

基于潮流嵌入和最小割池化的电网静态安全分析图学习模型

马遵¹, 李永哲², 何鑫¹, 管霖², 向川¹, 陈勇¹, 何伊慧²

(1. 云南电网有限责任公司电力科学研究院, 昆明 650217; 2. 华南理工大学电力学院, 广州 510640)

摘要: 运用数据驱动模型实现快速的电网静态安全分析是新型电力系统分析中值得探索的研究方向。提高数据驱动模型对运行方式变化的泛化能力和对电网拓扑变化的适应能力是关键技术挑战之一。提出了一种基于潮流嵌入和最小割池化的电网静态安全分析图学习模型。首先, 通过以复原节点电压为导向的潮流状态嵌入模块, 将电网 $N-1$ 方式的拓扑差异转化为节点特征差异, 改善了模型的泛化能力。其次, 运用社团划分思想, 采用最小割池化技术动态缩小了电网节点规模和节点特征维数, 使模型具备对拓扑变化的适应能力。通过在 IEEE 39 节点系统和 IEEE 118 节点系统的验证测试和可视化分析, 表明所设计的图深度学习模型准确率高, 具有秒级的评估速度以及对电网规模变化的良好适应能力。

关键词: 静态安全分析; 图深度学习; 掩模图自编码器; 潮流嵌入; 图池化; 拓扑变化适应性

Graph Learning Model of Power System Static Security Analysis Based on Power Flow Embedding and Min-Cut Pooling

MA Zun¹, LI Yongzhe², HE Xin¹, GUAN Lin², XIANG Chuan¹, CHEN Yong¹, HE Yihui²

(1. Electric Power Research Institute of Yunnan Power Grid Co., Ltd., Kunming 650217, China; 2. School of Electric Power Engineering, South China University of Technology, Guangzhou 510640, China)

Abstract: The application of data-driven models for rapid static security analysis in new power system is a research area worth exploring. Enhancing the generalization ability of data-driven models to operation condition changes and the adaptability to power system topology variations is one of the key technical challenges. A graph learning model for static security analysis of the power system based on power flow embedding and the min-cut pooling is proposed. At first, a power flow embedding module directed by the node voltage restoration is designed to improve the model's generalization ability, which converts the topological differences in $N-1$ contingency scenarios into node feature differences. Secondly, based on the concept of community partitioning, a min-cut pooling technology is employed to dynamically reduce node scale and node feature dimensions, which enables the model to adapt to topological changes. Verification tests and visualization analyses conducted on IEEE 39-bus and IEEE 118-bus systems demonstrate that the model can achieve high accuracy, second-level evaluation speed, and good adaptability to variation of the power grid scale and topology.

Key words: static security analysis; graph deep learning; masked graph auto-encoder; power flow embedding; graph pooling; adaptability to the topology variation

基金项目: 国家自然科学基金资助项目(52077080); 云南电网有限责任公司科技项目(056200KK52220044)。

Foundation item: Supported by the National Natural Science Foundation of China (52077080); the Science and Technology Project of Yunnan Power Grid Co., Ltd. (056200KK52220044).

0 引言

静态安全分析是电网运行调度中进行安全评估的基础环节^[1]。电网的线路故障往往会伴随着潮流的转移,导致故障点临近节点的电压变化以及故障线路所处断面的潮流增大。静态安全分析需要在电网发生故障时判断节点电压和支路潮流的越限风险,便于调度员轻松地识别出电网处于正常或者异常状态。目前,交流潮流计算及其加速算法^[2-5]是静态安全分析的唯一工具。随着风电、光伏等新能源发电在电网中的渗透率不断提高^[6-7],风光电源功率的强波动性和不确定性使得电网运行方式变化的幅度和频度不断增加。当需要分析的检修+故障方式组合超过“ $N-1$ ”要求时,叠加上新型电力系统运行场景数的骤增影响,基于交流潮流的静态安全分析技术在计算效率和算力方面将越来越难以支撑大电网运行分析的规模和效率要求。

电网运行中常态化开展的静态安全分析为数据驱动模型的训练提供了源源不断的样本。不再简单抛弃这些历史扫描计算结果,而是充分利用它们训练数据驱动的静态安全分析模型,可望逐步建立物理仿真+数据驱动相结合的电网分析模式,显著提升未来新型电力系统的安全分析效率,是一个值得探索的前沿技术方向。

机器学习(machine learning, ML)技术中,支持向量机(support vector machine, SVM)^[8]、人工神经网络(artificial neural network, ANN)^[9-10]等浅层模型较早被学者们应用于数据驱动的静态安全分析建模中,大幅度提升了评估速度。近年来,深度神经网络(deep neural network, DNN)^[11]、卷积神经网络(convolutional neural network, CNN)^[12]、自编码器(autoencoder, AE)^[13]等深度学习(deep learning, DL)模型在静态安全分析中的应用研究成果不断涌现。已有研究表明,面对特征维度更大的电网,DL模型较之浅层模型可以从样本数据中提取深层次的特征,增强了模型的表达能力和评估准确率。

从物理原理看,静态安全分析研究的是具有图结构的电网络中发生拓扑变化时功率流的再分配过程。电网的拓扑关系,包括图结构和支路阻抗参数分布是静态安全分析中的重要信息。传统的DL模型缺乏对图拓扑的有效特征提取机制,是影响静态

安全分析模型在线路检修和故障组合变化时泛化能力不足的主要原因之一。

图深度学习(graph deep learning, GDL)模型在节点特征的聚合中加入了对图结构的针对性特征提取机制,已在潮流计算^[14]、连锁故障仿真^[15]、暂态稳定分析等电力系统分析领域得到应用。文献[16]的研究表明,基于图卷积网络(graph convolution network, GCN)的SSA模型可以相对全面捕捉电网的图特征,在一定程度上提高了模型的泛化能力。数据驱动的静态安全分析模型要求以正常方式下的潮流信息为输入,评估各种给定检修和故障运行方式下的电网电压和潮流越限情况。模型设计的关键在于如何有效地引导GCN模型准确学习和捕捉电网拓扑变化对潮流分布的影响规律和特征。对此,本文提出了将GCN与自编码器相结合的设计思路以提升模型的泛化能力。

为提升节点规模变化时模型的适应能力,通常可以使用特征工程^[17]、迁移学习^[18-20]、图池化^[21]等方法。特征工程通常指对样本特征进行筛选和处理,选取有利于模型训练的特征作为模型输入。迁移学习^[22]是指当拓扑发生变化时,基于先前的模型和当前拓扑下的少量样本,通过修正模型参数实现模型的迁移。图池化技术^[23]指在模型训练和评估中,将样本节点规模缩小至一个固定值,当节点数量变化时,由于该固定值未发生变化,依旧可以正常地向下游网络进行映射。对于系统级的静态安全评估,图池化可以减少待分析的特征数量,固定的上游网络输出维度也使得模型在一定程度上可以适应节点规模变化。

本文在GDL模型中引入最小割池化(min-cut pooling)机制,提出了基于潮流状态嵌入和最小割池化的电网静态安全分析模型(SSA model based on power flow embedding and min-cut pooling, PFE-MinCut),可有效提升SSA模型的泛化能力和适应能力。潮流嵌入模块以掩模图自编码器(masked graph autoencoder, GraphMAE)为基础,将电网 $N-1$ 方式的拓扑差异转化为节点特征矩阵差异。最小割池化方法通过构造图层次池化模型,将系统节点规模缩小至固定值,使模型具备拓扑变化适应能力。在IEEE 39节点系统和IEEE 118节点系统中通过对比测试和可视化分析验证了模型的有效性。

1 SSA的图深度学习模型

1.1 SSA问题的数学模型

静态安全分析基于交流潮流方程, 通过逐一开断支路, 计算各个节点的电压和支路的有功潮流, 判断它们在电网 $N-1$ 方式下是否存在越限风险。潮流计算公式如式(1)所示。

$$\begin{cases} P_i = V_i \sum_j^{N_n} V_j [G_{ij} \cos(\delta_i - \delta_j) + B_{ij} \sin(\delta_i - \delta_j)] \\ Q_i = V_i \sum_j^{N_n} V_j [G_{ij} \sin(\delta_i - \delta_j) - B_{ij} \cos(\delta_i - \delta_j)] \end{cases} \quad (1)$$

式中: P_i 、 Q_i 、 V_i 、 δ_i 分别为节点 i 的注入有功功率、注入无功功率、电压幅值和电压相角; N_n 为电网的节点数量; $G_{ij} + jB_{ij}$ 为节点导纳矩阵中节点 i 和节点 j 对应位置导纳。根据各节点潮流计算结果, 各支路的有功潮流方程可以写为:

$$P_{ij} = [V_i^2 - V_i V_j \cos(\delta_i - \delta_j)] G_{ij} - V_i V_j \sin(\delta_i - \delta_j) B_{ij} \quad (2)$$

式中 P_{ij} 为节点 i 和节点 j 之间支路的有功功率。

根据上述数学模型, 设计基于 GDL 的 SSA 模型时, 以正常运行方式下电网的潮流定解条件和电网拓扑结构(以邻接矩阵描述)作为输入。

其中, 引入 GDL 的优势就在于电网 $N-1$ 拓扑变化可以通过邻接矩阵直接输入模型。考虑到支路的电导通常远小于电纳, 可选择支路的电纳 B_{ij} 作为邻接矩阵 A 的边权重, 以此来表示节点之间的连接强度。即输入 SSA 模型的邻接矩阵单元 A_{ij} 为:

$$A_{ij} = B_{ij} \quad (3)$$

SSA 模型的目标是判断某个方式下断开任一支路后($N-1$ 方式), 系统是否存在节点和支路越限问题。因此, 模型输入的节点信息只能包含已知的运行方式信息, 包括 PQ 节点的 P_i 和 Q_i ; PV 节点的 P_i 和 V_i ; 平衡节点的 V_i 和 δ_i 。

进一步分析可以看出, 尽管在图深度学习模型的输入中通过邻接矩阵可以体现 $N-1$ 开断关系, 但是对一个运行方式枚举分析不同支路 $N-1$ 开断时, 样本的节点特征矩阵通常相同, 样本之间的差异仅仅体现在输入邻接矩阵的差异上。本文提出的模型改进之一, 就是通过加入潮流嵌入模块获得更能体现拓扑变化影响的新节点特征, 提升模型性能。模块工作原理在第 2 节详细说明。

根据安全稳定准则^[24], 电网在 $N-1$ 故障下不应

存在潮流和电压越限风险。本文采用文献[25]中定义的安全风险指标 R_i 作为静态安全风险的评估判据, 并将图深度学习 SSA 模型设计为分类问题。

采用的静态安全风险指标公式如下。

$$R_i = \left[\sum_i^{N_n} (d_i^u)^{2n} + \sum_i^{N_n} (d_i^l)^{2n} + \sum_j^N (g_j)^{2n} \right]^{1/2n} \quad (4)$$

式中: d_i^u 为节点 i 的过电压风险; d_i^l 为节点 i 的低电压风险; g_j 为线路 j 的潮流越限风险; n 为形状参数; N 为支路数量。指标的详细计算过程可参考文献[25]。

进一步, 根据 R_i 对系统状态进行二分类: 1) $0 \leq R_i \leq 1$: 安全状态, 系统中不存在元件越限; 2) $R_i > 1$: 危险状态, 系统中存在越限元件。SSA 模型的输出为上述静态安全风险类别。

实际大电网中发生潮流/电压越限的 $N-1$ 场景占比往往很小。经过深度学习模型快速筛选出少量危险场景后, 安全分析系统可以进一步调用交流潮流计算程序对少量危险场景进行更精准地计算分析。通过深度学习模型地初筛和交流潮流地详细检测相配合可以较好地兼顾应用中的高效率和高精度要求。

1.2 SSA问题的图深度学习模型

本文提出的基于潮流状态嵌入和最小割池化的电网静态安全分析模型如图 1 所示, 模型可分为潮流状态嵌入模块、池化模块和下游网络 3 个部分。

潮流状态嵌入模块基于掩模自编码器模型对所有节点的电压幅值和相角进行嵌入计算, 即近似复原 $N-1$ 运行方式下各节点的电压幅值和相角。其功能不仅实现了不同类型节点的特征对齐, 也将不同 $N-1$ 扰动的邻接矩阵的差异嵌入到节点特征矩阵中, 提高模型对不同 $N-1$ 故障的分析精度。

第二阶段由池化层完成对节点间特征的聚合和变换。池化层的基本结构采用图卷积网络 GCN 和 MinCutPooling 池化层串联。其中, GCN 可以有效考虑节点的拓扑连接和电气联系(支路阻抗), 并体现在新特征的构造中。MinCutPooling 池化负责对 GCN 产生的节点新特征进行归并和降噪, 同时也将待评估系统的节点数量缩小到给定的规模。从而使设计的模型可以适用于规模不同的电网, 而不需要重新下游分类器设计, 增强了模型的泛化能力。

通过图自编码器、GCN 和 MinCutPooling 池化




图1 PFE-MinCut模型结构

Fig. 1 Structure of PFE-MinCut model

的分工合作，可以在特征聚合和特征变换中灵活考虑拓扑、电气距离和节点类型等的影响。即使系统中部分节点类型变化时，图自编码器和GCN的输出也可以响应这些变化，并通过特征的差异反映到电网静态安全评估结果中。

上述环节形成的最终特征向量将输入全连接层构成的下游分类器网络。下游网络完成预测任务，输出对静态安全风险的分类预测。

基于PFE-MinCut模型的校核框架如图2所示，共包括离线训练和在线评估两部分。离线训练部分从大量同节点规模的运行方式样本中经过筛选和归一化、z-score标准化等步骤后得到离线数据作为训练样本；对每个样本计算它们存在的静态安全风险类别作为样本标签；而后对PFE-MinCut进行离线训练。在线评估部分以与训练样本相同或相近节点规模的同一区域电网运行方式作为输入，PFE-MinCut可以判断每一个样本是否存在静态安全风险，若存在风险，则可以通过交流潮流校核对风险进行更精确的分析，而后通过调整发电机启停以及无功补偿等操作消除风险。




图2 基于PFE-MinCut模型的分析框架

Fig. 2 Analyzing framework based on PFE-MinCut model




图3 GCN的卷积过程

Fig. 3 Convolution process of GCN

2 潮流状态嵌入模块

2.1 图卷积神经网络

图卷积神经网络^[26]是一种专门针对图数据进行特征提取的神经网络模型。如图3所示，GCN可以根据节点之间的拓扑连接关系将相邻节点的特征进行汇聚，增强了深度学习模型对图数据的表达能力。

GCN层的特征传播公式为：

$$f_{GCN}(\mathbf{h}, \hat{\mathbf{A}}) = \sigma(\hat{\mathbf{D}}^{-1/2} \hat{\mathbf{A}} \hat{\mathbf{D}}^{-1/2} \mathbf{h} \mathbf{W}) \quad (5)$$

式中： $f_{GCN}(\cdot)$ 为GCN的前馈函数； $\hat{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 为带自环的邻接矩阵； $\mathbf{A}$ 为邻接矩阵； $\mathbf{I}$ 为单位矩阵； $\hat{\mathbf{D}}$ 为与 $\hat{\mathbf{A}}$ 对应的度矩阵； $\mathbf{h}$ 为输入特征矩阵； $\mathbf{W}$ 为可学习的权重矩阵； $\sigma(\cdot)$ 为非线性激活函数。

2.2 潮流状态嵌入模块的设计

根据1.1节中样本输入特征的选取方法，基于GDL的SSA模型构建会存在以下两个问题：1) $N-1$

场景下每个节点的潮流解中, 有 2 个元素可根据正常方式潮流解确定, 而剩余 2 个元素需要经过交流潮流计算方可确定。2) 同一方式不同 $N-1$ 开断故障下, 样本节点特征矩阵相同, 容易造成池化模型的过拟合, 即对线路故障位置的泛化能力不足。因此, 潮流状态嵌入模块需要从电网节点特征和邻接矩阵中提取更深层次的特征来表示不同方式之间的潮流差异性。

本文使用掩模图自编码器(GraphMAE)^[27]对本节点的节点特征矩阵进行嵌入计算。嵌入计算根据 $N-1$ 样本交流潮流计算结果, 对节点特征矩阵中未知的节点电压和相角进行补全, 以编码器输出的高维特征作为节点特征的嵌入结果, 如图 4 所示。




图 4 潮流状态嵌入模块结构

Fig. 4 Structure of the embedding module in power flow

该模块使用掩码将未知的节点特征进行覆盖:

$$\begin{cases} X_i = X_{[M]} \\ X_i \text{ 未知} \\ X_i \in \{P_i, Q_i, V_i, \delta_i\} \end{cases} \quad (6)$$

式中: X_i 为节点 i 的电气量; $X_{[M]}$ 为对应电气量的可学习掩码值。

图自编码器根据经过掩码覆盖的节点特征矩阵和邻接矩阵对各节点的电压和相角进行拟合, 由于不同 $N-1$ 故障样本节点电压和相角存在明显差异, 而本文设计的图自编码器具有复杂的编码器和简单的解码器结构, 编码器可以得到充分的训练, 该差异可以在编码器输出中得以体现。因此, 在经过充分训练后编码器可以得到高维度且具备明显差异的节点嵌入特征。在线评估中由于无需解码器的输出结果, 解码器可直接丢弃。

3 PFE-MinCut 的训练和性能评估

3.1 MinCutPooling 的池化机制

为提高模型对不同节点规模电网的拓扑适应能

力, 需要使用图池化技术对电网进行社团划分, 将每个社团作为一个超级节点。当电网节点规模发生变化时, 超级节点数量不变, 特征发生改变, 从而使 SSA 模型具有拓扑适应能力。

在静态安全分析中, 社团的划分从以下两点出发: 1) 节点间特征相似性。当支路潮流较重时, 两端节点相角差较大, 体现为两端节点嵌入特征的差异较大, 池化模块需要识别这种嵌入特征差异, 将特征相似的节点划分至同一社团。2) 节点连接强度。节点间的连接强度体现于节点间的电气距离, 为使划分结果满足电网的社团特征, 需要将电气距离相近的节点划分为一个社团。

本文在 GCN 特征提取后使用 MinCutPooling^[28]对电网划分社团。如图 5 所示, 该池化层利用 MinCut 算子, 以节点间的连接强度和特征相似度为划分依据, 将部分节点聚合为一个社团, 形成超级节点。




图 5 Min-Cut pooling 的池化机制

Fig. 5 Pooling mechanism of Min-Cut pooling

针对上述问题, 池化模块根据最大社团数量设定值, 结合邻接矩阵, 训练社团分配矩阵 S 决定每个节点的社团归属。在该方法中, 所有节点共用同一套划分策略, 不受节点数量的影响。

$$h' = f_{\text{GNN}}(h, \hat{A}) \quad (7)$$

$$S = f_{\text{MLP}}(h') \quad (8)$$

式中: $f_{\text{GNN}}(\cdot)$ 为 GNN 卷积层, 本文选取 GCN 层; $f_{\text{MLP}}(\cdot)$ 为全连接层; h' 为图卷积层到社团分配矩阵之间的中间节点特征矩阵; S 为社团分配矩阵, $S \in \mathbb{R}^{N_n \times N'_n}$; N'_n 为池化后节点数量; $\mathbb{R}$ 为矩阵维度表示符号。

社团对应的超级节点特征需要考虑到其内部每一个节点的影响。本文对同一个社团内节点特征进行求和得到超级节点特征。超级节点间的邻接矩阵可根据簇分配矩阵自适应生成。

$$h^p = S^T h' \quad (9)$$

$$\hat{A}^p = S^T \hat{A} S \quad (10)$$

式中 $\mathbf{h}^p$ 和 $\hat{\mathbf{A}}^p$ 分别为池化后超级节点特征矩阵和邻接矩阵。由于同一个社团内部连接强度较高, $\hat{\mathbf{A}}^p$ 的对角元素通常大幅度大于其余非对角元素, 导致训练中自循环过强, 不利于邻域信息的传播和聚合, 需要将对角线元素进行归零:

$$\mathbf{A}^p = \hat{\mathbf{A}}^p - \mathbf{I}_{N_n} \text{diag}(\hat{\mathbf{A}}^p) \quad (11)$$

式中: $\mathbf{A}^p$ 为池化后无自环的邻接矩阵; $\mathbf{I}_{N_n}$ 为 N_n 阶单位矩阵; $\text{diag}(\cdot)$ 为取对角元素操作。

在训练过程中, MinCutPooling 的最小割机制主要体现在损失函数的设计上, 模型通过最小化两项无监督损失函数来联合优化上述 GNN 和 MLP 模型的参数。

$$L_u = L_c + L_o = -\underbrace{\frac{\text{Tr}(\mathbf{S}^T \hat{\mathbf{A}} \mathbf{S})}{\text{Tr}(\mathbf{S}^T \hat{\mathbf{D}} \mathbf{S})}}_{L_c} + \underbrace{\left\| \frac{\mathbf{S}^T \mathbf{S}}{\|\mathbf{S}^T \mathbf{S}\|_F} - \frac{\mathbf{I}_N}{\sqrt{N_n}} \right\|_F}_{L_o} \quad (12)$$

式中: $\text{Tr}(\cdot)$ 为求矩阵的迹; $\|\cdot\|_F$ 为 Frobenius 范数; L_c 为社团分配损失函数; L_o 为正交损失项; L_u 为 MinCutPooling 评价社团划分效果的无监督损失函数。社团分配损失函数 L_c 对 min-cut 进行评估, 取值范围为 $[-1, 0]$ 。最小化 L_c 会使社团中各节点间具备尽可能强的连接关系。函数的分子表示社团内边权重之和, 分母表示社团内节点度数之和。当分子等于分母时, 损失函数可以取最小值 -1。然而 L_c 是一个非凸函数, 仅对 L_c 进行优化容易导致模型陷入局部极小点, 产生退化解, 比较典型的有: 1) 所有的节点被分给同一个社团, 此时池化结果等同于全局池化; 2) 每个节点以相同的概率分向所有的社团, 此时模型会同等看待所有的社团, 结果与全局池化几乎相同。

为了规避上述的退化解, 引入正交损失项 L_o 鼓励社团分配正交, 且不同的社团具有相似的大小。社团的正交是指不同节点的社团分配向量内积为 0, 即 $\langle \mathbf{S}_i, \mathbf{S}_j \rangle = 0$, 其中 $\mathbf{S}_i$ 和 $\mathbf{S}_j$ 分别为节点 i 和节点 j 的社团分配向量。由于 L_o 的取值范围为 $[0, 2]$, 所以两项损失函数可以直接进行求和, 无需进行缩放, 两者相互制衡优化社团分配结果。

3.2 损失函数

PFE-MinCut 训练过程中的损失函数 L 由潮流状态嵌入模块节点电压的有监督损失 L_n 、静态风险预

测的有监督损失 L_R 、MinCutPooling 评价社团划分效果的无监督损失 L_u 构成。其中 L_u^l 为第 l 层 min-cut pooling 的无监督损失函数。

$$L = L_n + L_R + \sum_l L_u^l \quad (13)$$

潮流状态嵌入模块节点电压的有监督损失使用 MSE Loss 进行衡量。

$$L_n = \frac{1}{2N_n B} \sum_{i=1}^{N_n} \sum_{b=1}^B [(\tilde{V}_{i,b} - V_{i,b})^2 + (\tilde{\delta}_{i,b} - \delta_{i,b})^2] \quad (14)$$

式中: B 为一个批量样本数量; b 为该批量中的第 b 个样本; $\tilde{V}_{i,b}$ 和 $\tilde{\delta}_{i,b}$ 分别为第 b 个样本第 i 个节点电压幅值和相角的预测值, $V_{i,b}$ 和 $\delta_{i,b}$ 为其实际值。

静态安全风险预测是一个二分类任务, 其有监督损失 L_R 使用 Cross Entropy Loss 衡量。

$$L_R = \frac{1}{B} \sum_{b=1}^B (r_s \log \tilde{r}_s + r_D \log \tilde{r}_D) \quad (15)$$

式中: r_s 和 r_D 分别为样本安全和危险的标签, 同一个样本两个标签仅有 1 个为 1, 其余为 0; $\tilde{r}_s$ 和 $\tilde{r}_D$ 分别为样本处于上述两个标签代表的状态的概率。

3.3 性能评估指标

为验证模型对静态风险分类任务的性能, 定义如表 1 所示的混淆矩阵表示模型对不同标签样本的评估性能。其中 T_N 、 F_N 、 F_P 和 T_P 分别为矩阵对应位置元素数量。

表 1 静态安全分析混淆矩阵

Tab. 1 Confusion matrix of SSA

评估标签	真实标签	
	危险	安全
危险	T_N	F_N
安全	F_P	T_P

根据统计和整理得到的一级指标, 定义二级指标准确率 A_{cc} 、漏判率 M_A 和误判率 F_A 。

$$A_{cc} = \frac{T_P + T_N}{T_P + F_P + F_N + T_N} \quad (16)$$

$$M_A = \frac{F_P}{T_N + F_P} \quad (17)$$

$$F_A = \frac{F_N}{T_P + F_N} \quad (18)$$

A_{cc} 反映模型整体的评估准确性, M_A 反映将危险样本判别为安全的比重, 由于在电网实际运行中将危险方式误判为安全对系统威胁较大, 所以 M_A 是需要重点关注的二级指标。三级指标 G_{mean} 可以兼顾危险样本和安全样本的预测准确率, 在评价模型

性能时也应关注该指标。

$$G_{\text{mean}} = \sqrt{\frac{T_p}{T_p + F_N} \times \frac{T_N}{T_N + F_p}} \quad (19)$$

4 算例分析

在 IEEE 39 节点系统对模型的性能进行测试。考虑新能源的接入, 将 IEEE 39 节点系统节点 31、节点 35 和节点 38 处的火电机组替换为额定功率为 550 MW、600 MW 和 800 MW 的风电场, 新能源渗透率为 31.38%。使用 PSD-PF 进行潮流计算并根据潮流结果生成所有样本标签。所提出的 PFE-MinCut 模型基于 Pytorch-Geometric 框架搭建。计算平台配置为: Intel(R) Core(TM) i7-13700KF 3.40 GHz CPU, 32GB RAM 和 NVIDIA GeForce RTX4070Ti 12 G。模型训练使用余弦退火算法动态调整学习率, 迭代 300 轮, 其中所有卷积和池化都使用稀疏计算方法。

在样本生成过程中采用 Weibull 分布对风速进行独立采样。同时, 在 120%~170% 之间, 以 5% 的步长调整系统的负荷水平, 等比例调整发电机出力使系统功率平衡。继而, 在每一个负荷水平下, 逐条断开支路获得若干 $N-1$ 方式样本, 丢弃其中产生孤岛和潮流不收敛的样本。采用上述方式, 共得到 17 079 个样本, 其中类别为危险的样本 7 345 个, 占比 43%。按 3:1:1 的比例将样本随机划分训练集、验证集和测试集。训练得到的模型参数如表 2 所示, 其中池化模块的输出节点数为模型可接受的最大社团划分数量。

4.1 算法性能对比实验

为对比验证 PFE-MinCut 模型性能, 选取了支持向量机 SVM、深度神经网络 DNN 和卷积神经网络 CNN 作为对照组, 在相同训练集、验证集、测试集、输入输出特征和训练策略下, 各方法性能如表 3 所示, 耗时表示测试集样本评估总耗时。

根据表 3 结果可以发现, PFE-MinCut 性能远高于其余 3 种模型。这是因为训练样本之间差异主要体现在邻接矩阵的不同, 也就是拓扑上的不同, SVM、DNN 和 CNN 无法针对电网的拓扑结构进行针对性的特征提取, 对不同 $N-1$ 拓扑下的样本难以区分, 导致了模型性能的不佳。而 PFE-MinCut 基于图卷积网络, 节点可以根据邻接矩阵从邻居节点聚合特征, 从而更新自己的特征, 对拓扑结构更加

表 2 PFE-MinCut 模型参数

Tab. 2 Parameters of PFE-MinCut model

模型	IEEE 39 节点系统	IEEE 118 节点系统
潮流复原模块(输入维度, 输出维度)		
GCN1	(4, 32)	(4, 32)
GCN2	(32, 64)	(32, 64)
GCN3	(64, 128)	(64, 128)
GCN4	(128, 32)	(128, 32)
FC	(32, 2)	(32, 2)
图池化模块(输入节点数量×输入维度, 输出节点数量×输出维度)		
GCN1	(39×128, 39×96)	(118×128, 118×96)
MinCutPooling1	(39×96, 20×96)	(118×96, 40×96)
GCN2	(20×96, 20×64)	(40×96, 40×64)
MinCutPooling2	(20×64, 10×64)	(40×64, 20×64)
GCN3	(10×64, 10×32)	(20×64, 20×32)

表 3 各算法性能对比结果

Tab. 3 Comparison results of performances of each algorithm

模型	$A_{cc}/\%$	$M_A/\%$	$F_A/\%$	$G_{\text{mean}}/\%$	耗时/s
SVM	89.91	13.67	7.31	89.45	1.12
DNN	89.98	13.14	7.73	89.53	0.51
CNN	89.84	15.07	6.36	89.18	0.62
PFE-MinCut	98.15	0.99	1.49	98.75	1.38

敏感, 可以敏锐地发现不同样本拓扑之间的差异并将其表达出来, 所以性能远高于其余 3 种模型。

在评估速度方面, PFE-MinCut 评估耗时虽然高于其余模型, 但考虑到测试集共有 3 146 个样本, 平均每个样本评估耗时约为 $4.38 \times 10^{-4} \text{s}$, 远快于交流潮流计算, 符合在线应用的需求。

4.2 潮流状态嵌入模块性能验证

为充分验证潮流状态嵌入模块对节点特征的嵌入性能, 按照如下方法生成潮流状态嵌入模块测试集: 在 120%~170% 之间以 5% 的步长调整系统的负荷水平, 等比例调整发电机出力使系统功率平衡, 保持所有发电机和负荷不变, 考虑每一条支路的 $N-1$ 开断, 共生成 11 个负荷水平下共 381 个样本。使用欧几里得相似度和点积相似度对该模块输入和输出之间的差异度进行衡量。

$$\omega_e = \frac{1}{N_L} \sum_i \left(\frac{1}{N_{i,B}(N_{i,B} - 1)} \sum_{j \neq k}^{N_{i,B}} \frac{1}{1 + \|\mathbf{h}^{(j)} - \mathbf{h}^{(k)}\|_F} \right) \quad (20)$$

$$\omega_d = \frac{1}{N_L} \sum_i \left(\frac{1}{N_{i,B}(N_{i,B} - 1)} \sum_{j \neq k}^{N_{i,B}} \frac{\mathbf{h}^{(j)} \cdot \mathbf{h}^{(k)}}{\|\mathbf{h}^{(j)}\|_F \|\mathbf{h}^{(k)}\|_F} \right) \quad (21)$$

式中： ω_e 和 ω_d 分别为欧几里得相似度和点积相似度； N_L 为负荷水平数量； $N_{i,B}$ 为第 i 个负荷水平下样本总数量； $\mathbf{h}^{(j)}$ 和 $\mathbf{h}^{(k)}$ 分别为第 j 和第 k 个样本的节点特征矩阵；“ $\cdot$ ”为点积运算。

从表4中可以看出，在输入编码器前，每一个负荷水平下节点特征完全相同，相似度指标均为1，经过编码器处理后，由于不同样本节点电压幅值和相角不同，样本间节点特征的相似度明显缩小。

表4 编码器输入与输出节点特征相似度

Tab. 4 Node feature similarity of encoder input and output

相似度指标	输入特征	输出特征
ω_e	1.00	0.03
ω_d	1.00	0.91

为更直观地展示模型性能，使用tSNE将编码器输入和输出特征进行降维，绘制于散点图中，如图6所示。可以发现，输入节点特征在图中仅可以表示为11个点，代表11个不同的负荷水平，经过编码器处理后，输出节点特征差异度显著增大，在图6中有明显的区分。




图6 编码器输入与输出特征分布

Fig. 6 Features distribution of encoder inputs and outputs

4.3 池化模块消融实验

为验证MinCutPooling与其余图池化方法相比的性能，设置如下2个消融实验对照组。

PFE-Global：全局池化对照组。将MinCutPooling全部删除，在每一层GCN后使用最大平均池化获取全局特征。由于模型具有3层GCN，需进行3次最大平均池化，将3次池化结果拼接输向下游网络，下游网络特征维度也根据池化输出进行调整。

PFE-Diff：DiffPool^[23]对照组。DiffPool与MinCutPooling同属于节点合并类图池化方法，输入和输出具有相同的结构，可以直接将模型中所有MinCutPooling替换为DiffPool，其余结构保持不

变。与MinCutPooling相比，DiffPool不具备考虑最小割机制的无监督损失函数。

表5记录了PFE-MinCut和两种消融模型的性能，相比其余两种池化方法，全局池化模型性能最差，这是因为在全局池化过程中，完全没有考虑到电网的拓扑结构，直接将所有节点缩小为一个超级节点，超级节点上汇集了所有节点的特征，造成了较大的特征损失。PFE-Diff在池化中未考虑到节点间的连接强度，相比于PFE-MinCut对电网的社团结构考虑不足，所以性能较差。

表5 消融模型性能对比

Tab. 5 Performances comparison of ablation models %

模型	A_{cc}	M_A	F_A	G_{mean}
PFE-Global	97.66	1.63	2.64	97.86
PFE-Diff	97.82	1.98	2.12	97.95
PFE-MinCut	98.15	0.99	1.49	98.75

4.4 拓扑变化适应性实验

上述模型的测试集均基于 $N-1$ 拓扑，为验证模型对拓扑变化的适应能力，生成 N_n-2 、 N_n-1 （删除一个节点）和 N_n+1 （增加一个节点）样本集，每个样本集包含样本约4000个，其中危险样本数均大于1000。

表6记录了在不更新模型参数的前提下，3种池化模型的泛化性能结果，PFE-MinCut均具备最佳的性能。在 N_n-2 样本集下，PFE-Global的性能接近于PFE-Diff，这是因为在节点数量不变的电网拓扑中，由于GNN考虑拓扑连接的卷积机制，可以发现这种边数量的改变，所以两者性能接近。然而当节点数量发生变化时，GlobalPool池化过程中造成了过多的信息损失，对节点数量变化的识别不够明显，所以性能明显低于两种层次池化模型。PFE-MinCut的池化过程更加契合电网的社团结构，且池化中信息损失少，同一社团内节点特征相近，所以PFE-MinCut在泛化实验中具备最佳的性能。

4.5 池化过程可视化分析

为清晰直观地展示池化过程中节点社团的划分效果，选取某运行方式，将该方式及其在线路4-14故障场景下部分节点社团的划分结果进行可视化，结果如图7所示，图7中除灰色外，每一种颜色代表了一个社团。在初始运行方式下，该样本处于安全状态，当线路4-14故障后，节点14向节点4的输


表 6 不同拓扑下模型性能对比

Tab. 6 Models performances comparison in different

样本集	模型	topographies				%
		A_{cc}	M_A	F_A	G_{mean}	
N_n-2	PFE-Global	95.77	3.46	4.51	96.01	
	PFE-Diff	95.86	3.99	4.38	95.81	
	PFE-MinCut	97.64	1.55	2.94	97.75	
N_n-1	PFE-Global	95.28	6.34	8.91	92.37	
	PFE-Diff	97.16	3.81	3.94	96.12	
	PFE-MinCut	97.69	2.02	4.12	96.92	
N_n+1	PFE-Global	94.28	5.01	6.35	94.32	
	PFE-Diff	95.71	4.82	5.26	94.96	
	PFE-MinCut	97.23	2.41	4.03	96.78	

电路受阻, 潮流向其线路发生了转移, 造成线路的过载, 故障样本处于危险状态。

从图7可以看出, 在初始运行方式下, 模型将节点4和节点14划分到同一个社团, 而在故障方式下划分到了不同社团中, 即模型具备 $N-1$ 故障位置的感知能力。此外, 从图7中也可以看出, 故障前后除故障线路临近节点外, 其余节点的社团划分结果基本保持不变, 所以模型对 $N-1$ 场景的社团划分具有稳定性。

图7 $N-1$ 故障对社团划分影响可视化结果Fig. 7 Visual results of the impact of $N-1$ faults on cluster division

为进一步验证模型在节点规模变化时能够实现较高精度预测的本质, 在 $N-1$ 故障的基础上分别增加和删去一个节点, 对模型的池化过程进行可视化分析。

图8可视化了当线路1-39故障时删除节点30及

其所连支路前后社团划分结果, 可以看出, 节点删除前后社团划分结果基本相同。在该方式删除节点30后系统的有功缺额大部分由节点37承担, 造成了线路2-25的负载严重加重, 使系统处于危险状态。节点2和节点25由于相角差增大, 经过潮流状态嵌入模块提取的高维特征差异也相应增大, 造成池化模块将它们从同一社团中分离。




图8 删除节点30前后社团可视化结果

Fig. 8 Visual results of cluster before and after the deletion of node 30

图9可视化了当线路23-24故障后, 在节点16处增加新的发电机节点40前后社团可视化结果, 同样可以发现节点增加前后社团划分结果相同, 与图8结果相结合, 可证明模型在节点数量变化时社团划分结果依旧具备稳定性。当线路23-24故障后, 潮流大量向线路21-22转移, 造成该线路的过载, 增加节点40后, 相对应减少节点36的出力, 将线路21-22的负载率控制在安全的范围内。节点40的增加和节点36的出力减少会引起节点所在社团特征发生变化, 经过图自编码器和GCN的传播和聚合, 特征的变化也导致模型输出由危险转为安全。




图9 增加节点40前后社团可视化结果

Fig. 9 Visual results of cluster before and after the addition of node 40

4.6 大系统算例分析

在IEEE 118系统中对模型的性能进行测试分析。将该系统进行改进使新能源渗透率达到34.73%。按照与IEEE 39节点系统相同的方式生成

样本, 得到 15 858 个收敛样本, 其中危险样本 3 102 个, 安全样本 12 756 个。经过多次训练, 得到该系统最优参数设置如表 2 所示。

4.6.1 模型的性能验证

将 PFE-MinCut 与 4.1 节中 3 种非图学习模型和 4.3 节中 2 种池化消融模型进行比较, 结果如表 7 所示。PFE-MinCut 在测试集具备最优的性能, 这是因为模型在池化过程中考虑到了电网节点间存在的社团结构, 特征损失较小。

表 7 不同模型在 IEEE 118 系统上的性能

Tab. 7 Performances of different models on IEEE 118 system

模型	$A_{cc}/\%$	$M_A/\%$	$F_A/\%$	$G_{mean}/\%$	耗时/s
SVM	86.96	28.52	9.19	80.57	2.97
DNN	90.29	43.29	9.13	71.78	0.52
CNN	92.46	19.63	8.54	85.74	0.61
PFE-Global	96.15	2.16	3.21	97.31	1.66
PFE-Diff	96.90	2.32	3.84	96.92	1.75
PFE-MinCut	98.36	0.86	2.11	98.51	1.83

4.6.2 模型拓扑泛化能力验证

根据初始运行方式生成 N_n-2 、 N_n-1 和 N_n+1 样本集, 在不更新模型参数的前提下将模型用于上述样本集进行拓扑泛化能力测试, 结果如表 8 所示, 尽管系统规模扩大, 但 PFE-MinCut 依旧保持着对拓扑变化优异的泛化能力。

表 8 不同拓扑下模型在 IEEE 118 系统上的性能对比

Tab. 8 Performance comparison in different topographies on

IEEE 118 system

样本集	模型	A_{cc}	M_A	F_A	G_{mean}
N_n-2	PFE-Global	94.65	3.52	4.98	95.75
	PFE-Diff	95.84	3.67	4.82	95.75
	PFE-MinCut	97.22	1.86	3.54	97.30
N_n-1	PFE-Global	92.53	5.87	7.66	93.23
	PFE-Diff	95.14	3.88	5.71	95.20
	PFE-MinCut	96.84	2.08	4.55	96.67
N_n+1	PFE-Global	94.15	4.08	5.41	95.25
	PFE-Diff	96.01	2.94	4.73	96.16
	PFE-MinCut	97.02	2.13	3.85	97.01

4.7 模型的评估速度验证

本节在 IEEE 39 和 IEEE 118 节点系统的测试集中, 将 PFE-MinCut 的评估耗时与通过 Python 调用 PSD-PF 进行交流潮流计算的耗时进行对比, 结果如表 9 所示。

表 9 评估耗时对比

Tab. 9 Comparison of evaluation time

系统	PFE-MinCut/s	PSD-PF/s	提速比
IEEE 39	1.38	132.13	95.75
IEEE 118	1.83	171.27	93.53

相比 PSD-PF, 本文提出的模型在 IEEE 39 和 IEEE 118 节点系统中分别具有 95.75 和 93.53 的提速比, 同时也分别具有 98.15% 和 98.36% 的预测准确率, 测试表明本文所提方法具有准确率高和秒级评估速度的优势。

5 结论

随着电网规模的扩大和新能源占比的提高, 静态安全分析需要适应不同运行方式下电网拓扑变化且具备秒级的评估能力。针对该问题, 本文基于潮流嵌入和最小割池化提出了可适应拓扑变化的电力系统静态安全分析模型, 经过详细的推导和验证, 得到如下结论。

1) GDL 模型可以准确地把握节点之间的连接关系, 充分提取电网图结构中的信息; 本文提出的 PFE-MinCut 模型在静态安全分析中具有高准确率、高评估速度的特点, 符合对 SSA 模型的需求。

2) 基于 Min-Cut Pooling 的池化模型可以结合电网的社团结构, 将特征相似、联系紧密的节点划分至同一个社团中, 符合电网的实际拓扑结构, 且多社团的划分使节点信息损失小。

3) 在拓扑结构发生变化时, PFE-MinCut 模型适应拓扑的变化, 在新场景中依旧具备可观的性能。

需要特别说明的是, 实际电网在部分线路检修、潮流较重、电压偏移较大的情况下常常存在“N-1”潮流计算不收敛的情况。这些方式往往也是运行中需要重点关注的安全水平最差的方式和故障。本文在生成数据驱动模型的训练样本时, 因不收敛的潮流无法提供样本标签, 仅采用了简单丢弃不收敛样本的做法, 这可能使训练的模型漏掉不安全的 N-1 故障。模型后续研究中需要重点关注潮流不收敛场景, 改进数据驱动模型设计。可行的方案包括但不限于人工介入不收敛方式的标注、增加对不收敛方式的测试等, 训练数据驱动模型更有效地识别这类值得关注的方式和扰动。

参考文献

- [1] 冯永青,李鹏,梁寿愚. 大规模交直流混联电网在线静态安全分析[J]. 南方电网技术,2010,4(3):12-16.
FENG Yongqing, LI Peng, LIANG Shouyu. Online static security analysis of large-scale hybrid ac-dc interconnected system[J]. Southern Power System Technology, 2010, 4(3): 12-16.
- [2] KAPLUNOVICH P, TURITSYN K. Fast and reliable screening of $N-2$ contingencies [J]. IEEE Transactions on Power Systems, 2016, 31(6):1-10.
- [3] MAJIDI-QADIKOLAI M, BALDICK R. Stochastic transmission capacity expansion planning with special scenario selection for integrating $N-1$ contingency analysis [J]. IEEE Transactions on Power Systems, 2016, 31(6):4901-4912.
- [4] 唐坤杰,董树锋,宋永华. 一种GPU-CPU异构运算框架加速的实时 $N-1$ 交流潮流计算方法[J]. 中国电机工程学报, 2018, 38(15):4329-4338, 4633.
TANG Kunjie, DONG Shufeng, SONG Yonghua. A real-time $N-1$ ac power flow calculation method based on GPU-CPU heterogeneous computing framework [J]. Proceedings of the CSEE, 2018, 38(15):4329-4338, 4633.
- [5] FU M, ZHOU G, ZHAO J, et al. GPU-based $N-1$ static security analysis algorithm with preconditioned conjugate gradient method [J]. IEEE Access, 2020(8):124066-124075.
- [6] 郑外生,陈亦平,周保荣. 云南新型电力系统运行控制体系的构想[J]. 南方电网技术, 2022, 16(9):83-89.
ZHENG Waisheng, CHEN Yiping, ZHOU Baorong. Concept of operation and control system on yunnan new power system [J]. Southern Power System Technology, 2022, 16(9): 83-89.
- [7] 赵玉林,李若瑾,尹杰,等. 考虑新能源不确定性的含DSSC电网静态电压稳定分析[J]. 南方电网技术, 2024, 18(7):95-107.
ZHAO Yulin, LI Ruojin, YIN Jie, et al. Static voltage stability analysis of power grid with DSSC considering uncertainty of new energy sources [J]. Southern Power System Technology, 2024, 18(7):95-107.
- [8] DHANDHIA A, PANDYA V, BHATT P. Multi-class support vector machines for static security assessment of power system [J]. Ain Shams Engineering Journal, 2020, 11(1):57-65.
- [9] SUNITHA R, KUMAR S K, MATHEW A T. Online static security assessment module using artificial neural networks [J]. IEEE Transactions on Power Systems, 2013, 28(4):4328-4335.
- [10] SEKHAR P, MOHANTY S. An online power system static security assessment module using multi-layer perceptron and radial basis function network [J]. International Journal of Electrical Power & Energy Systems, 2016(76):165-173.
- [11] 杨燕,杨知方,余娟,等. 基于深度学习的含不确定性 $N-1$ 安全校核方法[J]. 中国电机工程学报, 2021, 41(8):2716-2725.
YANG Yan, YANG Zhifang, YU Juan, et al. Fast analysis of $N-1$ contingency screening with uncertainty scenarios based on deep learning [J]. Proceedings of the CSEE, 2021, 41(8): 2716-2725.
- [12] DU Y, LI F F, LI J, et al. Achieving 100x acceleration for $N-1$ contingency screening with uncertain scenarios using deep convolutional neural network [J]. IEEE Transactions on Power Systems, 2019, 34(4):3303-3305.
- [13] YANG H, QIU R C, TONG H. Reconstruction residuals based long-term voltage stability assessment using autoencoders [J]. Journal of Modern Power Systems and Clean Energy, 2020, 8(6):1092-1103.
- [14] 李骥皓,梁志坚,刘敏,等. 基于图多任务学习的潮流分析模型[J]. 南方电网技术, 2023, 17(11):33-40.
LI Shenhao, LIANG Zhijian, LIU Min, et al. The trend analysis model based on graph multitasking study [J]. Southern Power System Technology, 2023, 17(11):33-40.
- [15] LIU Y, ZHANG N, WU D, et al. Searching for critical power system cascading failures with graph convolutional network [J]. IEEE Transactions on Control of Network Systems, 2021, 8(3):1304-1313.
- [16] 杨梅,刘俊勇,刘挺坚,等. 节点图和边图切换卷积驱动的快速静态安全分析方法[J]. 电网技术, 2021, 45(6):2070-2080.
YANG Mei, LIU Junyong, LIU Tingjian, et al. Switching convolution of node graph and line graph-driven method for fast static security analysis [J]. Power System Technology, 2021, 45(6):2070-2080.
- [17] 姜新雄,徐箭,廖思阳,等. 基于增强进化计算的电力系统暂态稳定关键特征智能选择方法[J]. 中国电机工程学报, 2023, 43(14):5358-5372.
JIANG Xinxiong, XU Jian, LIAO Siyang, et al. Intelligent selection method for key features of transient stability of power system based on enhanced evolutionary computing [J]. Proceedings of the CSEE, 2023, 43(14):5358-5372.
- [18] 陈灏颖,管霖. 基于主动迁移学习的电力系统拓扑自适应暂态稳定评估[J]. 中国电机工程学报, 2023, 43(19):7409-7423.
CHEN Haoying, GUAN Lin. Adaptive transient stability evaluation of power system topology based on active transfer learning [J]. Proceedings of the CSEE, 2023, 43(19):7409-7423.
- [19] 赵晨浩,焦在滨,李程昊,等. 基于主动迁移学习的电力系统暂态稳定自适应评估[J/OL]. 中国电力, 1-10[2025-01-03]. <http://kns.cnki.net/kcms/detail/11.3265.TM.20240617.1540.003.html>.
ZHAO Chenhao, JIAO Zaibin, LI Chenghao, et al. Adaptive assessment of power system transient stability based on active transfer learning [J/OL]. Electric Power, 1-10[2025-01-03]. <http://kns.cnki.net/kcms/detail/11.3265.TM.20240617.1540.003.html>.
- [20] REN C, XU Y, DAI B, et al. An integrated transfer learning method for power system dynamic security assessment of unlearned faults with missing data [J]. IEEE Transactions on Power Systems, 2021, 36(5):4856-4859.
- [21] HUANG J, GUAN L, SU Y, et al. System-scale-free transient contingency screening scheme based on steady-state information: a pooling-ensemble multi-graph learning approach [J]. IEEE Transactions on Power Systems, 2021, 37(1):294-305.
- [22] PAN S J, YANG Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10):1345-1359.

(下转第92页 Continued on Page 92)