

基于门控时空图神经网络的电力系统 暂态稳定评估

刘建锋,姚晨曦,陈乐乐

(上海电力大学电气工程学院,上海 200090)

摘要:随着特高压交直流互联规模的不断扩大,在线高精度快速地暂态稳定评估对电网安全运行至关重要。为此,提出一种基于门控时空图神经网络的暂态稳定评估方法,并采用时间自适应方法,同时提高暂态稳定评估的准确度和速度。首先,为减小故障切除后动态拓扑结构对暂态稳定评估影响,使用门控时空图神经网络提取融合电网的拓扑结构关键特征和相邻节点属性信息,学习空间数据相关性、提高评估准确度。然后,将提取的特征量输入门控神经网络以学习各个时刻数据相关性,调整稳定性阈值快速输出准确评估结果;同时,为避免模型性能受训练样本质量的影响,采用具有K最近邻思想的改进加权交叉熵损失函数处理不平衡训练样本。最后,通过分析算例,从数据可视化视图验证所提出的方法能有效提高评估准确度和缩短评估时间。

关键词:暂态稳定评估;门控时空图神经网络;门控神经网络;K最近邻;数据可视化

DOI: 10.19781/j.issn.1673-9140.2023.02.024 中图分类号: TM470 文章编号: 1673-9140(2023)02-0214-10

Power system transient stability assessment based on gating spatial temporal graph neural network

LIU Jianfeng, YAO Chenxi, CHEN Lele

(College of Electric Power Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: With the continuous expansion of UHV AC/DC interconnection scale, on-line high-precision and fast transient stability assessment (TSA) is very important for the safe operation of power grid. To this end, a TSA method based on gating spatial temporal graph neural network (GSTGNN) is proposed and the time adaptive method is used to improve the accuracy and speed of TSA at the same time. Firstly, in order to reduce the impact of dynamic topology on TSA after fault removal, GSTGNN is used to extract and fuse the key features of topology and attribute information of adjacent nodes to learn the spatial data correlation and improve the evaluation accuracy. Then, the extracted features are input into the gated recurrent unit (GRU) to learn the correlation of data at each time, and adjust the stability threshold to quickly output accurate evaluation results. Meanwhile, in order to avoid the influence of the quality of training samples, the improved weighted cross entropy loss function with K nearest neighbor (KNN) idea is used to deal with the unbalanced training samples. Through the analysis of an calculation example, it is verified from the data visualization that TSA method can effectively improve assessment accuracy and shorten assessment time.

Keywords: TSA; GSTGNN; GRU; KNN; data visualizatio

收稿日期: 2021-11-23; 修回日期: 2022-04-12

基金项目: 国家自然科学基金青年科学基金(51807114)

通信作者: 刘建锋(1968—),男,博士,副教授,主要从事光电互感器、电气信息检测研究; E-mail: bansen@sina.com

电力系统暂态稳定性是指电力系统受到大扰动后各发电机能否保持同步运行的能力。目前,随着电力消耗不断增长,系统负载达到极限传输容量事件高频发生,导致更严重的瞬态稳定性问题^[1]。因此,对扰动后瞬态稳定性的实时评估备受关注。

传统上,暂态稳定评估(transient stability assessment, TSA)通过求解一组高阶微分代数方程来建模,使用基于简化模型的直接法^[2-3]和基于轨迹模型的时域仿真法^[4]评估系统稳定性。但是在实际大型交直流混合系统上,使用直接法评估不准确,时域仿真法需要完整的电网和扰动信息,耗费大量的计算时间。

随着同步向量测量技术和高性能计算方法的创新应用,为了使用以上技术进行准确快速 TSA,基于数据驱动的 TSA 受到关注。通过提取历史暂态数据集与稳定性条件之间的关系,可以准确地确认系统由不稳定状态到稳定状态所需要的约束条件。其中浅层神经网络^[5]有较多应用,如文献[6]所提的支持向量机(support vector machine, SVM)法,适用于小规模训练样本,评估时间短,但存在人工调参主观性强和拓扑结构适应性差等问题。近年来出现了一系列适用大样本自动提取数据特征的深度学习法^[7]用于 TSA,比如递归神经网络(recursive neural network, RNN)法中长短期记忆网络(long short-term memory, LSTM)法^[8]和门控神经网络(gated recurrent unit, GRU)法^[9],依赖数据时间性进行快速地评估。但是,只考虑各节点的独立时间序列数据,忽略了具有时变性的电网拓扑结构对 TSA 具有显著影响。目前,图神经网络(graph neural networks, GNN)^[10]模型解决了拓扑结构影响问题,例如文献[11]中的图卷积神经网络(graph convolutional network, GCN)和文献[12]中的图注意力神经网络(graph attention network, GAT)等嵌入电网拓扑结构,通过输入特征进一步提取各节点之间的空间相关性信息,从而提升评估准确性。但是该方法输出所有时刻的评估结果,计算数据量较大、延长了评估时间,不利于系统稳定的恢复。

以上深度学习模型仅单一考虑数据时变性或拓扑空间变化性,在协调评估时间和准确性之间具有局限性。RNN 和 GNN 的结合模型为快速提取准确动态空间网络拓扑和时间信息提供了新的解决方案。

因此,本文基于该 2 种模型提出一种嵌入电网拓扑结构和时间序列信息的门控时空图神经网络(gating spatial temporal graph neural network, GSTGNN)框架,并采用自适应方法^[13],同时提高评估准确度和速度。相比于 GAT 模型平均使用多个注意力头,本文采用 GSTGNN 模型给与评估结果相关性高的注意力头增加权重,以充分提取节点间拓扑信息,提高 TSA 准确度;同时,大规模电网紧急控制中心对 TSA 时间要求一般不超过 0.04 s^[14]。一般常规模型是聚合所有固定时刻数据进行 TSA,因此,提出自适应性 TSA 方法,使用 GRU 模型聚合较少时刻数据,快速得到准确的评估结果。除此之外,针对样本质量对评估结果的不利影响,采用 K 近邻(K-nearest neighbor, KNN)法^[15]的改进加权交叉熵损失函数改善评估性能。与多种 TSA 模型性能对比,本文模型能更准确地提取节点采样信息,可以快速有效地评估 AC/DC 的异构多源网络的瞬态稳定性。

1 门控时空图神经网络

1.1 图神经网络和注意力机制

图神经网络使用 $G(x, A)$ 矩阵描述电力系统网络的拓扑关系, x 表示采集的电网信息特征向量, A 表示拓扑结构的邻接矩阵。图神经网络在电力系统中的应用是对包含拓扑关系的 $G(x, A)$ 进行信息聚合,聚合节点自身和邻居特征训练生成包含原始信息以及拓扑信息的新特征 $G(\tilde{x}, A)$, 与输出结果相关性更高,其中, \tilde{x} 表示与评估结果相关性更高的新特征向量。图神经网络算法过程如图 1 所示。

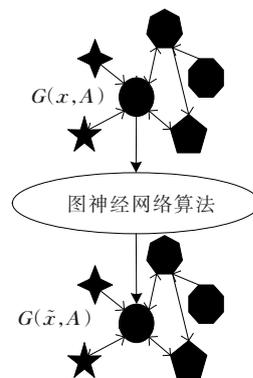


图 1 图神经网络算法过程

Figure 1 Graph neural network algorithm process

引入注意力机制对邻近节点特征加权求和,其权重完全取决于节点特征,不受动态拓扑结构影响。模型中每个节点代表电网拓扑结构中的发用电节点,图注意力层的输入是节点特征向量集 \mathbf{x} , $\mathbf{x}=(x_1, x_2, \dots, x_N)^T$, $x_i \in \mathbf{R}^F$, x_i 为节点 i 的特征向量, N 为系统节点个数, F 为节点的原特征数。每一层的输出是一个新的节点特征向量集 $\tilde{\mathbf{x}}$, $\tilde{\mathbf{x}}=(\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_N)^T$, $\tilde{x}_i \in \mathbf{R}^{F'}$, F' 为节点的新特征数。针对 N 个节点,按照其输入节点特征预测输出新节点特征。

为得到 $G(\tilde{\mathbf{x}}, A)$,需要计算注意力系数 a_{ij} ,其算式如下:

$$a_{ij} = \frac{\exp(\eta(\beta \cos(\mathbf{W}x_i, \mathbf{W}x_j)))}{\sum_{k \in N_i} \exp(\eta(\beta \cos(\mathbf{W}x_i, \mathbf{W}x_k)))} \quad (1)$$

式中, \mathbf{W} 为初始化矩阵; β 为训练参数; $\cos(\mathbf{W}x_i, \mathbf{W}x_j)$ 为余弦相似度, η 为LeakyReLU非线性激活函数。

a_{ij} 经由邻接矩阵 \mathbf{A} 确定新注意力系数:

$$\tilde{a}_{ij} = \begin{cases} a_{ij}, & A_{ij} = 1 \\ 0, & A_{ij} = 0 \end{cases} \quad (2)$$

每次训练时产生不同的 \tilde{a}_{ij} 。因此,本文提出一种采用新注意力头机制的网络结构,为包含拓扑信息重要注意力头设置权重,即0~1,使模型能够关注到重要注意力头的节点信息,从而提高模型解释性。

对于含有 k 个注意力头数目的一个GAT层,每个注意力头含有不同的一组参数 \mathbf{W} 和 a_{ij} 。具体特征提取过程如图2所示, m_i^k 表示第 k 个注意力头权重,节点1在其邻域上有3个注意力头,不同的箭头样式和灰度表示独立的注意力头,不同的软门聚合每个头的特征,控制得到相关性更高的特征向量。

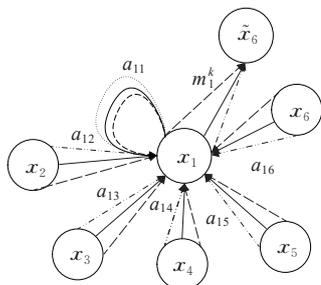


图2 特征提取过程

Figure 2 Feature extraction process

针对节点 i 使用最大池和平均池构建网络,计算其注意力头权重 m_i ,表达式为

$$m_i = [m_i^{(1)}, m_i^{(2)}, \dots, m_i^{(k)}] = \frac{\sum_{j \in N_i} x_j}{|N_i|} \quad (3)$$

式中, $m_i^{(k)}$ 为第 i 个节点第 k 个注意力头权重。

节点 i 聚合注意力头拓扑信息的输出新特征:

$$\tilde{x}_i = \prod_{k=1}^K m_i^{(k)} \sigma \left(\sum_{j \in N_i} \tilde{a}_{ij} \mathbf{W}^k x_j \right) \quad (4)$$

式中, \tilde{x}_i 为经过GSTGNN层后节点 i 包含不同空间相邻节点特征信息的输出新特征;注意力头 $k \geq 2$; σ 为GELUs激活函数^[16]。

为防止模型过拟合,引入随机正则思想控制训练集上的性能,GELUs表达式为

$$f_{\text{GELUs}}(x) = x\phi(x) =$$

$$0.5x \left\{ 1 + \tanh \left[\sqrt{2/\pi} (x + 0.044715x^3) \right] \right\} \quad (5)$$

式中, $\phi(x)$ 采用 $N(0, 1)$ 正态分布,当 x 减小时,输出值就会依据概率随机依赖于输入值,提高模型泛化能力。

1.2 门控神经网络

GSTGNN模型提取电网拓扑信息,提高评估准确度,但是未考虑评估时间。本文研究对象是高维度动态系统,各个节点除了具有电网拓扑信息外,其物理量还具有时序特性。GRU网络具有遗忘和选择记忆特性,学习和保留输入数据的时序特征以供在之后时刻中使用。在暂态评估中,可以由故障状态推出故障切除后稳定性。因此,加入GRU层,捕获节点历史序列和当前时刻信息,预测未来时刻稳定性,无需输入所有时刻数据量,缩短评估时间。

综上,为处理具有复杂拓扑结构和时间相关性的序列信息,GSTGNN和GRU组合成门控时空图神经网络框架,得到聚合的特征与稳定评估结果的非线性映射关系。在每一时刻,输入 x_t 和隐藏状态 h_{t-1} 都通过GSTGNN层,得到带有拓扑信息的新特征 $\tilde{x}_t, \tilde{h}_{t-1}$,其表达式为

$$\begin{cases} \tilde{x}_t = G(x_t, A) \\ \tilde{h}_{t-1} = G(h_{t-1}, A) \end{cases} \quad (6)$$

由 $\tilde{h}_{t-1}, \tilde{x}_t$ 得到控制更新门 z_t 和控制重置门 r_t ,

其计算过程为

$$\begin{cases} z_t = \alpha(\mathbf{W}_z \tilde{\mathbf{x}}_t[i, :] + b_z) \\ r_t = \alpha(\mathbf{W}_r \tilde{\mathbf{x}}_t[i, :] + \mathbf{U}_r \tilde{\mathbf{h}}_{t-1}[i, :] + b_r) \end{cases} \quad (7)$$

式中, α 为 sigmoid 激活函数, 范围为 $[0, 1]$ 。

当前时间步的记忆状态 $\mathbf{h}_t[i, :]$ 由以下公式获得, 需要 z_t 同时进行遗忘和选择记忆信息, 即

$$\begin{cases} \hat{\mathbf{h}}_t[i, :] = \tanh(\mathbf{W}_h \tilde{\mathbf{x}}_t[i, :] + \mathbf{U}_h \cdot \\ \quad (\mathbf{r}_t \odot \mathbf{U}_h \tilde{\mathbf{h}}_{t-1}[i, :] + b_h) \\ \mathbf{h}_t[i, :] = (1 - z_t) \odot \tilde{\mathbf{h}}_{t-1}[i, :] + z_t \odot \hat{\mathbf{h}}_t[i, :] \end{cases} \quad (8)$$

式中, \odot 为 Hadamard Product, 确定所要保留与遗忘的以前信息; $\hat{\mathbf{h}}_t[i, :]$ 为通过重置所记忆之前时刻的状态; $1 - z_t$ 表示清除不重要信息, z_t 表示遗忘过去状态信息, 并加入当前节点输入的某些状态信息。

最后时刻的记忆状态 $\mathbf{h}_{\text{last}}[i, :]$ 输入至 softmax 激活函数, 分类得到最后时刻的输出评估值 \tilde{y} , 取值范围为 $[0, 1]$, 即

$$\tilde{y} = \text{softmax}(\mathbf{W}_o \mathbf{h}_{\text{last}}[i, :] + b_o) \quad (9)$$

式中, \mathbf{W}_o, b_o 为通过梯度反向传播所学习的评估模型参数。

2 自适应暂态稳定评估

2.1 原理

为了故障切除后可以立刻启动紧急控制, 需要快速、准确地进行 TSA。在文献[7-8]中, 大多数现有的 TSA 方法利用固定长度的观察窗口, 评估时间是恒定的。但是, 此静态评估时间无法应对快速瞬态不稳定的情况, 而且不同故障程度的系统模型需要不同的观察窗口长度。故障切除后为评估系统未来时间窗口中的稳定性, 逐步调整观察时间窗口, 只要评估系统在未来失去稳定性, 即可立刻启动紧急控制。

2.2 离线训练

2.2.1 生成数据集

评估模型具有特征提取能力, 旨在从采样数据中获取评估结果, 输入数据需要全面反映系统的动态行为。本文主要研究故障切除后电力系统暂态稳定性, 选择反映系统动态的初始特征构建 TSA 的输入特征, 包括所有总线上各个节点的电压幅值、相角、注入有功功率和注入无功功率^[17]。

在 50 Hz 频率下采样, 为了模拟各种故障切除后的系统响应, 仿真不同的预想事故以生成整个数据集, 输入 \mathbf{x} 用时间形式表示:

$$\mathbf{x} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T)^T = \begin{pmatrix} \begin{pmatrix} \mathbf{u}_{1,1} & \dots & \mathbf{u}_{T,1} \\ \vdots & \mathbf{u}_{t,n} & \vdots \\ \mathbf{u}_{1,N+1} & \dots & \mathbf{u}_{T,N+1} \end{pmatrix}^T, \begin{pmatrix} \delta_{1,1} & \dots & \delta_{T,1} \\ \vdots & \delta_{t,n} & \vdots \\ \delta_{1,N+1} & \dots & \delta_{T,N+1} \end{pmatrix}^T, \\ \begin{pmatrix} \mathbf{p}_{1,1} & \dots & \mathbf{p}_{T,1} \\ \vdots & \mathbf{p}_{t,n} & \vdots \\ \mathbf{p}_{1,N+1} & \dots & \mathbf{p}_{T,N+1} \end{pmatrix}^T, \begin{pmatrix} \mathbf{q}_{1,1} & \dots & \mathbf{q}_{T,1} \\ \vdots & \mathbf{q}_{t,n} & \vdots \\ \mathbf{q}_{1,N+1} & \dots & \mathbf{q}_{T,N+1} \end{pmatrix}^T \end{pmatrix}^T \quad (10)$$

式中, $\mathbf{u}_{t,n}, \delta_{t,n}, \mathbf{p}_{t,n}, \mathbf{q}_{t,n}$ 分别为节点电压幅值、相角、有功和无功功率; 下标 T 为观察时间窗口, 影响 GRU 评估准确度与复杂度; N 为节点数, 由电网拓扑结构决定。

使用故障切除后功角暂态稳定指标 (transient stability index, TSI) t 判断样本稳定性, 表达式为

$$y_i = \begin{cases} 1(\text{稳定}), & t > 0, \\ 0(\text{不稳定}), & t \leq 0, \end{cases} \quad i = 1, 2, \dots, T \quad (11)$$

式中, $t = (180 - \delta_{\text{max}}) / (180 + \delta_{\text{max}})$, δ_{max} 为仿真结束时任意 2 台同步发电机的最大功角差, 确定系统中是否有任何发电机不同步; y_i 为真实类别的标签^[18], 建立完备的数据集。

2.2.2 改进的加权交叉熵损失函数

在现实大电网中, 稳定样本数量远大于失稳样本数量, 即“不平衡”, 一些比较重要的不稳定系统可能会被误判成稳定。因此, 引入 KNN 法统计数据并比较 2 类样本数量空间分布的不平衡信息。

首先, 使用 KNN 法计算每个样本与相反类别样本之间的距离, 即样本的参考位置; 然后, 通过参考位置划分区域, 得到一系列位置区域的不稳定与稳定数据数量, 即样本的空间分布。设定总体分为 a 个区域, 权重表达式为

$$\begin{cases} \omega_{A_i} = \frac{F_{B_i}}{F_{A_i} + F_{B_i}} \\ \omega_{B_i} = \frac{F_{A_i}}{F_{A_i} + F_{B_i}} \end{cases} \quad (12)$$

其中, F_{A_i}, F_{B_i} 分别为第 i 个区域上的失稳、稳定样本数量; $\omega_{A_i}, \omega_{B_i}$ 分别为样本第 i 个区域上失稳、稳定权重, $i = 1, 2, \dots, a$ 。

然后,采用改进加权交叉熵损失函数,提高失稳情况误判的代价,表达式为

$$L = -\frac{1}{N} \sum_{j=1}^N (\omega_{A_i} y_j \log(\tilde{y}_j) + \omega_{B_i} (1 - y_j) \log(1 - \tilde{y}_j)) \quad (13)$$

式中, N 为单次训练样本的数量; y_j 为真实类别的标签; \tilde{y}_j 为评估类别的概率。

离线训练目的是在保证损失函数 L 最小的情况下,使用adam优化器训练模型得到最优 w 和 b ,减少不平衡样本的不利影响,提高评估准确度。

2.3 在线评估

采用稳定性阈值对评估结果进行评估,由于,本文使用了GRU层,因此, \tilde{y}_i 仅关注在 T 时刻生成的稳定性指标,当 $i=1,2,\dots,7$ 时, $T-1$ 值忽略不计,其规则为

$$\text{稳定性} = \begin{cases} \text{稳定, } 1 \geq \tilde{y}_i > \delta, \\ \text{不稳定, } y_i < 1 - \delta, i = 1, 2, \dots, T \\ \text{未知, 其他,} \end{cases} \quad (14)$$

其中, $\delta \in (0.5, 1.0)$ 为稳定性阈值,搜索合适的 δ ,平衡TSA准确度与平均评估时间,自适应性TSA流程如图3所示。

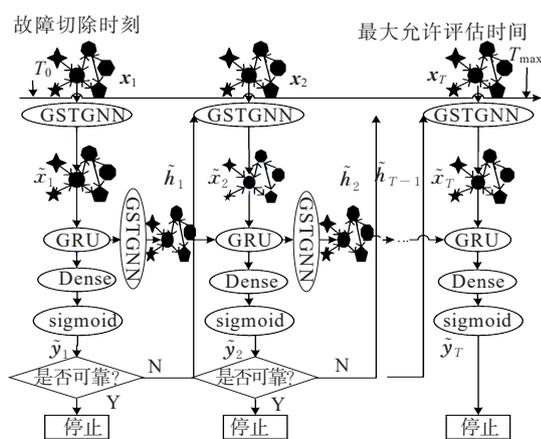


图3 自适应性暂态稳定评估过程

Figure 3 Adaptive transient stability assessment process

本文根据故障切除后的观察时间窗口向模型输入 x_i ,逐时刻评估系统稳定性。当在判定范围内时,直接输出结果,否则,将这一时刻隐藏状态 h_i 和下一时刻 x_{i+1} 输入到下一个神经元;如果评估时间超出观察时间窗口,则采取滑动时间窗口方式评估,直到输出可靠的评估结果 \tilde{y}_i 或达到最大允许评

估时间 T_{\max} ;若达到 T_{\max} 还未判定就被视为不稳定。在此过程中 h_i, x_{i+1} 经过GSTGNN层得到带有拓扑关系的 h_i, x_{i+1} ,共同输入到下一评估时刻。通过实验发现 T_{\max} 一般设置为10个周期。

2.4 总评估过程

总评估流程如图4所示,具体步骤如下。

1) 离线训练。本文在不同线路的不同故障点下,设置三相永久性短路故障,实现样本数据多样性。由时域仿真法生成数据,包括各个节点的电压幅值、相角、注入有功功率、注入无功功率和仿真结束时最大功角差 δ_{\max} ,再由 δ_{\max} 得到稳定性指标 t ,当 $t > 0$ 时,表示系统暂态稳定,标签为“1”;反之,系统不稳定,标签为“0”。本文选取总线上各个节点动态数据作为输入数据来判定系统稳定性,一般将输入数据进行归一化处理,获得一定范围内训练数据和测试数据,减小数据间的差异度。由训练数据得到失稳和稳定情况下的权重,形成加权交叉熵损失函数,以构成训练损失函数;不断调整模型参数,采用adam法使损失函数最小,直到获得最优评估模型。

2) 在线评估。使用所训练的最优评估模型评估测试数据,得到系统稳定性。

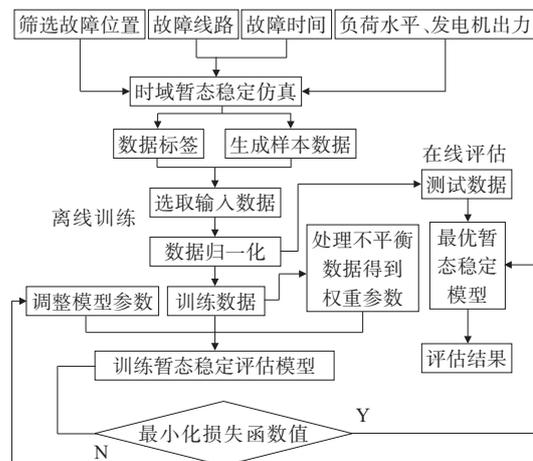


图4 总评估流程

Figure 4 General evaluation flow chart

3 算例

3.1 样本数据集的生成

本文采用具有代表性的新英格兰10机39节点电力系统,如图5所示,基准频率为50 Hz,使用时域

仿真软件 PSA-BPA 模拟 PMU 采集数据,并使用 Python 编程。

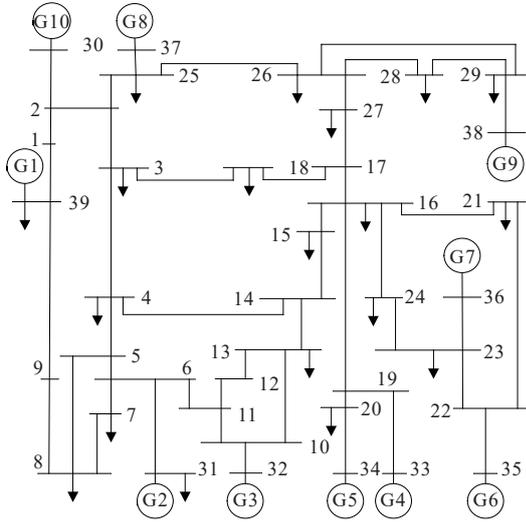


图 5 新英格兰 10 机 39 节点电力系统

Figure 5 New England 10-machine 39-bus power system

采样步长设为 0.02 s,在各种场景下模拟各种故障得到完备数据集。设定 75%~125% (步长 5%) 的 11 种负载水平,并相应地改变发电机出力,保证潮流收敛;设置三相永久性短路故障,线路的 0%、25%、50%、75% 以及 100% 处设置故障点,故障切除时间设置为 0.2 s,仿真时长为 5 s。当电网拓扑结构变化时,考虑全接线系统和 N-1 意外情况,在 $46 \times 11 \times 5 + C_{46}^2 \times 11 \times 5 = 8\,855$ 个故障样本中,随机抽取 6 000 个训练集样本,并按照 4:1 抽取测试集,包括 5 211 个稳定样本和 2 289 个不稳定样本。

在测试中,基于采样步长,自适应性 TSA 方法的每个评估周期为 0.02 s,最大评估时间设为 0.2 s ($T_{\max}=10$);观察窗口 T 、稳定性阈值 δ 分别设置为 8、0.62。

3.2 处理不平衡数据

在暂态稳定评估中,可采用准确率(accuracy,简称为 ACC)作为评价指标,即正确评估数目占总评估数目的比例。本文引入 KNN 法计算每个样本的权重,加入到损失函数训练参数中,分别以有、无不平衡处理的 6 000 个样本作为训练数据,迭代次数为 300。当 $T=8$ 、 $\delta=0.62$ 时,训练过程如图 6 所示。故障发生后随着迭代次数增大 ACC 迅速提高,直到迭代次数为 50 次时 ACC 趋于平缓增大。最终,有平衡处理的评估 ACC 可达到 99.237%。由此可知,数据质量对训练高性能模型具有重要影响。

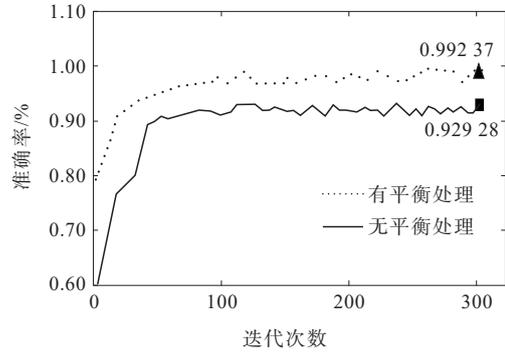


图 6 迭代次数与准确率关系

Figure 6 Relationship between iteration times and accuracy

3.3 TSA 性能对比

随着机器学习的不断发展,为解决分类问题,基于混淆矩阵(如表 1 所示)的指标比仅使用 ACC 能更好地评估分类模型的适用性。在电力系统暂态稳定分析中,研究者更关注失稳情况是否分类正确,其评判指标以能否正确判断出失稳情况为主。在表 1 中, P_T 为稳定样本被正确评估的数目; P_F 为不稳定样本被错误评估的数目; N_F 为稳定样本被错误评估的数目; N_T 为不稳定样本被正确评估的数目。通过计算失稳准确率、误判率(recall)、精确度(precision)以及综合评价指标(F_1)予以评估模型性能。

表 1 暂态稳定评估混淆矩阵

Table 1 Confusion matrix for transient stability assessment

评估性质	评估数量	
	真实稳定	真实不稳定
稳定	真正类(P_T)	假负类(P_F)
不稳定	假正类(N_F)	真负类(N_T)

准确率表达式为

$$A_{cc} = \frac{P_T + N_T}{P_T + N_T + P_F + N_F} \times 100\% \quad (15)$$

误判率为不稳定样本中被正确评估的比例,表达式为

$$R_{ec} = \frac{N_T}{N_T + P_F} \quad (16)$$

精确度为评估不稳定样本中被正确评估的比例,表达式为

$$P_{re} = \frac{N_T}{N_T + N_F} \quad (17)$$

F_1 为 P_{re} 和 R_{ec} 加权调和平均值,同时综合考虑 2 个性能指标,表达式为

$$F_1 = \frac{2P_{re} \cdot R_{ec}}{P_{re} + R_{ec}} \quad (18)$$

F_1 在 $[0,1]$ 之间分布,越接近1,模型提取特征能力越强,评估性能越好。准确度主要包含 A_{cc} 和 F_1 ,虽然本文研究的深度学习算法在理论上可以达到1(或者100%),但是会导致模型过拟合,进而使数据模型没有足够的预测能力。所以,本文引入随机正则思想,在满足预测要求情况下尽可能接近100%。

对同样一组数据,使用本文方法与其他深度学习模型在评估准确度方面进行比较,性能有所提高。如表2所示,属于浅层神经网络的SVM模型的 R_{ec} 小于0.9,不能较准确地提取特征,容易误判。GAT、LSTM和GRU模型都有较高的准确率,但当系统拓扑规模扩大时,GAT模型的 F_1 比LSTM和GRU模型高,表明节点间拓扑关系对于TSA的重要性。由于CNN模型忽略电网拓扑结构和时间序列信息,因此,准确率较低。本文所建立框架的 A_{cc} 更接近于100%, F_1 也更接近于1,对高维数据依然有强大的泛化性能,稳定性更强、准确度更高,总体性能优于GAT-GRU、GAT、SVM、GRU、LSTM和CNN模型。此框架较好地挖掘了数据的本质特征,并且训练参数共享,克服了传统自适应性评估系统构建复杂的问题。

表2 TSA性能对比

Table 2 TSA performance comparison

模型	$A_{cc}/\%$	R_{ec}	P_{re}	F_1
本文	99.82	0.998	0.995	0.996
GAT-GRU	99.02	0.983	0.989	0.988
GAT	98.26	0.987	0.988	0.987
SVM	93.06	0.897	0.990	0.941
GRU	97.80	0.949	0.986	0.967
LSTM	97.51	0.947	0.991	0.969
GNN	92.23	0.945	0.993	0.968

3.4 平均评估时间和训练时间

除评估ACC外,平均评估时间(average response time, ART)也是评估模型性能的重要指标,即故障切除后平均TSA时间,其表达式为

$$A_{RT} = \frac{\sum_{i=1}^{T_{max}} [T_i \cdot C(T_i)]}{\sum_{i=1}^{T_{max}} C(T_i)} \quad (19)$$

式中, T_{max} 为最大允许评估时间(10个周期); $C(T_i)$ 为当前评估周期中已评估的实例总数。

ART和训练时间对比如表3所示,GRU和LSTM模型的ART基本相同^[19],GRU比LSTM模型参数少、训练时间相对短。极限学习机(extreme learning machine, ELM)^[20]网络训练10个参数不共享的分类器,训练时间最长;简单SVM网络结构的ART最长。本文模型提取重要注意力头的拓扑关系和时间序列信息,特征提取能力高于仅平均提取注意力头的拓扑关系的GAT-GRU模型,TSA速度更快。在保证高ACC情况下,本文模型的ART最短,即1.010周波(0.020 2 s),满足紧急控制的要求。同时,虽然本文和GAT-GRU模型的层数较多,离线训练时间都长于GRU和LSTM模型,但是不影响在线评估效果,故此模型仍具有实用性。

表3 ART和训练时间对比

Table 3 Comparison chart of ART and training time

模型	$A_{RT}/\text{周波}$	训练时间/s
本文	1.010	95.3
GAT-GRU	1.360	84.6
LSTM	1.672	41.5
GRU	1.555	32.7
ELM	2.111	156.2
SVM	4.000	20.2

3.5 观察时间窗口和稳定性阈值测试

参数 T 和 δ 影响评估模型性能, T 与ACC、ART的关系分别如图7、8所示, $T=8$ 意味着当故障清除后,可以使用前8个周期的输入数据进行训练以及连续时间序列数据进行测试,ACC达到最大值约为99.27%。

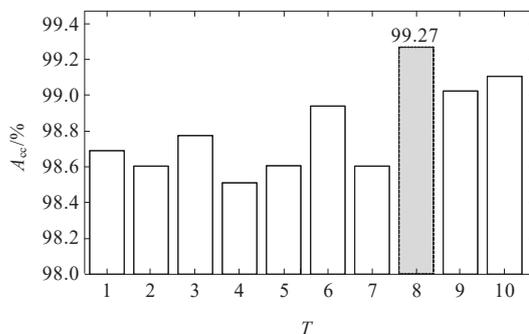


图7 T与ACC的关系

Figure 7 The relation between T and ACC

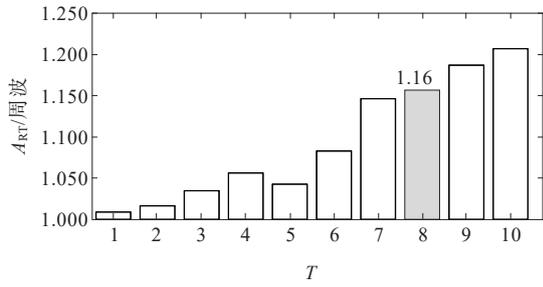


图 8 T 与 ART 的关系

Figure 8 The relation between T and ART

不同 T 具有不同的 ACC, 表明输入数据的数量影响评估性能。随着 T 的不断增大, ACC 总体趋势有所增加(虽然存在小幅度的波动, 但 TSA 时间变长)。短 T 会损害输入数据的完整性, 降低 ACC。因此, 在 T 尽可能小的情况下保证高精度, $T=8$ 时是最佳选择。

当选取 $T=8$ 时, δ 与 ACC、ART 的关系如图 9、10 所示。与观察时间窗口一样, δ 的大小影响 ACC、ART, 更大 δ 导致在早期得到评估结果, 但 ACC 降低, 而较小 δ 在牺牲评估速度的情况下, 评估结果更准确。随着 δ 不断增大, ACC 不断减小, 而 ART 却不断增大。较小 ART 和高 ACC 都是模型评估性能的期望值, 所以, δ 设置为 0.62。

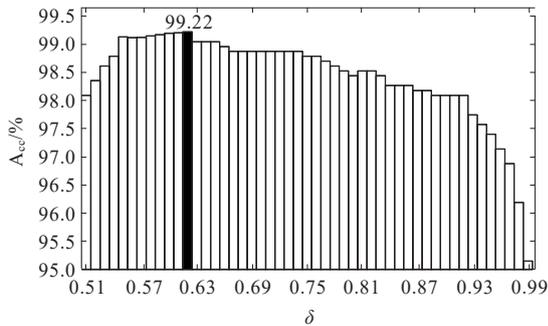


图 9 delta 与 ACC 的关系

Figure 9 The relation between delta and ACC

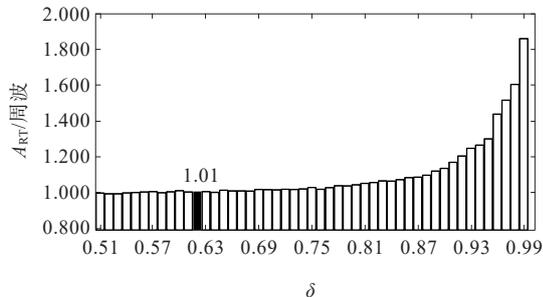


图 10 delta 与 ART 的关系

Figure 10 The relation between delta and ART

综上, $T=8, \delta=0.62$ 时可以获得最短评估时间和高准确率。

3.6 数据可视化

对评估模型所提取的特征向量进行数据可视化 (t-distributed stochastic neighbor embedding, t-SNE) 处理, 验证本文所训练的深层框架具有优秀的特征提取性能, 有利于直观验证算法的有效性, GSTGNN 模型的输入层、GRU 层和全连接层的特征如图 11 所示, “0” 为不稳定样本, “1” 为稳定样本。

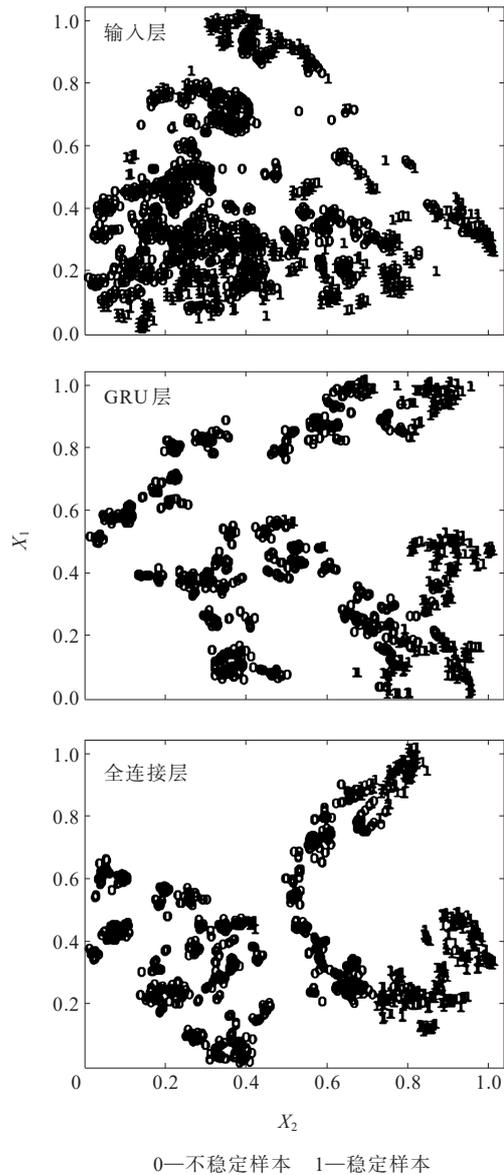


图 11 输入层、GRU 层以及全连接层的特征

Figure 11 Characteristics of input layer, GRU layer and full connection layer

利用t-SNE建立线性投影,得到近似高维数据空间和低维嵌入空间之间的映射关系。将高维输入数据映射到二维空间上,对稳定性分类做出直观解释。起初2类样本混合,随着特征层的加深,在新特征空间表现出明显的不同特性,其分界线越来越明显,空间重叠数据越来越少。GSTGNN模型的深层结构层次提取作用明显,最终达到明显的分类效果。

4 结语

本文提出一种基于GSTGNN的电力系统自适应性TSA方法,提取电气量数据空间和时间相关性以平衡评估准确度与评估时间。采用新英格兰10机39节点系统进行验证,并与多种验证算法进行对比测试,分析表明如下。

1) 本文引入图神经网络,考虑节点间的拓扑关系,同时提出了一种具有新注意力头机制,考虑来自重要注意力头的相邻节点特征相关性。在聚合过程中,节点新特征随拓扑和注意力系数动态变化,因此,模型具有高维度特征提取能力、高评估准确度,并适用于不断变化的复杂电网结构。

2) 本文使用自适应性TSA,考虑节点各个时刻数据的时间相关性,采用GRU层逐个捕获输入数据的特征量,在早期提取动态数据所映射的系统稳定性特征,缩短评估时间。

3) 除了TSA性能和评估时间测试外,引入2个基本参数即稳定性阈值和训练观察窗口长度进行初步敏感性测试。仿真结果表明:参数配置具有良好的性能,能够促进评估性能的提升。

综上,GSTGNN框架专门用于处理具有动态拓扑结构和时间相关性的电气量数据,在不牺牲评估准确度的情况下缩短评估时间,适用于更复杂的大规模电网结构。但是,实际噪声干扰会对评估结果准确度产生影响,这是今后需要考虑的问题。

参考文献:

- [1] 江琴,刘天琪,曾雪洋,等.大规模风电与直流综合作用对送端系统暂态稳定影响机理[J].电网技术,2018,42(7):2038-2046.
- [2] 康卓然,张谦,陈民权,等.适用于电力系统暂态稳定分析的网络电压解析算法研究[J].电力系统保护与控制,2021,49(3):32-38.
- [3] 杨力森,何一帆.辛几何算法在电力系统暂态稳定性分析中的应用[J].电力科学与技术学报,2009,24(2):80-83+88.
- [4] 徐艳春,蒋伟俊,孙思涵,等.含高渗透率风电的配电网暂态电压量化评估方法[J].中国电力,2022,55(7):152-162.
- [5] 汤奕,崔晗,李峰,等.人工智能在电力系统暂态问题中的应用综述[J].中国电机工程学报,2019,39(1):2-13+315.
- [6] 张晓英,史冬雪,张璁,等.基于CPSO-BP神经网络的风电并网暂态电压稳定评估[J].智慧电力,2021,49(10):38-44.
- [7] 谢施君,雷汉坤,王乃会,等.基于BP神经网络的CVT暂态电压传递特性补偿技术[J].高压电器,2022,58(2):149-157.

- XIE Shijun, LEI Hankun, WANG Naihui, et al. Compensation technology on transient voltage transfer characteristics of CVT based on BP neural network[J]. High Voltage Apparatus, 2022, 58(2): 149-157.
- [8] 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.
- [9] YU H Z, YU D Y. Transient stability assessment using gated recurrent unit[C]//5th Asia Conference on Power and Electrical Engineering (ACPEE), Chengdu, China, 2020.
- [10] FRANCO S, MARCO G, TSOI A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.
- [11] LING Z, YU J S, CHAO Z, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.
- [12] 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.
- [13] 潘晓杰,徐友平,朱成亮,等.基于深度学习的多输入特征融合的暂态电压稳定性评估方法[J].电网与清洁能源,2021,37(2):79-84.
- PAN Xiaojie, XU Youping, ZHU Chengliang, et al. Transient voltage stability evaluation method based on multi-input feature fusion of deep learning[J]. Power System and Clean Energy, 2021, 37(2): 79-84.
- [14] 王长江,姜涛,陈厚合,等.基于相位校正李雅普诺夫指数的电力系统暂态电压稳定评估[J].电工技术学报,2021,36(15):3221-3236.
- WANG Changjiang, JIANG Tao, CHEN Houhe, et al. Transient voltage stability assessment of power systems based on phase correction maximum Lyapunov exponent [J]. Transactions of China Electrotechnical Society, 2021, 36(15): 3221-3236.
- [15] WANG H Y, YE W T. Transient stability evaluation model based on SSDAE with imbalanced correction[J]. IET Generation, Transmission & Distribution, 2020, 44(11): 2209-2216.
- [16] DAN H, KEVIN G. Gaussian error linear unit[DB/OL]. <https://arxiv.org/abs/1606.08415>, 2020-07-08.
- [17] 李森,雷鸣,周挺,等.基于深度森林的电力系统暂态稳定评估方法[J].电测与仪表,2021,58(2):53-58.
- LI Miao, LEI Ming, ZHOU Ting, et al. Transient stability assessment method for power system based on deep forest [J]. Electrical Measurement & Instrumentation, 2021, 58(2): 53-58.
- [18] 谢培元,袁文,刘永刚,等.基于主动学习的电力系统暂态稳定评估方法[J].电测与仪表,2021,58(5):86-91.
- XIE Peiyuan, YUAN Wen, LIU Yonggang, et al. Transient stability assessment method in power system based on active learning[J]. Electrical Measurement & Instrumentation, 2021, 58(5): 86-91.
- [19] YU J J Q, HILL D J, LAM A Y S, et al. Intelligent time-adaptive transient stability assessment system[J]. IEEE Transactions on Power Systems, 2018, 33(1): 1049-1058.
- [20] ZHANG Y C, XU Y, REN C, et al. Post-disturbance transient stability assessment of power systems by a self-adaptive intelligent system[J]. IET Generation Transmission & Distribution, 2015, 9(3): 296-305.