种关系, 下一时刻的电压相角与上一时刻密切相连, 因此不能独立看待。在暂态过程中, 例如在发生故障、切换负荷或发电机动作时, 电压相角会迅速变化。通过时间序列分析, 可以捕捉电压相角的变化趋势, 进而评估电力系统的暂态稳定性和响应特性, 而 Transformer 具有很强的序列关系处理能力。

Transformer^[22] 采用的架构, 在编码器和解码器中分别使用了堆叠的自注意力机制和逐点的全连接层, 如图 3 所示的左半部分和右半部分所示。

在这种结构中, 编码器可以将电气特征量表示的输入序列 (x_1, x_2, \dots, x_n) 映射为连续的序列 $z = (z_1, z_2, \dots, z_n)$ 。在给定 z 的情况下, 解码器会逐步生成特征量的输出序列 (y_1, y_2, \dots, y_m) 。




图2 多头图注意力聚合

Fig. 2 Multi-head graph attention aggregation

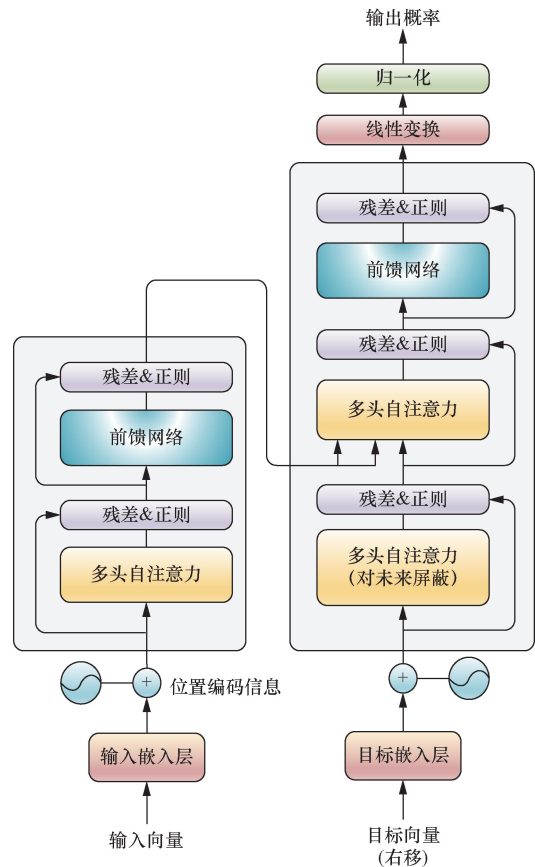


图3 Transformer 架构

Fig. 3 Transformer architecture

1.2.1 编码器和解码器堆叠

编码器:编码器由相同的层组成。每一层包含两个子层。第一个子层是多头自注意力机制,第二个子层是逐点的全连接前馈网络。在每个子层周围使用了残差连接,并在其后进行层归一化,每个子层的输出为 $\text{LayerNorm}[\mathbf{x} + \text{Sublayer}(\mathbf{x})]$,模型中的所有子层以及嵌入层都产生相同维度的输出。

解码器由与编码器相同的层组成,增加了一个子层:在编码器输出上执行多头注意力机制。每个子层通过残差连接和层归一化处理,为了防止某个位置关注后续位置,解码器中的自注意力子层引入了屏蔽机制。结合输出嵌入偏移的位置,确保每个位置的预测只依赖于先前的已知输出。

1.2.2 位置编码

在编码器和解码器堆栈的底部将“位置编码”添加到输入嵌入中使模型能够利用电气量序列的顺序信息。位置编码与嵌入的维度 d_{model} 相同,然后相加。

位置编码是通过使用不同频率的正弦和余弦函数来表示,即

$$\text{PE}_{(\text{pos}, 2i)} = \sin(\text{pos}/10\,000^{2i/d_{\text{model}}}) \quad (6)$$

$$\text{PE}_{(\text{pos}, 2i+1)} = \cos(\text{pos}/10\,000^{2i/d_{\text{model}}}) \quad (7)$$

式中:pos 为位置; i 为维度。

位置编码的每个维度对应一个正弦波。它可以让模型更容易通过相对位置来学习注意力机制。

1.3 基于注意力机制改进的 Transformer-GAT 特征融合模型构建

电力系统暂态稳定性评估需要捕捉故障后的

动态行为。结合 Transformer 和 GAT 的并行注意力机制是一种提升模型性能的有效方法。Transformer 擅长处理时间序列,通过多头自注意力机制捕捉电压、电流、相角等关键时序数据中的全局依赖,特别是在故障时识别系统的动态变化。GAT 利用电力系统的拓扑结构,通过图注意力机制学习节点间的依赖,聚合邻居节点特征,精准判断故障对不同节点的影响。再通过注意力权重对值进行加权求和的并行融合方式,如式(8)所示,并进行全局平均池化。模型结合时间序列与拓扑特征,能够更全面地捕捉时空信息,从而提升暂态稳定性评估的准确性与效率。模型结构如图 4 所示。

GAT 和 Transformer 的输出进行加权融合,表达式为

$$\text{Output} = \beta \mathbf{H}' + (1 - \beta) \text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) \quad (8)$$

式(8)中: \mathbf{H}' 为 GAT 提取的特征; $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为 Transformer 查询、键和值的特征输出。

1.4 基于 PyTorch 框架的模型实现

选用 PyTorch 框架来研究电力系统暂态稳定性评估是因为 PyTorch 提供了一个直观且易于使用的编程接口,使得深度学习模型的构建非常灵活,并且 PyTorch 使用动态计算图(dynamic computation graphs),可以在每一步训练中即时构建网络结构。同时可以利用 GPU 加速计算,极大地提高了模型训练和推理的速度。这在需要处理大量电力系统数据(如时序电压和相角数据)时尤为重要,可以大幅度减少模型的训练时间。

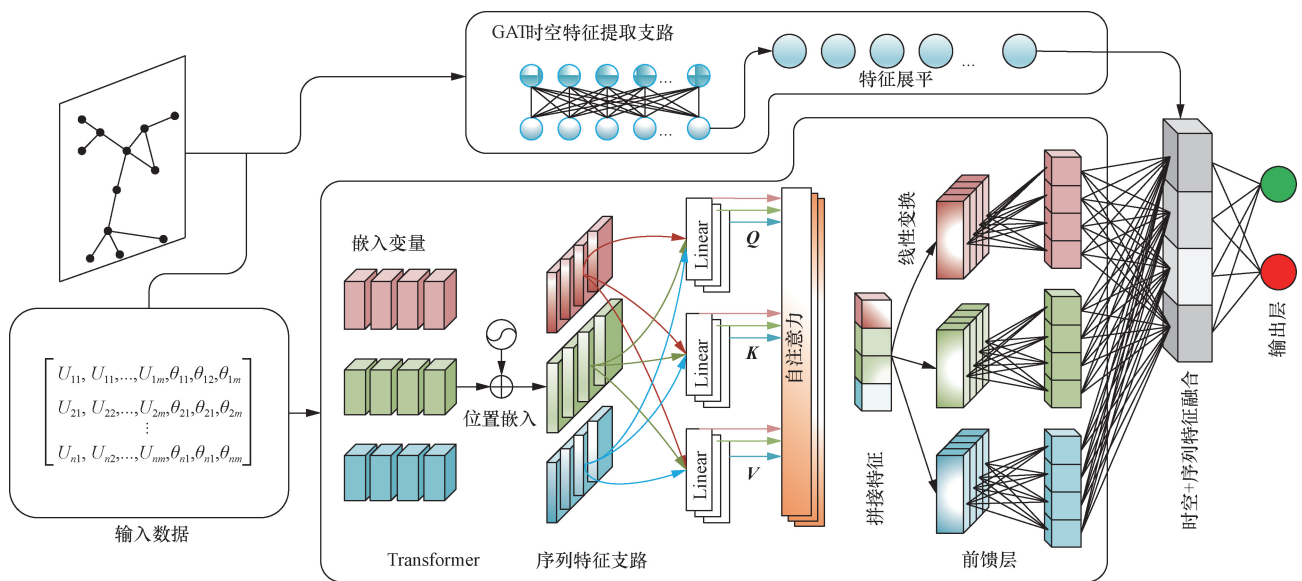


图4 Transformer-GAT 并行特征融合

Fig. 4 Parallel feature fusion of Transformer-GAT

Transfoemer-GAT 并行融合模型过程对暂态数据集进行训练,如表 1 所示,循环此过程直至模型性能满足要求。

表 1 Transfoemer-GAT 并行融合模型

Table 1 Transformer-GAT parallel fusion algorithm

初始化:数据集节点特征、边索引和标签 (node_features, edge_index, labels), 初始化 Transformer、GAT 参数
1. 准备输入数据,包括节点特征和邻接矩阵: Data (x = node_features, edge_index = edge_index)
2. 定义 Transformer 和 GAT 模型结构:TransformerLayer() 和 GAT-Conv()
3. 用 Transformer 处理节点特征数据,提取时间序列特征。用 GAT 处理节点特征数据,提取图结构特征:transformer (node_features)、gat (node_features, edge_index)
4. 将 Transformer 和 GAT 的输出进行加权方法融合, fusion (transformer, gat)
5. 损失计算和反向传播:loss (output, labels)、loss.backward()
6. 将融合后的特征传递给分类器进行最终预测:classifier (fusion_out)
7. 模型评估、保存模型参数

1.5 模型性能参数选取

Transformer 模型层数选取 4 层,注意力头数设置为 4 个,隐藏层维度:设置为 128,前馈网络大小设为隐藏层维度的 2 倍。图注意力网络图选用 2 层的图注意力网络。层数过多会导致图卷积中的过平滑问题,使得节点特征趋于一致,影响区分度。注意力头数:类似于 Transformer,选择 4 个头以增强模型的多样性。节点特征维度为 2。图注意力机制的激活函数使用 Leaky ReLU 作为激活函数可以增强模型的非线性表示能力。特征融合模块融合方式:采用注意力机制方式来融合 Transformer 和 GAT 提取的特征。注意力机制能平衡不同模型特征的影响,能够保留更多信息。优化器使用 Adam (adaptive moment estimation) 优化器,具有较好的收敛速度和稳定性。因为是二分类问题(稳定与不稳定),损失函数使用交叉熵损失 (cross-entropy loss)。学习率取 0.01,训练部分的批量大小 (Batch Size) 设为 256,因为数据集较大,同时较大的 Batch Size 可以提高并行性。训练轮数为 30 轮,使用 Dropout 技术 (取 0.3) 防止模型过拟合。

2 特征及性能指标构建

2.1 特征构建

随着智能电网的建设,各级调度中心积累了大量在线安全稳定分析数据,以及广域测量系统 (wide area measurement system, WAMS)^[23] 和相量测量单元 (phasor measurement unit, PMU) 的广泛普及和应用,这为基于数据驱动方法的电力系统稳

定分析和监测提供了可靠的同步数据源。神经网络、决策树、支持向量机、深度学习等数据驱动方法应用到电力系统的暂态稳定评估中,其通过大量离线数据进行训练,建立系统特征与暂态稳定性之间的映射关系。在线应用阶段,故障后根据训练所得的映射关系与 WAMS/PMU 测量数据,快速进行暂态稳定评估,及时为稳定控制算法提供依据。

电力系统暂态稳定性属于大扰动功角稳定问题。其定义为当电力系统发生故障后,若发电机的各功角 (δ_i) 能够维持在某一数值附近,则电力系统被认为是暂态稳定的。相反,电力系统暂态不稳定是指在发生较大扰动后,由于发电机之间功率的不平衡,导致机组间的相对功角 (δ) 非周期性增大,进而引发不稳定现象。由于系统部分发电机加速,部分发电机减速,系统的母线电压也随着功角的变化而改变,所以系统各母线电压幅值及相角可以表征电力系统暂态稳定的特征量。

2.2 暂态稳定判断依据

电力系统暂态稳定指的是系统受到大干扰下的功角稳定。当前较常用的稳定判断依据是扰动发生后转子功角的暂态稳定系数 (transient stability index, TSI)^[24]。

$$TSI = \frac{180^\circ - |\Delta\delta_{\max}|}{180^\circ + |\Delta\delta_{\max}|} \quad (9)$$

式(9)中: $\Delta\delta_{\max}$ 为任意两台发电机的最大相对功角差。若 $|\Delta\delta_{\max}| > 180^\circ$, 则 $TSI < 0$, 此时可以判定系统失稳,反之,系统稳定。

2.3 评估指标选择

电力系统暂态稳定问题可以理解为一个二分类问题,即 0/1 问题,1 表示由暂态稳定判据得到的稳定标签,0 则表示失稳标签。这时只需选择一系列可以表征电力系统状态的特征集合,然后选择构建好的模型就可以对系统稳定性进行分析。而二分类问题常用的混淆矩阵如表 2 所示。

在暂态稳定性分析 (transient stability assessment, TSA) 中,稳定与失稳样本之间的不平衡问题是备受关注的重点之一。失稳样本对模型的准确性以及后续应用可能产生重要影响。除了在生成样本时重点关注失稳状态的发生,还可以通过引入暂

表 2 混淆矩阵

Table 2 Confusion matrix

评估结果	真实标签	
	稳定	失稳
稳定	TP	FP
失稳	FN	TN

态失稳样本的预测准确率(true negative rate, TNR)和 F_1 -score (F_1) 来评估模型性能。 F_1 是衡量模型能力的综合指标。此外,结合整体准确率(accuracy, A)以及暂态稳定样本的预测准确率(true positive rate, TPR)^[25],可以更全面地评价模型的性能。它们各指标定义如下。

$$TNR = \frac{TN}{TN + FP} \times 100\% \quad (10)$$

$$R = TNR \quad (11)$$

$$TPR = \frac{TP}{TP + FN} \times 100\% \quad (12)$$

$$P = \frac{TN}{TN + FN} \times 100\% \quad (13)$$

$$F_1 = \frac{2PR}{P + R} \times 100\% \quad (14)$$

$$A = \frac{TP + TN}{TP + FP + TN + FN} \times 100\% \quad (15)$$

2.4 TSA 评估流程

主要步骤分为离线训练和在线验证,离线部分通过仿真得到暂态特征的数据,通过暂态稳定判断依据,得到数据所对应的标签值,经过数据处理之后,然后输入所构建的模型 Transformer-GAT 并行特征融合模型,当模型训练好后,保存模型。之后在 PMU 在线采集的实时数据作为训练好的模型输入,以此来验证电力系统暂态是否失稳,流程如图 5 所示。

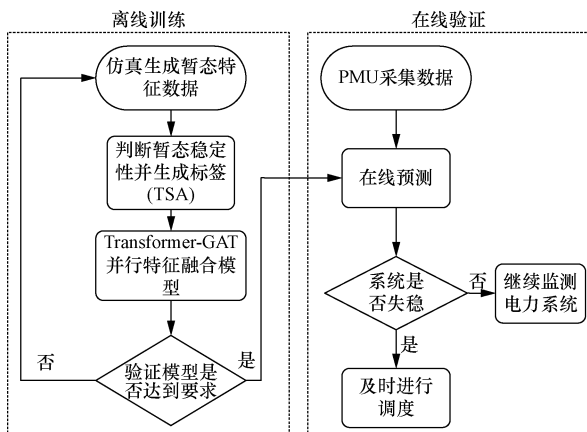


图5 TSA 流程图
Fig. 5 TSA flowchart

3 IEEE10 机 39 节点系统算例分析

选用 IEEE10 机 39 节点系统为算例进行分析,包含 39 条母线(节点),系统中有 10 台发电机,46 条输电线路连接母线之间,系统如图 6 所示。利用 Pytorch 框架搭建深度学习网络模型,硬件平台为 13th Gen Intel © Core™ i9-13900HX 和 NVIDIA GeForce RTX 4060 Laptop GPU。




图6 IEEE39 节点系统拓扑图
Fig. 6 IEEE 39-bus system topology diagram

3.1 构造数据集

采用的电力系统仿真软件是由西门子 PTI 公司开发的 PSS/E。该软件能够对电网进行建模、潮流计算以及故障分析,广泛应用于电力系统的规划、运行和分析等领域。PSS/E 不仅支持通过图形用户界面(graphical user interface, GUI)设置各种运行场景,还提供与 Python 的接口,可以自动批量生成暂态稳定样本,从而方便、快速地获得大量仿真真数据。

在全接线系统的运行模式下,以 5% 为步长调整负荷水平,范围为 70% ~ 140%。发电机出力随机分配,仿真总时长为 3 s。假设在 0.1 s 时系统发生三相短路故障,并分别在 0.2、0.3、0.4、0.5 和 0.6 s 时切除故障,故障位置随机变化。选取故障发生前、发生时和切除时 3 个时间节点,仿真得到这 3 个时刻 39 个节点的电压标幺值和相角数值。输入节点特征信息的矩阵维度为 39×2 。最终得到 7 000 个样本,其中包含 3 215 个失稳样本。训练集和测试集按 7:3 分配。

通过 PSSE 生成的暂态数据,再经过暂态稳定判断依据 TSI 对暂态稳定和失稳打上标签,因为数据集较大,所以选取一份失稳 IEEE39 节点的数据集以及对应的拓扑结构的邻接矩阵。通过对数据进行处理,因为使用的是 PyTorch 框架,所以要把数据转换成张量形式,从而使得它们可以作为 Transformer 和 GAT 并行特征融合模型的输入。

3.2 模型性能对比分析

3.2.1 并行和串行方式对比

不同于 Transformer-GAT 并行特征融合,在 Transformer 和 GAT 串行方式中,减少了融合方式,如图 7 所示。

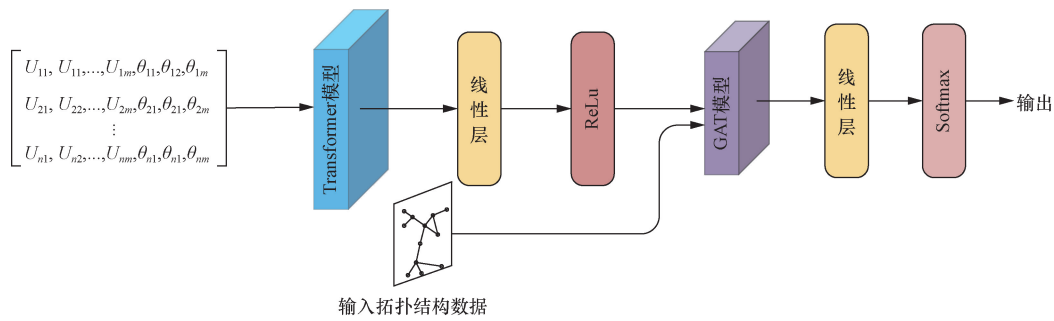


图7 Transformer 和 GAT 串行方式

Fig. 7 Serial configuration of Transformer-GAT

在前向反馈中将暂态时序数据先输入 Transformer 模型中, 再通过线性以及激活函数然后作为 GAT 模型的输入, 同时, 电力系统拓扑结构邻接矩阵也一起作为 GAT 模型输入, 最终通过线性空间变化以及 softmax 输出概率值确定是否暂态失稳。

如表 3 所示, Transformer-GAT 并行特征融合模型的准确率(A)在 98% 以上, 同时, F_1 、查全率(R)和查准率(P)都在 96% 以上, 相较于 Transformer 和 GAT 串行都有了进一步的提升, 尤其是在准确率误差上, 由原来 4% 降低到不足 2%, 误差降低近一半, 由于 Transformer 和 GAT 串行方法中特征传递过程中的信息可能会丢失, 导致最终输出的性能下降, F_1 、查全率(R)和查准率(P)都有所下降, 说明提出的模型能够同时从暂态数据以及拓扑网络中挖掘到重要特征。

表 3 两种模型评估结果


Table 3 Evaluation results of two models

模型	A/%	F_1 /%	TNR/%	TPR/%
Transformer-GAT 并行特征融合	98.73	98.01	97.73	98.28
Transformer 和 GAT 串行	96.27	96.23	95.38	96.55


在电力系统中将暂态稳定误判成失稳和将暂态失稳误判成稳定的成本是不一样的, 显然后者更严重。为了可视化对比两种模型带来电力系统误判成本, 通过对一定批量的稳定和失稳样本所呈现出两种模型的混淆矩阵, 来直观对比模型的性能。如图 8 所示展示了通过使用不同模型方案的混淆矩阵二维图。通过对比可以得到 Transformer-GAT 并行特征融合提高了对稳定样本和失稳样本的误判, 对稳定样本的误判从 17 份减少到 8 份, 对失稳样本也从 13 份降低到 6 份, 说明该方案确实可以有效地减少电力系统暂态故障时的误判, 降低误判所带来的危害性。

3.2.2 不同数据驱动模型方法对比

为了验证所构建的 Transformer-GAT 并行特征融合更加具有有效性和优越性, 选取了当前基于数据



(a) 预测类别1



(b) 预测类别2

图 8 混淆矩阵

Fig. 8 Confusion matrix

驱动的电力系统暂态稳定评估的深度学习主流模型, 卷积神经网络 (convolutional neural network, CNN), 循环神经网络 (recurrent neural network, RNN)、图卷积神经网络 (graph convolutional network, GCN)、Transformer、GAT 等模型进行对比。为保证实验一致性, 所有模型采用同一份数据集。

通过训练得出不同模型收敛速度如图 9 所示。

相比于传统的 CNN、RNN、GCN、Transformer 及 GAT 模型, 提出的 Transformer-GAT 并行特征融合模型展现出显著的收敛优势。通过图 9 可知 Trans-

former-GAT 模型在第十轮左右趋于收敛,而其他模型如 GCN、RNN 等一般需要 15 ~ 20 轮后才能达到类似的收敛状态。这一结果表明,Transformer-GAT 模型通过并行融合全局依赖和局部节点重要性,大大提升了特征提取的效率,使得模型可以在更少的训练轮次中捕捉到复杂的特征。同时这一快速收敛的特性不仅提高了训练效率,也显著减少了计算资源的消耗,在实际电力系统故障诊断等需要实时响应的场景中具有重要的应用价值。

同时对 6 种模型进行横向比较,分析得出模型可视化的预测准确率如图 10 所示以及模型性能指标如表 4 所示。

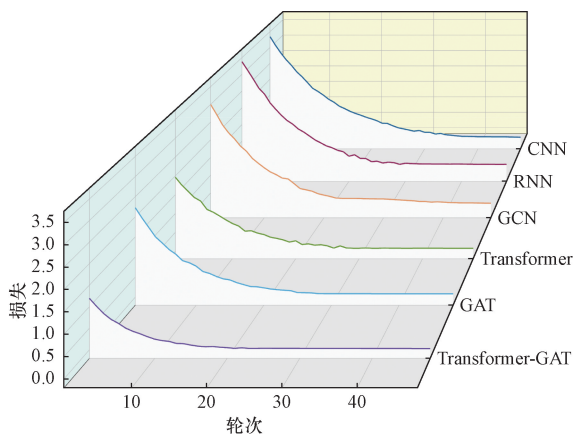


图 9 模型收敛性对比

Fig. 9 Comparison of model convergence

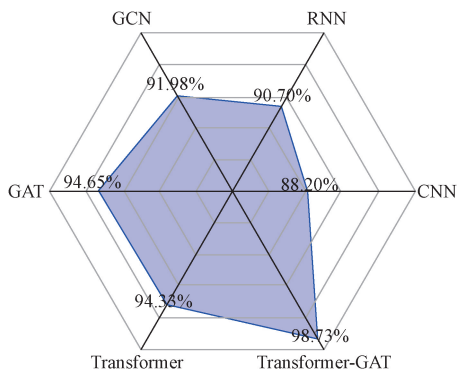


图 10 6 种模型的预测准确率

Fig. 10 Prediction accuracy of six models

表 4 模型方案评估结果

Table 4 Evaluation results of model approaches

模型	A/%	F ₁ /%	TNR/%	TPR/%
CNN	88.20	87.34	88.41	86.34
RNN	90.70	89.05	90.21	91.27
GCN	91.98	90.36	92.08	91.13
Transformer	94.33	93.69	94.32	93.97
GAT	94.65	94.95	93.14	94.13
Transformer-GAT 并行特征融合	98.73	98.01	97.73	98.28

通过对准确率的可视化分析,明显看出 GAT 并行特征融合在性能上具有显著优势。根据表 4 可知,CNN 模型的评估指标低于 90%,主要原因是 CNN 无法有效处理暂态时间序列数据。相比之下,RNN 和 GCN 虽然都能够处理序列特征,但由于 GCN 还能捕捉拓扑结构信息,模型表现略优于 RNN。而基于 Transformer 和 GAT 的单一模型,得益于强大的注意力机制,在此基础上评估指标提升了约 3%。然而,单一模型在处理特征时可能会丢失部分信息。因此,表 4 清楚地展示了 Transformer-GAT 并行特征融合能够显著提升准确率和整体模型评估指标,各项指标 Transformer 和 GAT 的单一模型提升幅度接近 4%,也验证了所构建模型相比单一模型表现出巨大优势。

3.2.3 模型性能鲁棒性研究

为进一步验证所提出模型的鲁棒性,引入暂态电压和相角的噪声数据放入训练集中,以此来评估模型的鲁棒性。实验通过引入 100 份噪声(随机选取训练集中的 100 份数据集将标签反转),然后验证模型的鲁棒性。性能指标如图 11 所示。

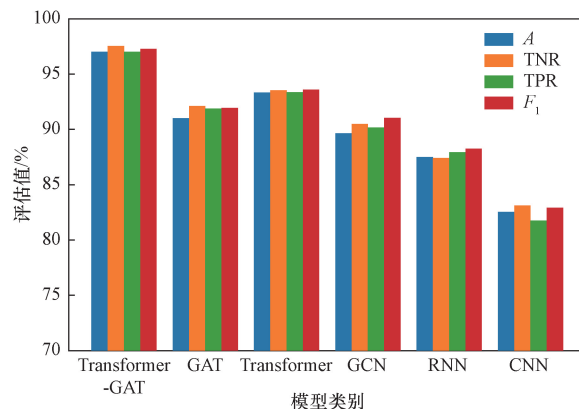


图 11 加入噪声后模型性能指标对比

Fig. 11 Comparison of model performance metrics after adding noise

所有模型在加入随机噪声后,准确率均有所下降(比未加入噪声之前的 Transformer-GAT 降低 1.7%),尤其是 CNN 准确率下降近 6%,其余几个模型也下降 3% ~ 4%,相较于其他模型,Transformer-GAT 并行模型性能下降幅度较小,模型表现出了较强的抗噪能力。这也为解决电力系统中存在的暂态虚假数据导致暂态评估准确下降的问题提供了一种方案。以上结果表明,所提出的模型在面对噪声时,表现出了较好的鲁棒性,验证了其在实际应用中的可靠性。

4 结论

提出了一种基于 Transformer-GAT 并行特征融

合的电力系统暂态稳定性评估方法,针对电力系统暂态仿真数据进行深入挖掘,旨在克服传统方法在捕捉时空特征方面的局限性,经过在典型电力系统中拟合我国暂态工况进行验证,证明了其在暂态稳定性评估中的有效性。主要结论如下。

(1)与 Transformer 和 GAT 的串行结构相比,提出的并行特征融合模型在预测准确率上表现更优。并行融合策略有效降低了对稳定样本与失稳样本的误判率,显著减小了因误判引发的潜在风险。

(2)通过与其他 5 种深度学习模型比较,本文模型展现出更快的收敛速度,能够满足电力系统实时响应的需求。相较于单独使用 Transformer 或 GAT,提出的融合模型在准确率上提升了 3% ~ 4%,对暂态稳定性的识别能力显著增强。

(3)在加入噪声的情况下,模型的并行特征融合方案仍具备较高的鲁棒性。尽管模型的准确率有所下降,但仅下降了 1.7%,相比其他模型依然展现出明显的优势。

尽管 Transformer-GAT 并行特征融合模型在电力系统暂态稳定性评估中取得了显著成果,未来仍有一些潜在的改进方向。首先,可以进一步优化特征融合机制,以更好地平衡时空信息的贡献。其次,除了 PMU 采集的暂态数据之外,模型的扩展性和适应性可通过引入多模态数据(如气象数据、市场行为数据等)加以增强。此外,在实际应用中,可以通过更多的实时监控数据对模型进行在线更新和调整,从而进一步提升评估的精度与实时性。

参 考 文 献

- [1] 中国能源网. 华中电网事故的经验与教训[EB/OL]. (2017-08-09) [2025-01-17]. <https://www.china5e.com/energy/news-334763-1.html>.
China Energy Network. Experience and lessons from the central China power grid accident[EB/OL]. (2017-08-09) [2025-01-17]. <https://www.china5e.com/energy/news-334763-1.html>.
- [2] 张智刚,康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报, 2022, 42(8): 2806-2819.
Zhang Zhigang, Kang Chongqing. Challenges and prospects of building a new power system under the carbon neutrality goal[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2819.
- [3] 朱冰,张龙,司文佳,等. 跟网型与构网型变流器混合并网的暂态特性分析及故障穿越控制[J]. 科学技术与工程, 2024, 24(28): 12177-12187.
Zhu Bing, Zhang Long, Si Wenjia, et al. Analysis of transient characteristics and fault ride-through control of hybrid grid-tied converters with grid-following and grid-forming[J]. Science Technology and Engineering, 2024, 24(28): 12177-12187.
- [4] 高剑,毕悦,杨亚兰,等. 光伏电站机电暂态实用化等值建模方法[J]. 科学技术与工程, 2022, 22(2): 556-562.
Gao Jian, Bi Yue, Yang Yalan, et al. Practical equivalent modeling method of photovoltaic power station in electromechanical transient simulation[J]. Science Technology and Engineering, 2022, 22(2): 556-562.
- [5] 戴远航,陈磊,张玮灵,等. 基于多支持向量机综合的电力系统暂态稳定评估[J]. 中国电机工程学报, 2016, 36(5): 1173-1180.
Dai Yuanhang, Chen Lei, Zhang Weiling, et al. Multi-support vector machine power system transient stability assessment based on relief algorithm[J]. Proceedings of the CSEE, 2016, 36(5): 1173-1180.
- [6] 刘炼,王强,陈浩. 基于改进随机森林的电力系统暂态稳定评估[J]. 科学技术与工程, 2022, 22(11): 4367-4374.
Liu Lian, Wang Qiang, Chen Hao. Transient stability assessment of power systems based on improved random forest[J]. Science Technology and Engineering, 2022, 22(11): 4367-4374.
- [7] 曲莹,韩肖清,刘新元,等. 基于多源数据驱动的电力系统暂态稳定性分析方法[J]. 太原理工大学学报, 2024, 55(1): 73-83.
Qu Ying, Han Xiaoqing, Liu Xinyuan, et al. Analysis method for transient stability of power systems based on multi-source data-driven approach[J]. Journal of Taiyuan University of Technology, 2024, 55(1): 73-83.
- [8] 李向伟,刘思言,高昆仑. 基于差分进化极限学习机的电力系统暂态稳定评估方法[J]. 科学技术与工程, 2020, 20(1): 213-217.
Li Xiangwei, Liu Siyan, Gao Kunlun. Power system transient stability assessment based on the differential evolution extreme learning machine[J]. Science Technology and Engineering, 2020, 20(1): 213-217.
- [9] 周芮,杨燕,余娟,等. 适应拓扑变化的数据驱动电力系统暂态主导失稳模式识别方法[J]. 中国电机工程学报, 2025, 45(9): 3436-3448.
Zhou Rui, Yang Yan, Yu Juan, et al. Data-driven method for identifying transient dominant instability patterns in power systems adapted to topological changes[J]. IEEE Transactions on Power Engineering, 2025, 45(9): 3436-3448.
- [10] 王强,陈浩,刘炼. 基于多层 CatBoost 的电力系统暂态稳定评估[J]. 科学技术与工程, 2022, 22(4): 1456-1464.
Wang Qiang, Chen Hao, Liu Lian. Research on transient stability assessment of power system based on multi-layer CatBoost[J]. Science Technology and Engineering, 2022, 22(4): 1456-1464.
- [11] 彭鑫,刘俊,刘嘉诚,等. 图像化数据驱动的电力系统暂态稳定性在线评估方法[J]. 智慧电力, 2022, 50(11): 17-24.
Peng Xin, Liu Jun, Liu Jiacheng, et al. Data-driven online assessment method for transient stability of power systems based on visualization[J]. Smart Power, 2022, 50(11): 17-24.
- [12] Cheng S, Yu Z, Liu Y, 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.
- [13] 李向伟,刘思言,高昆仑. 基于双向长短时记忆网络和卷曲神经网络的电力系统暂态稳定评估[J]. 科学技术与工程, 2020, 20(7): 2733-2739.
Li Xiangwei, Liu Siyan, Gao Kunlun. Power system transient stability assessment based on BiLSTM-ICNN[J]. Science Technology and Engineering, 2020, 20(7): 2733-2739.

- [14] Wang H, Gao F, Chen Q, et al. Instability pattern-guided model updating method for data-driven transient stability assessment[J]. IEEE Transactions on Power Systems, 2025, 40(2): 1214-1227.
- [15] Zhou J, Bu S. TSPM-CNN based power system transient stability assessment using a new data extraction method[C]//12th IET International Conference on Advances in Power System Control, Operation and Management (APSCOM 2022), Hybrid Conference. Hong Kong: Research Institute for Smart Energy, The Hong Kong Polytechnic University, 2022: 170-175.
- [16] Shao Z, Wang Q, Cao Y, et al. A novel data-driven LSTM-SAF model for power systems transient stability assessment[J]. IEEE Transactions on Industrial Informatics, 2024, 20(7): 9083-9097.
- [17] Umbreen S, Weiss X, Rolander A, et al. Investigating the performance of MLE & CNN for transient stability assessment in power systems[J]. IEEE Access, 2024, 12: 125095-125107.
- [18] 房佳姝, 刘崇茹, 苏晨博, 等. 基于自注意力 Transformer 编码器的多阶段电力系统暂态稳定评估方法[J]. 中国电机工程学报, 2023, 43(15): 5745-5759.
Fang Jiashu, Liu Chongru, Su Chenbo, et al. Multi-stage transient stability assessment method for power systems based on self-attention transformer encoder[J]. IEEE Transactions on Power Engineering, 2023, 43(15): 5745-5759.
- [19] Mahato N K, Dong J, Song C, et al. Electric power system transient stability assessment based on Bi-LSTM attention mechanism [C]//2021 6th Asia Conference on Power and Electrical Engineering (ACPEE). Chongqing: Engineering Research Center of Energy Electric Power Information Security, 2021: 777-782.
- [20] 张亮, 安军, 周毅博. 基于时间卷积和图注意力网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2023, 47(7): 114-122.
Zhang Liang, An Jun, Zhou Yibo. Transient stability assessment of power systems based on temporal convolution and graph attention networks[J]. Automation of Electric Power Systems, 2023, 47(7): 114-122.
- [21] Velikovi P, Cucurull G, Casanova A, et al. Graph attention networks[C]//6th International Conference on Learning Representations. Cambridge: University of Cambridge, 2018.
- [22] Vaswani A, Shazeer N, Parmar A, et al. Attention is all you need [J]. ArXiv, 2017: 1710.10903.
- [23] 段刚, 严亚勤, 谢晓冬, 等. 广域相量测量技术发展现状与展望[J]. 电力系统自动化, 2015, 39(1): 73-80.
Duan Gang, Yan Yaqin, Xie Xiaodong, et al. Current status and prospects of wide-area phasor measurement technology[J]. Automation of Electric Power Systems, 2015, 39(1): 73-80.
- [24] 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. Transient stability assessment of power systems based on GCN and HGP-SL[J]. Journal of Electrical Engineering, 2024, 19(4): 246-254.
- [25] 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): 2341-2350.
Wang Zhengcheng, Zhou Yanzhen, Guo Qinglai, et al. Transient stability assessment of power systems considering topological changes using message passing graph neural networks[J]. IEEE Transactions on Power Engineering, 2021, 41(7): 2341-2350.