

DOI:10.3969/j.issn.2097-0706.2023.07.006

基于多STA-GLN集成模型的电力系统暂态稳定评估方法

Power system transient stability assessment method based on multiple STA-GLN ensemble models

杨波^{1,2}, 李成雲^{1,2}, 吕浩轩³, 周博文^{1,2}, 李广地^{1,2}, 谷鹏^{1,2}

YANG Bo^{1,2}, LI Chengyun^{1,2}, LYU Haoxuan³, ZHOU Bowen^{1,2}, LI Guangdi^{1,2}, GU Peng^{1,2}

(1. 东北大学 信息科学与工程学院, 沈阳 110819; 2. 辽宁省综合能源优化与安全运行重点实验室 (东北大学), 沈阳 110819; 3. 国网辽宁省电力有限公司铁岭供电公司, 辽宁 铁岭 112099)

(1. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China; 2. Key Laboratory of Integrated Energy Optimization and Secure Operation of Liaoning Province (Northeastern University), Shenyang 110819, China; 3. Tieling Power Supply Company, State Grid Liaoning Electric Power Supply Company Limited, Tieling 112099, China)

摘要: 随着高比例可再生能源的不断接入和电力电子化程度的提高, 电力系统结构日益复杂, 导致电力系统稳定性受威胁。针对基于人工智能的暂态稳定评估(TSA)方法存在的拓扑适应能力差、失稳样本学习困难和模型训练耗时长等缺陷, 提出了基于图形卷积和长短时记忆组合网络的空间和时间双注意力机制(STA-GLN)集成电力系统TSA方法。搭建了电力系统仿真模型, 在全接线、N-1断线和N-2断线3种拓扑结构下设置不同线路故障, 获取原始样本集, 基于STA-GLN的TSA方法对系统拓扑变化表现出更强的适应性和评估准确性; 构建了基于自适应增强(AdaBoost)算法和迁移学习的集成STA-GLN多任务TSA模型, 解决了失稳误判问题并加快了模型的响应速度。最后通过新英格兰10机39节点系统仿真分析验证了该方法的有效性。

关键词: 电力系统; 可再生能源; 暂态稳定评估; 人工智能; 集成学习; 迁移学习; 多任务模型; 电力电子化

中图分类号: TK 01 **文献标志码:** A **文章编号:** 2097-0706(2023)07-0048-13

Abstract: With the continuous access of high-proportion renewable energy to the power grid and advancing of power electrification, power systems are becoming increasingly complex in structure, which threatens of systems' stability. To address the poor topology adaptability, difficulty in learning instability samples, and long model training time of the transient stability assessment (TSA) method based on artificial intelligence (AI), an ensemble TSA method based on Spatial-Temporal Attention Mechanism, Graph Convolution and Long Short-Term Memory Network (STA-GLN) is proposed. A power system simulation model is built, in which different line faults are set under three topologies, full connection, N-1 disconnection and N-2 disconnection, and the original sample sets are obtained. The TSA method based on STA-GLN shows stronger adaptability and accuracy to the variation of the system's topologies. Then, Adaptive Boosting (AdaBoost) and transfer learning are integrated into the multi-task TSA model based on STA-GLN, which reduces the false judgment and accelerates the response speed of the model. The effectiveness of the method is verified by the simulation analysis of a New England 10-generator 39-node system.

Keywords: power system; renewable energy; transient stability assessment; AI; ensemble learning; transfer learning; multi-task model; power electrification

基金项目: 国家自然科学基金项目(U22 B20115); 辽宁省科学技术计划项目(2022-MS-110); 广东省基础与应用基础研究基金项目(2021A1515110778)

National Natural Science Foundation of China(U22 B20115); Liaoning Science and Technology Project(2022-MS-110); Guangdong Basic and Applied Basic Research Foundation Project(2021A1515110778)

0 引言

暂态稳定评估(Transient Stability Assessment, TSA)是维护电力系统安全平稳运转的重要手段之一, 传统的TSA分析方法多由数学模型驱动, 如时域仿真法^[1-2]、直接法^[3-4]等。时域仿真法在线应用

时计算时间过长,计算成本的增加削弱了其在工程领域的实用价值。直接法需求较小、耗时较短,但构造能量函数较为困难,模型适应性差,难以广泛应用。随着电力系统数字化技术的不断发展,采用数据驱动的电力系统TSA方法逐渐发展起来。

深度学习作为人工智能的最新分支,凭借其强大的数据挖掘能力和自主学习能力,为获取电网数据特征信息和解决建模分析稳定性问题带来了新的思路。针对以往方法无法解决的TSA问题,国内外学者给出了相应的解决方案。

(1)对电力系统拓扑变化的适应性。目前,基于数据驱动的评估方法大多很难建立拓扑变量与评估指标之间的映射,电力系统拓扑变化对系统故障后稳定性的影响往往被忽视。针对拓扑变化造成的间接影响,文献[5]利用迁移学习使卷积神经网络(Convolutional Neural Networks, CNN)模型参数保留对拓扑结构的关联性。文献[6]通过图注意力网络捕捉拓扑结构特征。文献[7]构建了递归图卷积神经网络(Graph Convolution Network, GCN),提取拓扑联系与时序特征融合的暂态特征。但此类算法处理图结构数据存在一些共性缺陷,即评估时间较长,需要额外的方法加速计算过程。

(2)样本不平衡问题。TSA数据集天然存在类间不平衡现象。数据生成方法包括采样方法和算法合成方法:基于采样的方法^[8]包括合成少数类过采样技术和自适应合成采样等,二者均为线性插值方法,产生的合成数据无法为评估提供更多的暂态稳定特征,与实际电网的运行状态关联性不强;基于算法生成少数类数据样本主要通过生成对抗网络^[9]来实现。此外,基于集成学习^[10-13]和改进损失函数^[14-19]的方法能有效解决不稳定特征学习困难的问题,但集成学习会增加模型的复杂程度,训练时间增加会影响模型的响应快速性,自适应调节样本权重的代价敏感方法目前尚不完善。

(3)评估的快速性。在保证系统稳定性预测准确率的同时,及时对系统进行紧急控制将直接影响系统的稳定运行,而电力系统的在线稳定性评估是当下TSA问题的重点。文献[20]提出了基于集成极限学习机的自适应决策机制,缩短了响应时间。文献[21]采用长短时记忆(Long Short-Term Memory, LSTM)网络构建时间自适应集成模型与同步相量测量装置(Phasor Measurement Unit, PMU),预测效果良好。

为解决上述问题,本文提出了基于自适应增强(Adaptive Boosting, AdaBoost)算法和迁移学习的多任务TSA方法,在传统电力系统TSA的时序输入特

征基础上,将空间注意力(Spatial Attention, SA)机制引入GCN构建SA-GCN模型,进一步融合电力系统拓扑结构特征;再通过引入时间注意力(Temporal Attention, TA)的LSTM网络,即TA-LSTM模型,挖掘关键时间点处融合特征中的暂态特性;集成以上2个子模型,建立基于图形卷积和长短时记忆组合网络的空间和时间双注意力机制(Spatial-Temporal Attention Mechanism, Graph Convolution and Long Short-Term Memory Network, STA-GLN)TSA模型。引入时空双注意力机制深入挖掘暂态特性,解决电力系统TSA研究中存在的因拓扑结构变化导致的评估准确率下降问题;结合AdaBoost的集成学习方法减少样本不平衡问题导致的失稳误判情况;引入迁移学习解决模型复杂导致的训练耗时长的的问题,保证评估的快速性。

1 构建暂态稳定分析数据集

1.1 生成样本集

本文选用新英格兰10机39节点系统作为算例测试系统^[22],基准频率为60 Hz,拓扑结构单线图如图1所示。该系统包含39条母线、10台发电机、19个负荷和34条传输线。

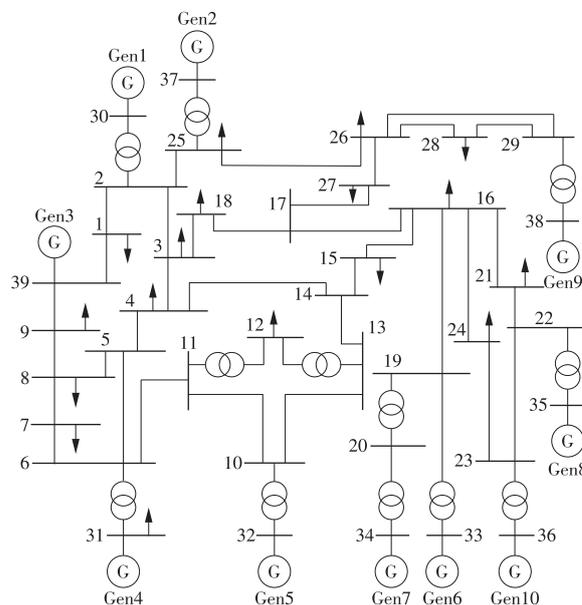


图1 新英格兰10机39节点系统

Fig. 1 New England 10-generator 39-node system

使用DIgSILENT PowerFactory 15.2仿真软件进行机电暂态仿真^[23],在34条不含变压器的并行传输线上设置三相接地短路故障,产生系统暂态失稳样本集。考虑测试系统拓扑变化对TSA结果的影响,在全接线系统的基础上增加了对N-1断线和N-2断线系统的样本生成。

(1)N-1断线样本集。系统负荷率在80%,

90%, 100%, 110%, 120% 之间变化, 发电机出力随负荷做相应调整。设置依次断开 15 条连接较大负荷的传输线路, 产生 15 种不同的 N-1 断线拓扑, 在断线外的 33 条传输线路上设置线路 50% 位置处的三相接地短路故障, 故障持续时间设置为 0.2 s。

(2) N-2 断线样本集。系统负荷率在 80%, 90%, 100%, 110%, 120% 之间变化, 发电机出力随负荷做相应调整。对前述 N-1 断线集中的 15 条断线进行组合, 除去会造成孤立母线的情况, 产生 10 种不同的 N-2 断线拓扑, 在断线外的 32 条传输线路上设置距离首端 50% 处的三相接地短路故障, 故障持续时间设置为 0.2 s。

样本集分类统计结果见表 1。

表 1 样本集分类统计

Table 1 Sample set classification statistics

样本集	稳定	失稳	总计
A(全接线)	2 436	1 235	3 671
B(N-1断线)	1 517	958	2 475
C(N-2断线)	845	755	1 600

1.2 构建暂态稳定特征集

通过评估电力系统暂态功角稳定性, 可以快速判定系统遭受大扰动后是否会失去稳定性。若预测结果为系统暂态失稳, 则可通过与暂态功角稳定评估同步的暂态电压稳定评估划分具体的失稳区域, 以便运维人员采取快速、精准的控制措施, 防止因故障造成严重的系统停电事故。

本文以电力系统的暂态功角稳定性和暂态电压稳定性为研究对象, 选取的特征量涉及电力系统大扰动后暂态过程中的运行状态变化, 故从时间、空间 2 个维度选取特征量, 本文选取的 TSA 模型特征输入量见表 2。

表 2 TSA 模型特征输入量

Table 2 Characteristic inputs for TSA model

特征类型	维度	描述	输入维度
I	时间	系统各母线的电压幅值与相角	39×2
II	空间	系统拓扑连接关系的拓扑矩阵	39×39

整体模型的时序特征输入特征为

$$X = (x_1, x_2, \dots, x_k) = (U^T, \Theta^T)^T, \quad (1)$$

$$U = \begin{bmatrix} u_{1,1} & \cdots & u_{N,1} \\ \vdots & & \vdots \\ u_{1,k} & \cdots & u_{N,k} \end{bmatrix}, \quad (2)$$

$$\Theta = \begin{bmatrix} \theta_{1,1} & \cdots & \theta_{N,1} \\ \vdots & & \vdots \\ \theta_{1,k} & \cdots & \theta_{N,k} \end{bmatrix}, \quad (3)$$

式中: U, Θ 分别为母线电压幅值、相角; k 为采样点

数; $u_{n,t}, \theta_{n,t}$ 分别为母线 n 在 t 时刻的电压幅值、相角。

在保证足够暂态信息输入的前提下, 为了缩短评估模型的训练时长, 通过评估试验得出最合适的采样点数为 $k = 5$, 即在选定的采样窗范围内对所选择的时序电气特征进行 5 次采样, 见表 3。

表 3 时序特征采样时间

Table 3 Time series features at different sample time

采样序号	采样时间
1	故障前的稳态母线电压幅值与相角
2	故障发生时刻的母线电压幅值与相角
3	故障发生过程中间时刻的母线电压幅值与相角
4	故障切除时刻的母线电压幅值与相角
5	故障切除后 1 s 末时的母线电压幅值与相角

1.3 选取 TSA 指标

按照前文对电力系统暂态稳定性的分析, 本文选取暂态功角稳定性和暂态电压稳定性作为研究对象。选取暂态稳定指数 (Transient Stability Index, TSI) 作为样本数据的暂态功角稳定性判据, 其表达式为

$$\eta_{TSI} = \frac{360 - |\Delta\delta_{\max}|}{360 + |\Delta\delta_{\max}|} \times 100, \quad (4)$$

式中: $\Delta\delta_{\max}$ 为排除故障 4 s 后系统内任意 2 台发电机功角差的最大值; η_{TSI} 为暂态稳定裕度。

$\eta_{TSI} > 0$ 时, 认定系统为稳定状态, 将样本标签标记为 1; $\eta_{TSI} < 0$ 时, 认定系统为失稳状态, 将样本标签标记为 0。

针对电压稳定类别, 本文采用暂态电压稳定实用判据, 即故障后母线节点电压低于 0.75 (标幺值) 的时间不超过 1 s。满足该条件的节点认定为稳定节点, 标记为 1, 不满足的节点认定为失稳节点, 标记为 0, 样本标签为 39 维。

混淆矩阵常用于比较、分析深度学习模型的分类结果。在 TSA 的混淆矩阵中, T_p, F_N 分别为将真实稳定样本正确预测为稳定样本的样本数量和将真实稳定样本错误预测为失稳样本的样本数量; F_p, T_N 分别为将真实失稳样本错误预测为稳定样本的样本数量和将真实失稳样本正确预测为失稳样本的样本数量。

使用的模型评价指标为依据暂态稳定混淆矩阵计算的准确率 P_{acc} 、精度 P_{rec} 、召回率 R_{ec} 、 F_1 值以及杰卡德系数 J 。

(1) 准确率 P_{acc} 表示稳定性预测结果正确的样本数量占总样本数量的百分比。通常情况下, 模型的准确率越高表明模型的预测性能越好。

$$P_{acc} = \frac{T_p + F_N}{T_p + F_p + T_N + F_N} \times 100\%。 \quad (5)$$

(2)精度 P_{rec} 又称查准率,表示被预测为失稳的真实失稳样本与预测为失稳的样本的比值。

$$P_{rec} = \frac{F_N}{T_N + F_N} \quad (6)$$

(3)召回率 R_{ec} 也称查全率,表示被预测为失稳的实际失稳样本与实际失稳总样本的比值。

$$R_{ec} = \frac{F_N}{F_p + F_N} \quad (7)$$

(4)进行电力系统 TSA 时,更关注遭受大扰动后电力系统是否失去稳定性,即对预测为失稳样本的准确率要求更高,但不能通过增加预测为失稳样本的样本数量来实现高召回率,因为正常情况下经历暂态过程后系统恢复稳定的几率远大于失稳几率。针对 P_{rec} 与 R_{ec} 的矛盾,引入 F_1 值平衡精度与召回率的影响,全面评价暂态稳定评估分类器性能。

$$F_1 = \frac{2R_{ec}P_{rec}}{R_{ec} + P_{rec}} = \frac{2F_N}{2F_N + F_p + T_N} \quad (8)$$

(5)杰卡德系数 J 为

$$J(S_i, S_j) = \frac{|S_i \cap S_j|}{|S_i \cup S_j|} = \frac{|S_i \cap S_j|}{|S_i| + |S_j| - |S_i \cap S_j|} \quad (9)$$

式中: $J \in [0, 1]$; S_i 为真实样本失稳节点电压状态集合; S_j 为多任务 TSA 模型中任务 2 输出的系统节点电压状态集合。

2 基于集成 STA-GLN 的多任务 TSA 模型

2.1 集成 STA-GLN 的多任务 TSA 模型

针对目前电力系统 TSA 研究中存在的泛化能力较差、评估实时性不足、失稳样本学习困难等缺陷,本文提出一种基于集成 STA-GLN 的电力系统多任务 TSA 模型,其框架结构如图 2 所示。

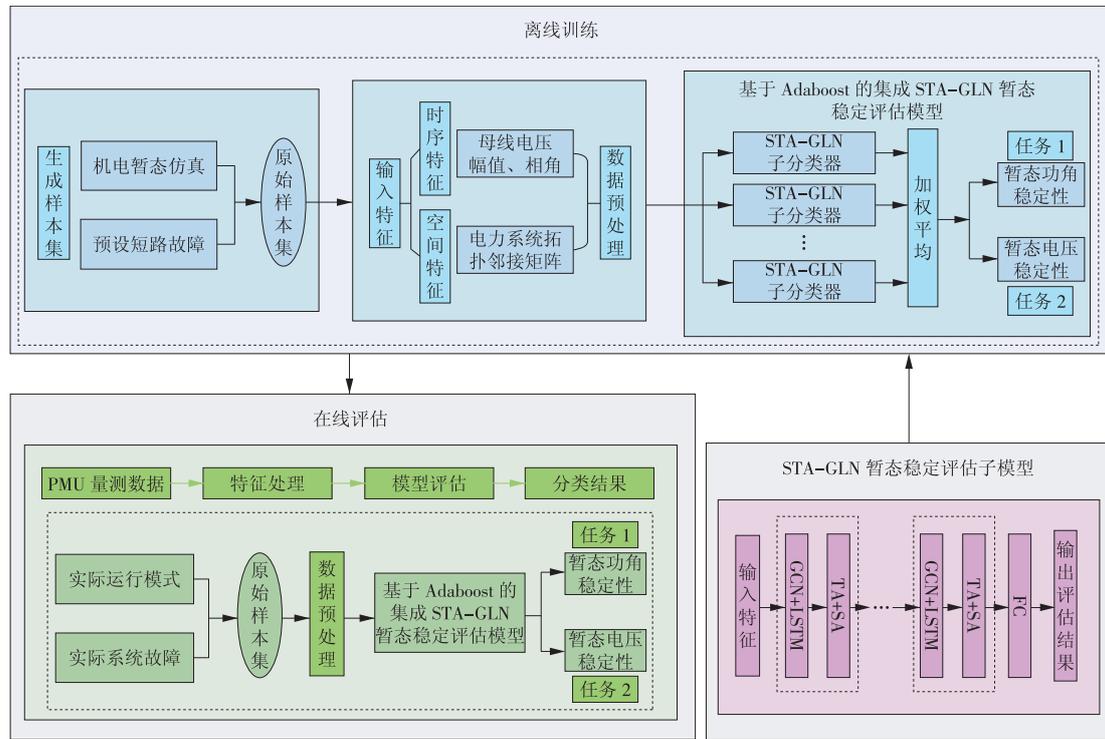


图 2 基于集成 STA-GLN 的电力系统多任务 TSA 模型框架

Fig. 2 Multi-task TSA model for the power system based on STA-GLN

为了提供更加详细的评估结果,提出同时进行暂态功角稳定性评估和暂态电压稳定性评估的多任务评估策略。引入集成学习和迁移学习的改进 STA-GLN 评估方法:将基于 STA-GLN 的 TSA 模型作为子模型,通过 AdaBoost 进行集成,使用 SAMME. R 算法动态调整各 STA-GLN 子分类器的输入样本权重,解决 TSA 中失稳样本学习困难的问题;引入迁移学习进行 STA-GLN 子分类器的模型参数迁移,节省各子分类器的训练时间,提升集成模型的评估速度,最终形成快速、准确且泛化能力强

的综合 TSA 方法。

电力系统暂态过程是沿时间顺序发生的不可逆的动态过程,暂态过程中每一时刻的输入特征对暂态过程发展的贡献度不同,以往的 TSA 问题研究很少考虑上述情况。因此,可以对不同时刻输入特征的重要等级进行排列,通过加强对重要时刻输入特征的学习,使模型获取更多的暂态稳定性预测经验,以提高评估结果的准确率。

从空间角度构建 SA-GCN 子模型,提取融合电力系统拓扑连接特性的输入特征,提升评估模型对

拓扑变化的适应性;从时间角度构建TA-LSTM子模型^[24-25],计算各时刻的时序特征重要性,以权重方式调节评估模型对重要时刻输入特征的学习强度,从

而深度挖掘输入特征中的暂态特性,提升模型性能。基于STA-GLN的电力系统TSA模型如图3所示。

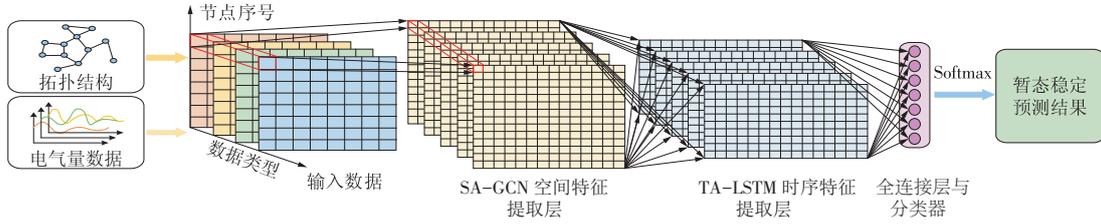


图3 基于STA-GLN的电力系统TSA模型结构

Fig. 3 TSA model for the power system based on STA-GLN

采用级联结构,结合SA-GCN子模型和TA-LSTM子模型得到基于STA-GLN的电力系统TSA模型结构如图3所示。输入特征包括电气时序特征 X 和电力系统拓扑邻接矩阵 A 。其中,邻接矩阵元素 a_{ij} 定义为

$$a_{ij} = \begin{cases} 1 & i = j \\ 1 & i \text{ 和 } j \text{ 相邻。} \\ 0 & \text{其他} \end{cases} \quad (10)$$

首先,将电气特征与邻接矩阵输入引入SA机制的GCN中。基于母线节点,SA-GCN将拓扑连接特性与节点输入特征融合,通过SA机制计算各节点的输入特征的余弦相似度 S ,据此对各节点进行注意力权重分配。

$$C_{ij}^{(l)} = \left(\frac{1}{S} \right) e^{\gamma^{(l)} \cos(H_i^l, H_j^{(l)})}, \quad (11)$$

$$S = \sum_{j \in N(i) \cup \{i\}} e^{\gamma^{(l)} \cos(H_i^l, H_j^l)}, \quad (12)$$

式中: $C_{ij}^{(l)}$ 为系统节点 i 对节点 j 的空间注意力系数; H^l 为GCN第 l 层的层间传播规则; $\gamma^{(l)}$ 为注意力引导传播参数; \cos 用于计算隐藏层特征的余弦相似度,相似度越大,表明其对中心节点的影响力越大。

以2层SA-GCN网络为例,通过SA矩阵 C 将拓扑连接关系融入节点输入特征中,得到输出的融合特征 X_G 。

$$X_G = f_G(X, A) =$$

$$\text{Softmax}\left(\left(C^{(l)} \odot \tilde{A}\right) \text{ReLU}\left(\left(C^{(0)} \odot \tilde{A}\right) X W^{(0)}\right) W^{(l)}\right), \quad (13)$$

式中: W^l 为每一层的节点训练权重矩阵; $\tilde{A} = A + I_N$ 表示添加了自连接的邻接矩阵, I_N 为单位矩阵。

然后,将SA-GCN网络的输出融合特征 X_G 作为TA-LSTM网络的输入进行二次特征提取。计算每一采样时刻 i 输入融合特征与全部输入融合特征的余弦相似度,进而获取对重要时刻输入特征的时间注意力系数 α 。

$$\alpha = \text{Softmax}\left(\cos(h_i, H)\right) = \frac{h_i H}{\|h_i\| \cdot \|H\|}, \quad (14)$$

式中: H 为当前样本全时刻的LSTM单元隐藏状态; h_i 为第 i 个时间步LSTM单元隐藏状态。

利用 α 更新TA-LSTM的隐层状态并加强TA-LSTM网络对关键时刻输入融合特征的学习,进一步提升TSA的准确性。具体表现为,将不同时刻的输入特征对评估结果的影响力通过注意力计算量化为更新LSTM网络隐藏状态的权重,得到新的隐藏状态。

$$h'_i = \text{contact}(h_i, \alpha_i H). \quad (15)$$

通过全连接层和Softmax处理后得到二维输出表示系统暂态功角稳定和失稳的概率,与设定的分类阈值 μ 比较即可得出电力系统暂态功角稳定性的预测结果,本文设定 μ 值为0.5。

$$y_{ST} = \text{Softmax}(Wh') \Rightarrow \begin{cases} y_{ST} > \mu & \text{稳定} \\ y_{ST} < \mu & \text{失稳} \end{cases}. \quad (16)$$

在以往的TSA研究中,多针对暂态过程后的功角稳定性进行预测,忽略了功角失稳与电压失稳常常同期出现^[26-27]这一事实。针对电力系统暂态功角稳定性和电压稳定性评估建立多任务评估模型^[28],任务1的暂态功角稳定性评估为二分类问题,经过Softmax激活函数处理后得到表示系统稳定和失稳的二维概率。多任务TSA模型如图4所示。

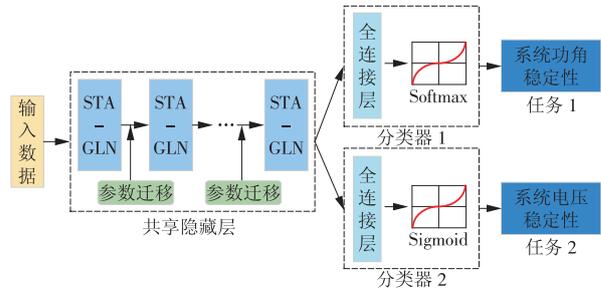


图4 多任务TSA模型

Fig. 4 Multi-task TSA model

2.2 基于AdaBoost的样本不平衡处理

针对电力系统TSA中存在的样本不平衡问题,通过AdaBoost的样本权重更新策略,能够对少数类

样本即失稳样本给予更多的关注,在迭代训练过程中不断修正对失稳样本的误判,以实现较高的失稳样本查全率与查准率。

AdaBoost 算法通过改变训练样本的权重分布来提升模型分类或预测精度。根据每轮迭代后形成的弱学习器对训练集所有样本划分的准确率及总体的分类准确率来改变进入下一次迭代的弱学习器训练集的样本权重,然后整合每一轮迭代产生的弱学习器,得到最终的强监督分类模型,如图 5 所示。

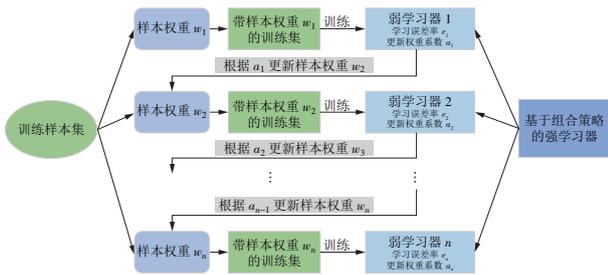


图 5 AdaBoost 学习机制

Fig. 5 AdaBoost learning mechanism

采用 AdaBoost 对 STA-GLN 模型进行集成时,将暂态稳定训练样本集表示为 X_{train} , 对训练集样本赋予初始权重分布 W_1 。

$$X_{train} = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}, \quad (17)$$

$$W_1 = (w_{11}, w_{12}, \dots, w_{1i}, \dots, w_{1n})$$

$$w_{1i} = \frac{1}{n}, i = 1, 2, \dots, n, \quad (18)$$

式中: X_{train} 为暂态稳定训练样本集; \mathbf{x} 为输入样本的特征向量; y 为输入样本的类别, 即样本标签。

对于 AdaBoost 的第 m 次迭代, 需要使用带有权重分布 W_m 的训练集进行训练, 得到子分类器 $G_m(\mathbf{x})$, 即第 m 个 STA-GLN 子分类器以及输出的分类结果。采用 SAMME. R 算法进行分类, 通过加权概率估计方法更新模型。在训练得到第 m 个子分类器 $G_m(\mathbf{x})$ 后, 记当前的组合强分类器为 $f_m(\mathbf{x})$, 希望通过加入一个新的子分类器 $h(\mathbf{x})$ 使强分类器的性能更好。首先计算加权类概率估计, 再根据加权概率估计求解新的子分类器 $h(\mathbf{x})$, 计算过程见式 (19)–(20)。

$$p_k^m(\mathbf{x}_i) = p_w(c = k | \mathbf{x}_i), k = 1, 2, \dots, K, \quad (19)$$

$$h_k^m(\mathbf{x}) = (K - 1)(\lg p_k^m(\mathbf{x}) - \frac{1}{K} \sum_i \lg p_i^m(\mathbf{x})), \quad (20)$$

式中: $p_k^m(\mathbf{x})$ 为第 m 个子分类器将样本 \mathbf{x}_i 分为第 k 类的概率; p_w 为加权概率; c 为分类类别。

归一化更新样本权重 $w_{m+1,i}$, 最终加权得到强分类器 $G(\mathbf{x})$ 。

$$w_{m+1,i} = \frac{w_{mi}}{Z_m} \exp\left(-\frac{K-1}{K} y_i \lg p_i^m(\mathbf{x})\right)$$

$$i = 1, 2, \dots, n, \quad (21)$$

$$G(\mathbf{x}) = \text{sign}\left(\arg \max_K \sum_{i=1}^M h_k^m(\mathbf{x})\right), \quad (22)$$

式中: Z_m 为规范因子。

$\sum_{i=1}^M h_k^m(\mathbf{x})$ 最大的类别即为模型的分类类别, Z_m 将 w_{mi} 值限制在 $[0, 1]$ 内, 保证 $\sum_{i=1}^n w_{mi} = 1$ 。

2.3 基于迁移学习的模型参数传递

基于 AdaBoost 的集成学习方法需要重复使用样本训练集对 STA-GLN 子模型进行训练, 这对加快模型响应速度, 实现快速的在线 TSA 十分不利。迁移学习可以从源域中迁移标签信息和知识结构, 从而完成目标域中的学习任务。迁移学习^[29-30]优化 AdaBoost 集成学习机制可缩短对 STA-GLN 子模型进行重复训练的时间, 实现集成模型的快速响应。

基于参数迁移的集成 STA-GLN 模型如图 6 所示。使用训练集训练第 1 个 STA-GLN 子分类器, 在 AdaBoost 集成的下一轮迭代中, 通过迁移学习迁移第 1 个 STA-GLN 子分类器的模型参数并赋予下一子分类器, 采用权重更新后的训练集对该子分类器进行参数微调, 从而得到新的 STA-GLN 子分类器, 之后重复这一过程。每一轮迭代产生的 STA-GLN 子分类器模型参数都迁移自上一轮产生的 STA-GLN 子分类器, 通过迁移学习迁移子分类器模型参数, 避免了重复训练子分类器所需的大量时间; 同时, 为了保证子分类器的多样性, 采用样本权重不同的训练集对迁移得到的 STA-GLN 子分类器进行参数微调, 在提升集成 STA-GLN 模型响应速度的同时, 进一步提升了 TSA 的准确性, 能够满足电力系统在线评估的需求。

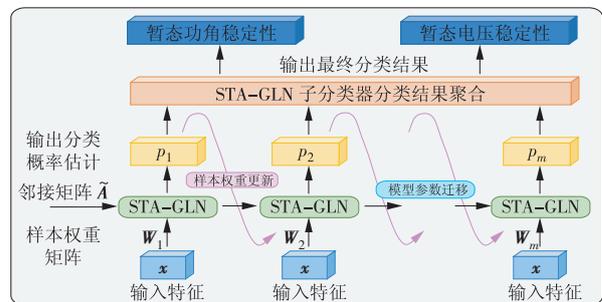


图 6 基于参数迁移的集成 STA-GLN 多任务 TSA 模型

Fig. 6 Multi-task TSA model based on STA-GLN integrating parameter transferring

3 算例分析

3.1 暂态特征集验证

为了验证本文选取的母线电压幅值和相角特

征对电力系统 TSA 问题的有效性,在新英格兰 10 机 39 节点系统中通过时域仿真生成对比样本集并在同一测试模型中验证输入特征对 TSA 的贡献。仿真得到的试验样本集见表 4。

表 4 不同输入特征的样本集

Table 4 Sample sets with different input characteristics

特征集	描述	输入维度	采样点数	总维度	样本数
1	39 条母线的电压幅值与相角	78	5	390	5 000
2	34 条传输线的有功、无功功率	68	5	340	5 000
3	发电机母线电压幅值	10	10	100	5 000

建立基于 LSTM 的 TSA 模型对上述时序特征集进行评估验证,取各特征集的 80% 样本作为训练集,20% 样本作为测试集,得到 P_{acc} 和 F_1 值,见表 5。

表 5 不同特征集的评估结果

Table 5 Assessment results of different characteristic sets

特征集	评估指标	
	$P_{acc}/\%$	$F_1/\%$
1	94.57	95.33
2	94.15	94.54
3	93.62	94.20

由表 5 可见,采用本文选取的电压幅值和相角特征进行 TSA 的效果最优。对比特征集 3,本文选用的特征集 1 包含的母线电压范围更全面,提升了测试模型的评估性能;对比特征集 2,考虑与系统节点拓扑连接关系的紧密性,选择母线电压幅值和相角比线路有功、无功功率更为合理,建立时间与空间 2 个维度的关联性也更容易,故本文选取的特征集 1 的 TSA 表现更好。

因此,在选择母线电压幅值和相角作为时序输入特征的基础上,考虑空间维度中拓扑连接关系对时序特征的影响,能够使特征对暂态过程的特性描述更加细致、全面,进而提升模型的评估性能,实现拓扑变化情况下更加准确的 TSA。

3.2 STA-GLN 模型结构确定及性能分析

为了便于验证模型对拓扑变化的适应能力,将原始数据集重新划分成表 6 所示的形式。从 3 个数据集分层抽取部分样本,维持与原样本集类别比例的一致性,按照 2:1:1 的比例构成混合数据集 D。

SA-GCN 与 TA-LSTM 的网络层数搭配不同将直接影响 STA-GLN 模型的评估性能。设计不同层数搭配的 STA-GLN 组合网络并从数据集 A 中抽取 1/3 样本数据进行模型的 TSA 性能测试,确定基于 STA-GLN 的 TSA 模型的最优结构。不同层数搭配的 STA-GLN 模型性能见表 7。

表 6 4 种数据集的稳定与失稳样本划分

Table 6 Stable and unstable sample partition of four data sets

数据集	稳定	失稳	总计
A(全接线)	2 436	1 235	3 671
B(N-1 断线)	1 517	958	2 475
C(N-2 断线)	845	755	1 600
D(分层抽样混合)	1 249	757	2 006

表 7 不同层数搭配的 STA-GLN 模型性能

Table 7 Performances of STA-GLN models with different layers

SA-GCN 层数量	TA-LSTM 层数量	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$
1	1	96.72	98.21	88.71	93.22
1	2	88.52	85.42	66.13	74.55
2	1	97.95	98.31	93.55	95.87
2	2	98.77	98.36	96.77	97.56
3	1	95.90	88.24	96.77	92.31
3	2	97.54	95.16	95.16	95.16

由表 7 可见,当 SA-GCN 和 TA-LSTM 网络层数均为 2 时,STA-GLN 模型的 TSA 效果最好。此时,SA-GCN 在有效融合拓扑结构和电气特征的前提下,实现了最大程度的分类性能贡献。

在不考虑噪声与数据缺失干扰的情况下,验证本文提出的基于 STA-GLN 的 TSA 模型的评估效果。选择用于组成 STA-GLN 模型的网络搭建相应的 TSA 模型,包括 GCN, SA-GCN, LSTM, TA-LSTM, GCN-LSTM,将数据集 A, B, C, D 以 6:2:2 的比例分割成训练集、验证集和测试集,进行性能对比分析,对比结果见表 8—11。

表 8 不同模型在数据集 A 上的性能表现

Table 8 Performances of different models on dataset A

模型	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$
GCN	89.24	93.55	96.67	95.08
SA-GCN	93.72	95.93	98.33	97.12
LSTM	94.17	95.22	99.58	97.35
TA-LSTM	95.52	98.32	97.50	97.91
GCN-LSTM	96.41	99.57	97.08	98.31
STA-GLN	97.31	99.58	97.92	98.74

表 9 不同模型在数据集 B 上的性能表现

Table 9 Performances of different models on dataset B

模型	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$
GCN	88.28	89.50	96.24	92.75
SA-GCN	92.89	96.17	94.62	95.39
LSTM	93.72	93.85	98.39	96.06
TA-LSTM	94.14	97.78	94.62	96.17
GCN-LSTM	94.56	96.76	96.24	96.50
STA-GLN	96.65	97.34	98.39	97.86

表 10 不同模型在数据集 C 上的性能表现

Table 10 Performances of different models on dataset C

模型	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$
GCN	78.12	94.74	96.00	95.36
SA-GCN	79.69	94.77	96.67	95.71
LSTM	81.25	95.39	96.67	94.77
TA-LSTM	82.81	96.64	96.00	96.32
GCN-LSTM	84.38	95.45	98.00	96.71
STA-GLN	87.50	96.71	98.80	97.35

表 11 不同模型在数据集 D 上的性能表现

Table 11 Performances of different models on dataset D

模型	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$
GCN	90.41	94.08	96.62	95.33
SA-GCN	91.10	94.70	96.62	95.65
LSTM	92.47	95.36	97.30	96.32
TA-LSTM	93.15	95.39	97.97	96.67
GCN-LSTM	94.52	96.67	97.97	97.32
STA-GLN	96.58	98.64	97.97	98.31

对比表 8—10 可知:在断线数据集 B 和 C 上,本文提出的 STA-GLN 模型依然在对试验中表现出最好的性能指标,其 P_{acc} , P_{rec} 和 F_1 值均为最高;在 N-2 断线数据集 C 中 STA-GLN 的性能表现较差,这是由于系统拓扑变化较大导致真实拓扑连接与完整拓扑连接之间存在差异,STA-GLN 没能建立拓扑结构与节点特征的完整关联,即空间特征与时序特征的融合度较低。

由表 11 可知,在混合数据集 D 中 STA-GLN 的性能表现与在全接线数据集 A 相差不大, P_{acc} 达到 96.58%, F_1 值为 98.31%, 表明精度与召回率的平衡情况较好。由此可见,对全接线样本的学习使 STA-GLN 模型建立了全面的拓扑结构特征(空间特征)与节点采集特征(时序特征)的耦合关联,在判断断线拓扑结构下的输入样本时,能够实现较高的评估准确率和失稳样本查全率、查准率,模型综合性能良好。

3.3 多任务 TSA 模型性能分析

针对电力系统暂态功角稳定性和电压稳定性评估建立多任务评估模型。任务 1 的暂态功角稳定性评估为二分类问题,使用的评价指标为依据暂态稳定混淆矩阵计算的 P_{acc} , P_{rec} , R_{ec} 和 F_1 值。任务 2 的暂态电压稳定性评估为多维标签分类问题,经过 Sigmoid 激活函数处理后得到表示系统节点电压稳定或失稳的 m 维概率,其中每一列对应系统中的一个节点。由于任务 2 的模型输出为整数集合,而非单一数值,因此选择杰卡德系数 J 作为评价指标,用于比较暂态电压稳定性评估结果与样本真实电压

稳定性的差异程度。

为了验证单一 STA-GLN 模型与集成 STA-GLN 模型的性能并确定最佳子分类器数目,将全接线样本集 A 以 6:2:2 的比例分割成训练集、验证集和测试集,训练过程采用交叉熵损失函数。测试结果见表 12。

表 12 单一 STA-GLN 模型与集成 STA-GLN 模型性能对比

Table 12 Performances of mono-STA-GLN model and ensemble STA-GLN model

模型	训练集		测试集		训练周期或子分类器数量
	$P_{acc}/\%$	$J/\%$	$P_{acc}/\%$	$J/\%$	
单一 STA-GLN 多任务 TSA 模型	95.70	91.50	94.56	90.69	40 个 epoch
	96.65	93.14	95.48	92.48	50 个 epoch
	95.82	91.89	94.51	91.05	60 个 epoch
集成 STA-GLN 多任务 TSA 模型	99.18	96.77	98.77	95.7	5 个子分类器
	98.36	94.66	98.25	94.00	8 个子分类器
	97.91	93.89	96.77	93.15	10 个子分类器
	96.54	92.68	95.72	92.07	15 个子分类器

由表 12 可知,单一 STA-GLN 多任务模型测试中,训练周期为 50 个 epoch 时,其测试性能指标最优,在同等前置条件下将子分类器数量从 1 增加至 15,观察其多任务评估指标变化情况,如图 7 所示。结合表 12,集成 STA-GLN 模型结构中,子分类器数量为 5 时, TSA 性能达到最佳。后续试验都参照这一设定。

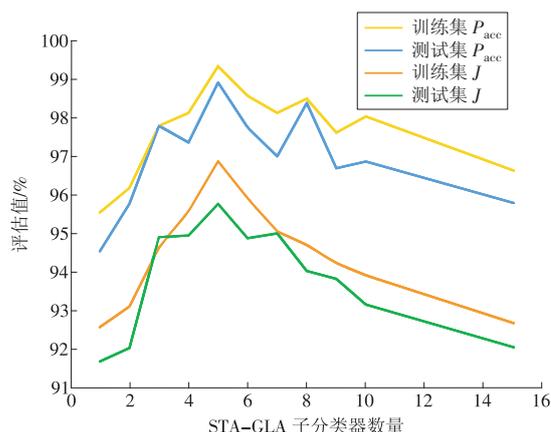


图 7 不同数量子分类器构成的 AdaBoost-STA-GLN 集成模型评价指标

Fig. 7 Evaluation index of the AdaBoost-STA-GLN ensemble model composed of different estimators

选取不同的算法与本文提出的多任务 TSA 模型进行性能对比。分别在全接新样本集 A、N-1 断线样本集 B、N-2 断线样本集 C 和包含数据集 A, B, C 全部样本的样本集 E 中验证本文提出的集成 STA-GLN 多任务 TSA 模型性能的优越性。各样本

集中的指标对比结果见表 13—16(表中:RF 为随机森林;DT 为决策树)。对比其他模型,本文提出的模型在各个样本集中均表现最优,在全样本集中,AdaBoost–STA–GLN 多任务评估模型的 P_{acc} 为 98.76%, R_{ec} 为 99.58%,表明该模型能够有效挖掘系统暂态过程中的功角特性和电压特性。而在断线样本集 B,C 中,各个模型的性能指标均有所下降,AdaBoost–GCN 指标下降最为明显,本文提出的 AdaBoost–STA–GLN 集成模型仍能维持较为准确的 TSA。任务 1 的 P_{acc} 仅分别下降了 1.26,3.25 百分点,任务 2 的 J 值仅下降了 1.14,3.14 百分点;此外,对比单一 STA–GLN 模型的断线样本集,AdaBoost–STA–GLN 集成模型的 P_{acc} 分别提升了 0.86,8.02 百分点,表明 AdaBoost–STA–GLN 集成模型的学习能力更强,针对输入特征的暂态特性挖掘更加深入。

表 13 不同模型在样本集 A 中的性能表现

Table 13 Performances of different models in sample set A

模型	任务 1				任务 2
	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$	$J/\%$
AdaBoost–STA–GLN	98.77	98.32	97.50	97.91	95.70
AdaBoost–LSTM	97.54	97.28	96.24	96.76	94.55
AdaBoost–CNN	97.31	98.30	96.77	97.53	94.35
RF	96.86	97.83	96.77	97.30	93.67
AdaBoost–DT	96.55	96.28	97.08	96.68	93.38
AdaBoost–GCN	95.82	96.17	94.62	95.39	92.77

表 14 不同模型在样本集 B 中的性能表现

Table 14 Performances of different models in sample set B

模型	任务 1				任务 2
	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$	$J/\%$
AdaBoost–STA–GLN	97.51	97.11	97.92	97.51	94.56
AdaBoost–LSTM	96.65	96.64	96.00	96.32	93.27
AdaBoost–CNN	96.58	96.62	95.33	95.97	93.10
RF	95.21	96.03	96.67	96.35	92.57
AdaBoost–DT	94.56	95.39	96.67	94.77	91.35
AdaBoost–GCN	92.47	94.70	96.62	95.65	89.68

表 15 不同模型在样本集 C 中的性能表现

Table 15 Performances of different models in sample set C

模型	任务 1				任务 2
	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$	$J/\%$
AdaBoost–STA–GLN	95.52	97.28	96.62	96.95	92.56
AdaBoost–LSTM	92.47	96.17	94.62	95.39	91.40
AdaBoost–CNN	91.78	95.39	96.67	96.03	91.25
RF	91.10	95.57	96.62	96.30	90.77
AdaBoost–DT	89.24	95.33	96.62	95.97	88.78
AdaBoost–GCN	86.55	94.67	95.95	95.30	86.55

表 16 不同模型在样本集 E 中的性能表现

Table 16 Performances of different models in sample set E

模型	任务 1				任务 2
	$P_{acc}/\%$	$P_{rec}/\%$	$R_{ec}/\%$	$F_1/\%$	$J/\%$
AdaBoost–STA–GLN	98.36	98.76	99.58	99.17	95.50
AdaBoost–LSTM	97.31	98.38	97.85	98.11	94.25
AdaBoost–CNN	96.86	98.32	97.50	97.91	94.18
RF	96.41	97.85	97.85	97.85	93.37
AdaBoost–DT	95.40	97.83	96.77	97.30	92.86
AdaBoost–GCN	93.72	96.28	97.08	96.68	91.54

为了对比多任务模型与各对比集成模型的快速性,基于前述测试条件,记录不同集成模型在样本集 E 中迭代训练 50epoch 所耗时长,见表 17。

表 17 不同模型的训练时长

Table 17 Training time of different models

模型	训练时长
AdaBoost–STA–GLN	112
AdaBoost–LSTM	155
AdaBoost–CNN	105
RF	127
AdaBoost–DT	130
AdaBoost–GCN	133

由表 17 可见:在相同训练周期下,AdaBoost–CNN 模型训练时长最短,为 105 s,本文提出的 AdaBoost–STA–GLN 多任务模型仅次于 AdaBoost–CNN 模型,训练时长为 112 s。结合在样本集 E 中各集成模型的 P_{acc} 和 J 值可知,本文提出的 AdaBoost–STA–GLN 多任务模型在评估准确性和快速性 2 方面取得了双优的均衡表现。

3.4 多任务 TSA 模型可视化

将单一 STA–GLN 模型、AdaBoost–LSTM 模型和 AdaBoost–STA–GLN 多任务模型输出层特征进行 t 分布随机近邻嵌入(t–Stochastic Neighbor Embedding, t–SNE)降维后,得到的分类结果如图 8 所示。说明通过基于 AdaBoost 的集成学习方式有效提升了 STA–GLN 模型的性能,对重叠区域的样本类别判别能力得到了进一步提升,失稳样本误判率较小,对进行暂态稳定在线评估具有较大优势。

针对任务 2 的暂态电压稳定性评估结果,在原始原样本集中任选 2 个样本进行 t–SNE 降维可视化,各样本的稳定节点与失稳节点嵌入如图 9 所示。样本 1 中,节点 26,28,29,38 为失稳节点,均位于红色边界线区域内,失稳节点之间相对距离较近;而在样本 2 中,系统出现大面积节点失稳情况,在蓝色边界线一侧为稳定节点 1,2,25,39,另一侧为失稳节点,表明失稳节点之间存在相互影响。

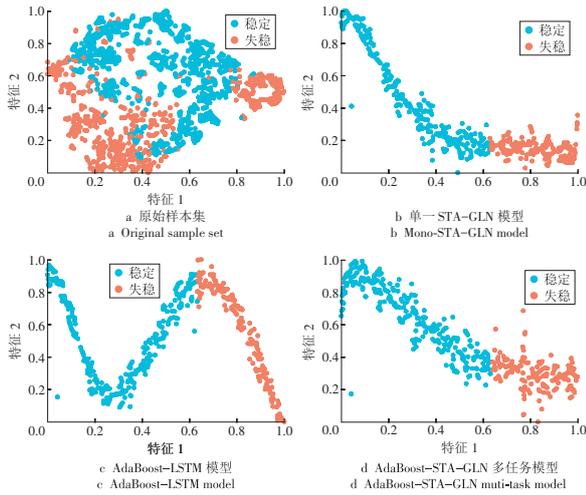


图 8 t-SNE 降维后的二维特征映射

Fig. 8 Two-dimensional feature mapping after t-SNE

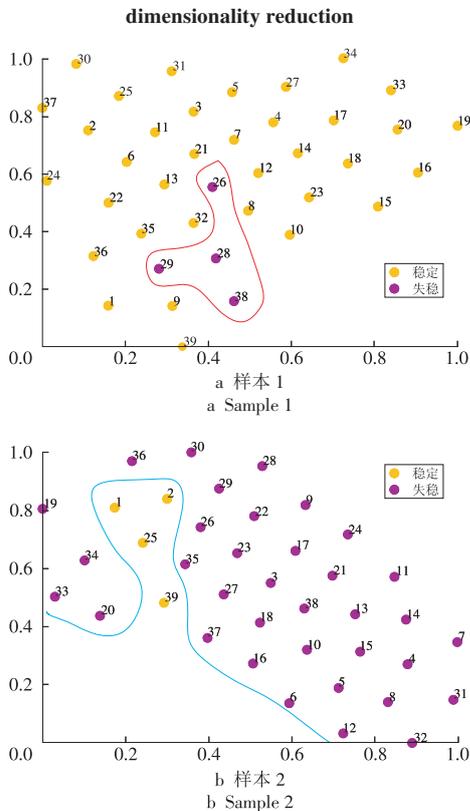
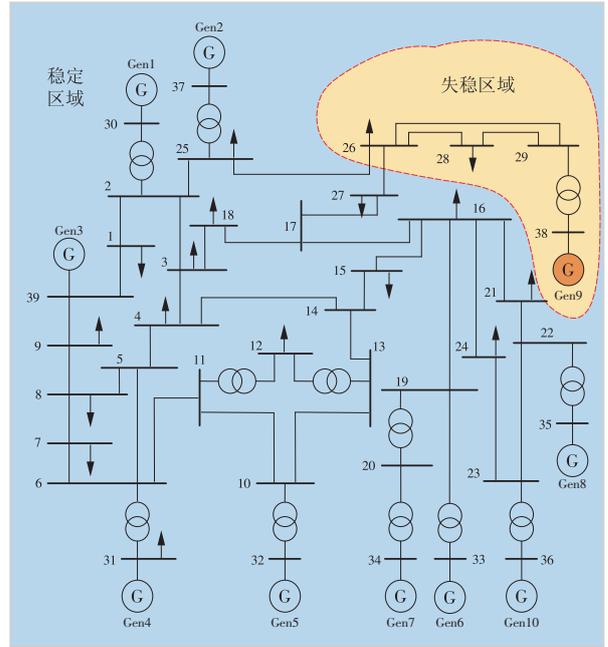


图 9 样本电压失稳节点分布

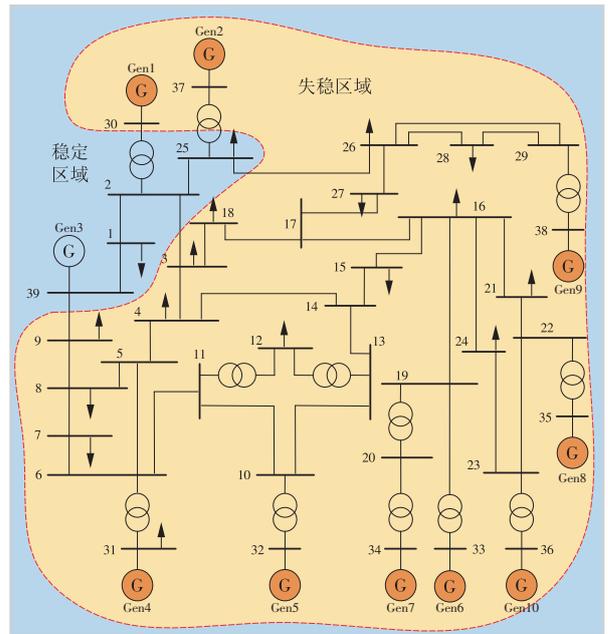
Fig. 9 Distribution of sample nodes with voltage instability

为了进一步验证失稳节点预测效果,将失稳节点预测结果嵌入实际仿真结果的电力系统拓扑结构中,得到图 10 所示的稳定与失稳区域划分结果。

由图 10 可见:样本 1 中,系统发生暂态过程后发电机 Gen9 失去同步,相关联的 38,29,28,26 节点接连失稳,多任务模型中任务 2 的评估结果与仿真结果的区域划分一致;样本 2 也得到了同样的效果。表明本文提出的 AdaBoost-STA-GLN 多任务评估模型能够有效划分系统的预测失稳区域,可为控制中心进行预防控制提供详细的系统稳定性评估方案。



a 样本 1 区域划分
a Partition of sample 1



b 样本 2 区域划分
b Partition of sample 2

图 10 任务 2 评估结果验证

Fig. 10 Evaluation on assessment results of task two

3.5 多任务 TSA 模型抗干扰能力验证

从 PMU 采集到的节点电气数据常存在噪声干扰和数据缺失现象,基于这一实际情况,需测试本文提出的 AdaBoost-STA-GLN 多任务 TSA 模型对噪声数据的鲁棒性。为了验证本文提出 AdaBoost-STA-GLN 多任务 TSA 模型的抗干扰能力,在原始样本集 E 中分别加入信噪比为 30 dB 和 50 dB 的高斯白噪声,构成噪声干扰样本集 G 和 H。经仿真验证,加入 2 种高斯白噪声后样本特征幅值均产生振荡,对提取样本中的暂态特性造成负面影响。

将 AdaBoost-STAGLN 多任务模型与其他模型在噪声样本集中进行训练与测试,得到各模型的抗干扰能力测试结果,见表 18。

表 18 不同集成模型的抗干扰能力

评估模型	50 dB 噪声样本集		30 dB 噪声样本集	
	$P_{acc}/\%$	$J/\%$	$P_{acc}/\%$	$J/\%$
1 AdaBoost-STAGLN	98.20	95.30	97.67	94.75
2 AdaBoost-LSTM	96.85	94.00	95.40	93.10
3 AdaBoost-CNN	96.40	93.75	95.17	92.77
4 RF	95.52	92.46	94.34	91.56
5 AdaBoost-DT	94.17	92.18	93.40	91.49
6 AdaBoost-GCN	92.38	91.34	91.52	90.64

对比各模型在外加干扰情况下的性能表现,本文提出的 AdaBoost-STAGLN 多任务 TSA 模型任务 1 的 P_{acc} 分别下降了 0.16, 0.69 百分点,任务 2 的 J 值分别下降了 0.20, 0.75 百分点,在各集成模型中性能下滑幅度最小,指标维持较好。总体来看,本文提出的 AdaBoost-STAGLN 多任务模型较其他集成模型具有更好的鲁棒性,但在高噪声环境中的表现有待进一步提升。

3.6 多任务 TSA 模型泛化能力验证

为了验证本文提出的 AdaBoost-STAGLN 多任务评估模型对电力系统拓扑变化的适应性,利用不同样本集构成的训练集和测试集对多任务模型进行泛化性测试。方案 1 为在全接线样本集 A 中进行训练,在 N-1 断线样本集 B 中进行测试;方案 2 为在由全接线样本集 A 和 N-1 断线样本集 B 构成的混合样本集 I 中进行训练,在 N-2 断线样本集 C 中进行测试。2 种方案下 AdaBoost-STAGLN 多任务评估模型与对比模型指标如图 11 所示。

如图 11 所示,在方案 1 中,对比模型中表现最好的是 AdaBoost-LSTM 单任务评估模型,但其 P_{acc} 和 J 值均低于 AdaBoost-STAGLN 多任务评估模型,其原因在于 AdaBoost-STAGLN 多任务评估模型充分考虑了系统拓扑连接对评估结果的影响。在方案 2 中,由于 N-2 断线拓扑结构变化较大,各模型的评估精度再次下降,而本文提出的 AdaBoost-STAGLN 多任务评估模型的 P_{acc} 维持在 96.55%, J 值维持在 94.47%, 下跌幅度最小。各对比模型由于考虑因素不够全面,对特征的提取能力不足,导致性能明显下降。综合来看,本文提出的 AdaBoost-STAGLN 多任务评估模型具有较好的泛化能力,面对电力系统拓扑变化具有较强的适应性,能够在运行工况变化频繁的系统中进行准确的 TSA。

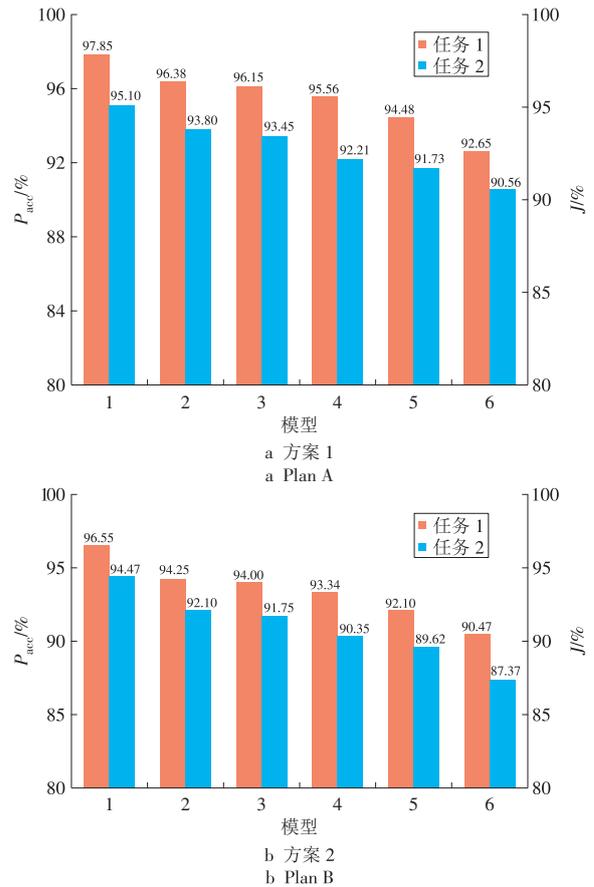


图 11 2 种方案中不同模型的泛化能力

Fig. 11 Generalization capacities of different models in two plans

4 结束语

为了解决电力系统 TSA 研究中存在的拓扑结构变化导致评估准确率下降、样本不平衡引起失稳误判和模型复杂导致训练耗时长问题,本文提出一种基于 AdaBoost 的集成 STA-GLN 电力系统 TSA 方法,主要结论如下。

(1) 考虑拓扑变化影响,将 SA 机制引入 GCN,增强了模型对拓扑结构连接特性的提取效果,将其与时序输入特征融合,再输入到引入 TA 的 LSTM 网络中提取融合特征中包含的暂态特性。经仿真验证,STA-GLN 对电力系统暂态过程有更深入的特征挖掘能力,暂态评估准确率更高。

(2) 通过 AdaBoost 集成 STA-GLN 构成集成模型,使用 SAMME. R 算法根据 STA-GLN 子分类器评估结果的误差对样本学习权重进行调整,降低了失稳样本误判率,解决了 TSA 过程中的样本不平衡问题,使集成 STA-GLN 模型的评估准确率得到进一步的提升。此外,在 AdaBoosting 的子分类器生成过程中引入迁移学习方法,有效提升了模型的响应速度。

(3) 将提出的集成 STA-GLN 的多任务 TSA 模型

在新英格兰 10 机 39 节点系统中进行仿真,验证结果表明,该模型提高了特征提取能力和评估准确性,能够正确、详细地划分失稳区域,有较强的泛化能力,可在拓扑变化情况下进行准确、快速、多角度的电力系统 TSA,保障电力系统安全稳定运行。

参考文献:

- [1] 薛巍,舒继武,严剑峰,等.基于集群机的大规模电力系统暂态过程并行仿真[J].中国电机工程学报,2003,23(8):38-43.
XUE Wei, SHU Jiwu, YAN Jianfeng, et al. Cluster-based parallel simulation for power system transient stability analysis[J]. Proceedings of the CSEE, 2003, 23(8):38-43.
- [2] 李亚楼,李芳,刘赫川,等.基于PSASP的综合能源仿真分析系统[J].电网技术,2019,43(7):2498-2505.
LI Yalou, LI Fang, LIU Hechuan, et al. Framework design of simulation system for integrated energy systems based on PSASP[J]. Power System Technology, 2019, 43(7):2498-2505.
- [3] CHANG H D, WU F F, VARIAYA P P. A BCU method for direct analysis of power system transient stability[J]. IEEE Transactions on Power Systems, 1994, 19(2):11-17.
- [4] 汪小明,刘涤尘,吴军,等.基于能量函数法的电网暂态稳定性分析[J].电网技术,2011,35(8):13-17.
WANG Xiaoming, LIU Dichen, WU Jun, et al. Energy function-based power system transient stability analysis[J]. Power System Technology, 2011, 35(8):13-17.
- [5] 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.
ZAHNG 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.
- [6] 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,2020,45(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, 2020, 45(6):2122-2130.
- [7] HUANG Jiyu, GUAN Lin, SU Yinsheng, et al. Recurrent graph convolutional network-based multi-task transient stability assessment framework in power system[J]. IEEE Access, 2020, 8: 93283-93296.
- [8] HE H B, GARCIA E A. Learning from imbalanced data[J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 21(9):1263-1284.
- [9] 谭本东,杨军,赖秋频,等.基于改进CGAN的电力系统暂态稳定评估样本增强方法[J].电力系统自动化,2019,43(1):149-157.
TAN Bendong, YANG Jun, LAI Qiupin, et al. Data augment method for power system transient stability assessment based on improved conditional generative adversarial network[J]. Automation of Electric Power Systems, 2019, 43(1):149-157.
- [10] 田芳,周孝信,史东宇,等.基于卷积神经网络综合模型和稳态特征量的电力系统暂态稳定评估[J].中国电机工程学报,2019,39(14):4025-4031.
TIAN Fang, ZHOU Xiaoxin, SHI Dongyu, et al. Power system transient stability assessment based on comprehensive convolutional neural network model and steady-state features[J]. Proceedings of the CSEE, 2019, 39(14):4025-4031.
- [11] 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.
- [12] 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.
- [13] ZHOU Y Z, GUO Q L, SUN H B, et al. A novel data-driven approach for transient stability prediction of power systems considering the operational variability[J]. International Journal of Electrical Power and Energy Systems, 2019, 107:379-394.
- [14] 李楠,李保罗,朱建华,等.计及样本不平衡与重叠的暂态稳定评估方法[J].电力系统自动化,2020,44(21):64-71.
LI Nan, LI Baoluo, ZHU Jianhua, et al. Transient stability assessment method considering sample imbalance and overlap[J]. Automation of Electric Power Systems, 2020, 44(21):64-71.
- [15] 陈振,肖先勇,李长松,等.基于代价敏感极端学习机的电力系统暂态稳定评估方法[J].电力自动化设备,2016,36(2):118-123.
CHEN Zhen, XIAO Xianyong, LI Changsong, et al. Power system transient stability assessment based on cost-sensitive extreme learning machine[J]. Electric Power Automation Equipment, 2016, 36(2):118-123.
- [16] WANG H Y, CHEN Q F, Zhang B H. Transient stability assessment combined model framework based on cost-sensitive method[J]. IET Generation, Transmission &

- Distribution, 2020, 14(12): 2256–2262.
- [17]王怀远,陈启凡.基于代价敏感堆叠变分自动编码器的暂态稳定评估方法[J].中国电机工程学报,2020,40(7):2213–2220.
- WANG Haiyuan, CHEN Qifan. A transient stability assessment method based on cost-sensitive stacked variational auto-encoder [J]. Proceedings of the CSEE, 2020, 40(7):2213–2220.
- [18]WANG H Y, WANG Q Y, CHEN Q F, et al. Transient stability assessment model with improved cost-sensitive method based on the fault severity [J]. IET Generation, Transmission & Distribution, 2020, 14(20): 4605–4611.
- [19]LI N, LI B L, HAN Y Q, et al. Dual cost-sensitivity factors-based power system transient stability assessment [J]. IET Generation, Transmission & Distribution, 2020, 14(24): 5858–5869.
- [20]ZHANG R, XU Y, DONG Z Y, 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.
- [21]TAN B D, YANG J, ZHOU T, et al. Spatial-temporal adaptive transient stability assessment for power system under missing data [J]. International Journal of Electrical Power and Energy Systems, 2020, 123, 106237.
- [22]SAUER P W, PAI M A. Power system dynamics and stability [M]. USA: Prentice Hall, 1998.
- [23]王莉丽,刘崇茹. DIgSILENT在电力系统稳定计算中的应用[J].中国科技论文,2016(11):1283–1287.
- WANG Lili, LIU Chongru. Application of DIgSILENT in power system stability calculation [J]. China Science Paper, 2016(11):1283–1287.
- [24]LAI G K, CHANG W C, YANG Y M, et al. Modeling long- and short-term temporal patterns with deep neural networks [C]//The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. SIGIR, 2018:95–104.
- [25]刘文慧,严博文,吴江,等.基于平行控制理论的循环流化床锅炉床温智能预测模型[J].综合智慧能源,2022,44(3):50–57.
- LIU Wenhui, YAN Bowen, WU Jiang, et al. Intelligent prediction model of CFB boiler bed temperature based on parallel control theory [J]. Integrated Intelligent Energy, 2022, 44(3): 50–57.
- [26]周挺,杨军,詹祥澎,等.一种数据驱动的暂态电压稳定评估方法及其可解释性研究[J].电网技术,2021,45(11):4416–4425.
- ZHOU Ting, YANG Jun, ZHAN Xiangpeng, et al. Data-driven method and interpretability analysis for transient voltage stability assessment [J]. Power System Technology, 2021, 45(11):4416–4425.
- [27]梁修锐,刘道伟,杨红英,等.数据驱动的电力系统静态电压稳定态势评估[J].电力建设,2020,41(1):126–132.
- LIANG Xiurui, LIU Daowei, YANG Hongying, et al. Data-driven situation assessment of power system static voltage stability [J]. Electric Power Construction, 2020, 41(1): 126–132.
- [28]孙黎霞,彭嘉杰,田屹昀,等.基于混合门控循环单元子层的多任务暂态稳定评估[J].电力建设,2022,43(2):63–69.
- SUN Lixia, PENG Jiajie, TIAN Yiyun, et al. Multi-task transient stability assessment based on sub-layer of hybrid gated recurrent unit [J]. Electric Power Construction, 2022,43(2):63–69.
- [29]郑真,朱峰,马小丽,等.基于TL-LSTM的新能源功率短期预测[J].综合智慧能源,2023,45(1):41–48.
- ZHENG Zhen, ZHU Feng, MA Xiaoli, et al. Short-term new energy power prediction based on TL-LSTM [J]. Integrated Intelligent Energy, 2023, 45(1): 41–48.
- [30]PAN S J, YANG Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10):1345–1359.

(本文责编:刘芳)

收稿日期:2023-04-25;修回日期:2023-06-28
 上网日期:2023-07-11;附录网址:www.ienergy.cn

作者简介:

杨波(1976),男,高级工程师,从事新能源、物联网、电气控制和电力通信等方面的研究,yangbo@ise.neu.edu.cn;

李成云(1998),女,在读博士研究生,从事电力系统数字孪生建模方面的研究,17367911495@163.com;

吕浩轩(1995),男,硕士,从事电力系统稳定性分析方面的研究,18641036168@163.com;

周博文(1987),男,副教授,硕士生导师,博士,从事电力系统运行、稳定与控制,电动汽车与电网互动,储能,需求响应,虚拟储能,可再生能源,能源互联网,人工智能与电力系统等方面的研究,zhou Bowen@ise.neu.edu.cn;

李广地(1989),男,讲师,博士,从事新能源并网发电、高频软开关技术等方面的研究,liguangdi@ise.neu.edu.cn;

谷鹏(1992),男,讲师,博士,从事综合能源系统、无线电能传输技术及其在电力系统中的应用、新型电力系统电磁暂态分析等方面的研究,gupeng@mail.neu.edu.cn。