

DOI: 10.19783/j.cnki.pspc.250588

基于改进 GCN-Transformer 的电力系统脆弱性节点辨识

刘伟^{1,2}, 梁悦帅²

(1. 东北石油大学三亚海洋油气研究院, 海南 三亚 572000; 2. 东北石油大学电气信息工程学院, 黑龙江 大庆 163000)

摘要: 随着电力系统规模不断扩大和新能源接入比例增加, 电网结构日趋复杂。局部节点故障易引发电网连锁失效, 对系统安全构成严重威胁。因此, 预先识别电网中的脆弱性节点并加以保护对保障电网的安全运行至关重要。为实现脆弱性节点的高效辨识, 提出一种改进融合图卷积网络与 Transformer 架构(graph convolutional network-Transformer, GCN-Transformer)的脆弱性节点辨识方法。首先, 结合复杂网络理论和改进信息熵-K 壳算法构建节点脆弱性评价指标集。其次, 引入基于 Chebyshev 多项式的 Kolmogorov-Arnold 网络(Chebyshev Kolmogorov-Arnold network, Cheb-KAN)作为图卷积网络(graph convolutional networks, GCN)的前置支路特征提取模块, 优化 GCN 的节点特征提取在不同支路间的传播效果。同时, 将改进 GCN 提取的特征输入至融合了多模态交叉注意力机制(multimodal cross-attention mechanism, MCA)的 Transformer 中, 用以捕获不同模态特征间的全局关联关系, 构建面向脆弱节点辨识的深度学习模型。然后, 基于 IEEE39 节点构建多种工况运行场景, 建立模型训练的原始数据集。最后, 在原始数据集上对所提模型进行训练与评估。结果表明, 该方法在脆弱节点辨识准确率方面显著优于传统图网络模型, 具备良好的可行性及其在电网实际场景中的工程应用潜力。

关键词: 脆弱性节点; 脆弱性评价指标; 改进 GCN-Transformer; Cheb-KAN; 多模态交叉注意力; 节点辨识

Power system vulnerability node identification based on improved GCN-Transformer

LIU Wei^{1,2}, LIANG Yueshuai²

(1. NEPU Sanya Offshore Oil&Gas Research Institute, Sanya 572000, China; 2. School of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163000, China)

Abstract: With the continuous expansion of power systems and the growing penetration of renewable energy, modern power grids have become increasingly complex. Local node failures can easily trigger cascading outages, posing serious threats to system security. Therefore, proactively identifying vulnerable nodes and implementing targeted protection measures is crucial for ensuring safe grid operation. To achieve efficient vulnerable node identification, an improved graph convolutional network-Transformer (GCN-Transformer) method is proposed. First, a set of node vulnerability evaluation indicators is constructed by integrating complex network theory with an improved information entropy-K-shell algorithm. Second, a Chebyshev polynomial-based Kolmogorov-Arnold Network (Cheb-KAN) is introduced as a front-end branch feature extraction module for the graph convolutional network (GCN), enhancing the propagation effectiveness of node feature extraction across different branches. The features extracted by the improved GCN are then fed into a Transformer integrated with a multimodal cross-attention (MCA) mechanism to capture global correlations among different modal features, thereby establishing a deep learning model for vulnerable node identification. Subsequently, multiple operating scenarios are constructed based on the IEEE 39-bus system to build the original dataset for model training. Finally, the proposed model is trained and evaluated on this dataset. Results demonstrate that the proposed method significantly outperforms traditional graph network models in terms of identification accuracy, showing strong feasibility and promising engineering application potential in practical power grid scenarios.

This work is supported by the National Natural Science Foundation of China (No. 62473096).

Key words: vulnerable node; vulnerability evaluation index; improved GCN-Transformer; Cheb-KAN; multimodal cross-attention; node identification

0 引言

随着电力系统的不断发展, 电网规模日益扩大。

以水能、风能为代表的新能源在电力系统中的占比持续提升。然而, 大规模新能源供电普及也面临着一些问题, 包括分布式新能源网络控制难度高造成的线路过载以及可再生能源不稳定出力引起的输电线路保护装置误动、拒动^[1]等问题。同时, 大电网的复

基金项目: 国家自然科学基金项目资助(62473096)

杂度和不确定性特点使其可能因自然灾害、变电站操作机构故障等问题,导致部分关键脆弱性节点故障下线,最终引发整个电网的级联故障甚至瘫痪解列,给国民经济造成较大损失。快速准确地预判存在于大电网中的脆弱性节点、保证电力系统可靠安全运行对目前的电网发展具有积极意义。

电力网络的脆弱性概念由 Fouad 等提出^[2],随后基于复杂网络理论的电网脆弱性研究迅速发展。复杂网络理论从拓扑结构角度观察系统中节点的相互关联关系,同时以网络形式分析系统整体动态特性,具有计算效率高、系统运行机理符合度高的特点。基于复杂网络理论,文献[3]基于线路电抗构建了加权电网拓扑模型,并结合节点负荷平衡改进连锁故障演化模型,提出了一种新的电网脆弱性评价指标。该指标能够较好地反映电网对关键节点的依赖性,相较于传统拓扑模型在准确性上具有一定优势。但该研究主要侧重于整体层面的脆弱性分析,对局部电网的脆弱性特征考虑不足。文献[4]基于系统潮流分布和运行方式,提出线路潮流介数,克服了以往介数对节点间功率直接定义为最短路径传输和无方向性设定的弊端,并采用层次分析法验证此介数对关键线路的重要程度;文献[5]通过定义功率传输路径、功率加权传输距离等参数,经加权聚合生成脆弱性环节综合评价指标,使之符合电网潮流运行规律,进而实现脆弱性节点的识别。综上,目前对于脆弱性节点辨识的方法各有所长,但因模型复杂、计算+繁琐,且难以实现在线辨识等问题,存在一定的局限性^[6]。随着电网规模和复杂度的不断提升,亟需研究与发展更加高效、实时的脆弱性节点辨识方法。

随着人工智能技术的兴起和发展,深度学习算法在电力系统中的应用日益广泛。针对电网脆弱性节点的辨识问题,节点脆弱性不仅与其自身所带负荷轻重和所经功率潮流有关,还可通过节点在网络结构中的位置、节点与节点之间以及节点与边之间的邻接关系来反映^[7]。传统深度学习因不能准确关注到电力系统各个部分之间的拓扑关系,致使其在不同系统的泛化能力受限。近年来,图神经网络(graph neural network, GNN)作为深度神经网络(deep neural networks, DNNs)的衍生变体,凭借其强大的数据挖掘和特征表示能力,产生了多种组合优化模型^[8-9]。为将高效、便捷的卷积运算引入到图结构数据中,研究人员提出了图卷积网络(graph convolutional networks, GCN),该模型在非欧式空间数据处理任务中发展迅速,如节点分类、图分类、链路预测等^[10]。文献[11]提出了一种基于 GNN 的节点排序模型(graph neural networks-based node ranking model,

GNR),该模型能够仅依靠网络拓扑结构来快速且高效地对任意类型网络中的节点进行排序。为了提高 GCN 在邻域范围内对于节点信息聚合的准确性,图注意力网络(graph attention network, GAT)作为图卷积模型的一种典型变体,通过为图中不同邻居节点动态赋予不同的重要性权重,从而实现局部领域信息的有效聚合^[12]。

然而, GNN 仍存在部分缺陷。GNN 在特征传播过程中主要依赖局部邻居信息的重复聚合,随着网络层数的增加容易出现特征过平滑和表达能力下降的问题^[13],尤其在面对非线性强、结构复杂的图数据时,其建模能力受到显著限制。Kolmogorov-Arnold 网络(KAN)作为一种新型深度学习模型,凭借可解释的函数组合结构与强大的非线性建模能力,能够更精准地刻画节点间复杂的非线性映射关系,为 GNN 提供更具判别性的输入特征表示,提升其对图结构中隐含规律的学习能力。另一方面,传统 GCN 基于消息传递范式聚合局部特征,其表达能力受限于 W-L 同构层次,难以有效捕捉长距离依赖。针对这一问题,Transformer 因具备全局注意力机制,可直接建立远距离节点间的信息交互,从而缓解过平滑与过挤压问题。文献[14]提出的 GraphTrans 模型,通过 GNN 提取局部结构特征,引入无位置编码的 Transformer 模块以实现全图节点间的自注意力交互,从而更全面地捕获长距离依赖关系,显著提升了图表示学习与分类性能。

综上,本文依据现有研究成果,构建了基于改进 GCN-Transformer 的电力系统脆弱性节点辨识模型。主要创新点包括:引入基于 Chebyshev 多项式的 Kolmogorov-Arnold 网络(Chebyshev Kolmogorov-Arnold network, Cheb-KAN),用于提取图支路特征并加权输入至 GCN,为 GCN 更有效融合拓扑结构与节点物理属性提供支持,提升模型对弱连通区域的结构感知能力;将改进 GCN 所提取的节点特征输入基于多模态交叉注意力机制(multimodal cross-attention mechanism, MCA)的 Transformer 网络中,建立面向脆弱性节点辨识的深度学习模型。本文基于 IEEE39 节点系统构建多种工况场景作为模型训练的原始数据集,并在原始数据集上对所提模型进行训练与评估。辨识结果表明,所述方法具备可行性,在辨识准确率上优于传统模型,具有一定工程应用价值。

1 脆弱性节点评价指标的定义

1.1 节点潮流介数指标的建立

在电力系统实际运行中,由发电机至负荷的功

率传输具有显著的选择性特征。且电力网络是有向加权网络，线路上的潮流具有方向性。多向潮流叠加导致功率传输主要经由电网中的关键线路完成，而非均匀分布于所有线路。为准确描述这一特性，本文借鉴文献[4]思路，运用潮流追踪算法，建立线路潮流介数指标，用于评估各线路在功率传输网络中的承载作用。

$$F_{ij,vt} = \min(S_v, S_t) \frac{P_{ij}(v,t)}{P(v,t)} \quad (1)$$

$$F_{ij} = \sum_{v \in G_0} \sum_{t \in L_0} F_{ij,vt} \quad (2)$$

式中： G_0 为发电机节点集合； L_0 为所有负荷节点集合； S_v 和 S_t 分别为潮流运行过程中的电源出力和实际负荷； $P(v,t)$ 为发电机 v 到负荷 t 所传输的有功功率； $P_{ij}(v,t)$ 为发电机 v 到负荷 t 所传输的有功功率在线路 ij 上的分量，在数值上体现了不同发电-负荷节点对间功率传输方向的叠加，根据潮流追踪法^[15]，在顺序/逆序分配矩阵的基础上，分别对由发电机节点 v 到线路的潮流(顺流追踪)以及由流经线路的潮流中流向负荷节点 t 的部分(逆流追踪)进行计算，可求得 $P_{ij}(v,t)$ ； $F_{ij,vt}$ 为单一发电-负荷节点对 (v,t) 的线路潮流介数，用于量化其功率传输过程中线路 ij 的承载能力，对所有节点对间的 $F_{ij,vt}$ 求和得到线路潮流介数指标 F_{ij} ，其值越大，线路承载能力越强，线路越重要。

在此基础上，借鉴文献[16]中复杂网络理论节点出入度的思想，以线路潮流介数和潮流方向作为节点间连边的权重和方向，定义节点潮流介数指标 F_i 为

$$F_i = \frac{1}{N_i - 1} (\alpha F_{i_in} + \beta F_{i_out}) \quad (3)$$

$$F_{i_in} = \sum_{ij \in E_{i_in}} F_{ij} \quad (4)$$

$$F_{i_out} = \sum_{ij \in E_{i_out}} F_{ij} \quad (5)$$

$$\alpha = v_{i_in} / E \quad (6)$$

$$\beta = v_{i_out} / E \quad (7)$$

式中： N_i 为节点 i 的连边数； α 和 β 分别表示流入和流出节点 i 的连边数与网络总连边数 E 的比值； F_{i_in} 、 F_{i_out} 分别为节点潮流介数入度、出度，数值上表示为流入和流出节点 i 的连边潮流介数和，物理意义分别为节点 i 在网络潮流传输中，潮流汇入、馈出的重要程度，数值越高，节点在潮流汇入和馈出的关键性就越强； E_{i_in} 、 E_{i_out} 分别表示流入和流出节点 i 的连边集合； v_{i_in} 、 v_{i_out} 分别为 E_{i_in} 、 E_{i_out}

中包含的线路数量。最终经过加权运算得出节点潮流介数指标 F_i 的节点关键性表示如式(3)所示， F_i 越高，节点 i 在整个网络潮流传输的位置越关键，节点越重要。

1.2 节点拓扑指标的建立

在复杂电力网中，处于关键位置的节点有其具体特征：往往位于多条功率传输路径中，承担大量电力传输的中转任务；在电网中有大量其他节点与其相连，表现为具有较高的拓扑枢纽特征；对网络连通性具有重要影响，对电网全局的稳定运行起到关键作用。节点在电网中的关键地位在其发生故障时表现为脆弱性，这些节点陷入故障甚至下线可能会引发连锁反应，引起电网局部停电、电压波动甚至系统解列等严重后果，这里可以采用K-壳算法依据节点在网络中的位置判断节点重要性。

K-壳分解法^[17]通过迭代移除节点的方式对网络进行分层。K-壳分解法分层示例如图1所示。该方法的具体步骤如下：首先，从网络中移除所有度值最小的节点及其连接边；随后，在更新后的网络中重复这一过程，继续移除当前度值最小的节点；每次迭代中被移除的节点归为同一层级，并赋予其K壳值(K_s 值)，该值等于迭代的层数。这一过程持续进行，直到网络中不再存在可移除的节点为止。

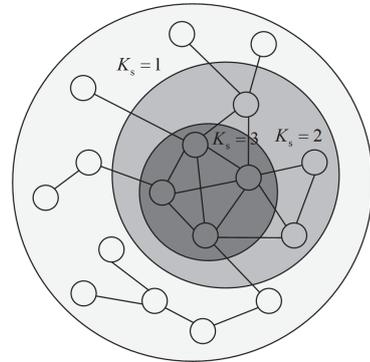


图1 K-壳分解法分层示例图

Fig. 1 Example of stratification of K-shell decomposition method

然而，K-壳分解法因其在划分出同一层节点时，无法更进一步得出每个节点具体的重要性程度而存在其局限性，故这里引入信息熵修正因子的改进K-壳算法^[18]来定义节点脆弱性的拓扑指标。

$$f_j = \frac{k_j}{\sum_{b \in \Gamma(i)} k_b} \quad (8)$$

$$E_i = - \sum_{j \in \Gamma(i)} f_j \cdot \ln f_j \quad (9)$$

$$E_{i+} = E_i \cdot K_{sj} \quad (10)$$

式中： k_j 为节点 i 的邻居节点 j 的度； $\Gamma(i)$ 为节点

i 的邻居节点集合; $\sum_{b \in \Gamma(i)} k_b$ 表示所有邻居节点的度之和; f_j 为节点 j 的度在节点 i 的所有邻居节点中的比例, 反映了节点 j 在节点 i 的邻居节点中的相对重要性; E_i 为节点 i 的信息熵; K_{sj} 为节点 j 的 K_s 值; E_{it} 为节点 i 的改进信息熵。

可以看出, 节点信息熵的计算主要依赖于节点的本地邻居信息; 改进信息熵 E_{it} 在 E_i 的基础上, 融合了邻居节点 j 的 K_s 值, 即与节点在网络中的位置信息相结合, 能通过全局更加清晰地区分节点的重要性程度。

1.3 节点脆弱性综合评价指标

综合考虑拓扑结构特性以及系统运行特性的影响, 本文提出节点脆弱性综合评价指标, 基于改进的熵权法^[19]建立上述两个评价指标的相应权重, 具体步骤如下。

1) 对于一个拥有 c 个节点的电网系统, 建立 g 个评价指标, 其原始矩阵 U_o 为

$$U_o = \begin{bmatrix} u_{11} & \cdots & u_{1e} & \cdots & u_{1g} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ u_{d1} & & u_{de} & & u_{dg} \\ \vdots & & \vdots & \ddots & \vdots \\ u_{c1} & \cdots & u_{ce} & \cdots & u_{cg} \end{bmatrix} \quad (11)$$

这里指定 u_{de} 为第 d 个评价节点在第 e 个脆弱性指标上的指标值。

2) 定义第 e 个脆弱性指标的熵: 对原始矩阵中两种指标归一化为 $R = (r_{de})_{c \times g}$, 得熵值 H_e 为

$$H_e = -C_o \sum_{d=1}^c u_{de} \ln u_{de}, d=1,2,3,\dots,c \quad (12)$$

式中: $u_{de} = r_{de} / \sum_{d=1}^c r_{de}$, r_{de} 是对原始指标数据做归一化处理后得到的数值, 用于消除量纲差异, 方便后续熵值计算。当 $u_{de} = 0$ 时, 令 $u_{de} \ln u_{de} = 0$; $C_o = 1/\ln c$ 。

3) 得到每项评价指标的熵后, 第 e 个脆弱性指标对应熵权 τ_e 定义为

$$\tau_e = \frac{1 - H_e}{g - \sum_{e=1}^g H_e} \quad (13)$$

式中: $0 \leq \tau_e \leq 1$, $\sum_{e=1}^g \tau_e = 1$ 。

4) 节点脆弱性综合评价指标的建立

将归一化的节点潮流系数度指标和节点改进信息熵拓扑评价指标分别乘以相应的综合权重, 得到节点 i 脆弱性综合评价得分 ξ_i 为

$$\xi_i = \tau_1 \cdot F_i + \tau_2 \cdot E_{it} \quad (14)$$

节点的综合评价指标值越大, 表明当节点的运行状态发生变化时, 对系统潮流分布的影响越显著, 其邻近节点也更容易受到波及, 因此节点的脆弱性越高; 反之, 若该指标值较小, 则节点对系统潮流分布的影响较小, 其重要性也相对较低。IEEE39 节点系统的脆弱性排序得分如图 2 所示。

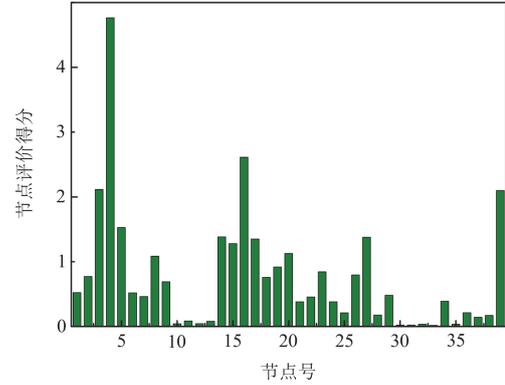


图 2 IEEE39 节点脆弱性综合评价得分

Fig. 2 Composite evaluation score of IEEE39-node vulnerability

2 传统脆弱性节点辨识模型理论基础

2.1 图卷积神经网络模型

图卷积神经网络(GCN)基于空间域特征提取策略, 通过在图数据节点邻域内执行卷积运算来捕捉局部拓扑结构。该方法的核心机制在于构建节点与邻域间的特征传播路径, 利用可学习的权重参数对邻接节点特征进行动态聚合, 最终实现多层次的特征表征学习。其计算过程在形式上与卷积神经网络(convolutional neural network, CNN)处理常规欧氏空间数据具有同源性: 通过逐层迭代的局部感受野操作, 既保持了 CNN 的平移不变性优势, 又能有效处理非欧式图结构数据中节点间的复杂空间关系。其卷积聚合机制^[20]为

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)} \right) \quad (15)$$

式中: $\tilde{A} = I_N + A$, I_N 为 N 阶单位阵, A 为拓扑图的邻接矩阵; \tilde{D} 为 \tilde{A} 的度矩阵; σ 为激活函数; $H^{(l)}$ 表示第 l 层的节点隐藏特征矩阵; $W^{(l)}$ 为第 l 层的可训练权重矩阵。传统 GCN 模型在进行邻接节点信息聚合时, 通常采用归一化的邻接矩阵进行传播, 其中边的权重被简化为 1, 从而忽略了不同支路在信息传递中的重要性差异。

2.2 KAN 网络模型

在传统多层感知机(multilayer perceptron, MLP)中, 神经元之间的连接通常是一个实数值, 代表连

接的强度或权重, 神经元本身则配有一个非线性的激活函数。相比之下, KAN 将可学习的激活函数放置在边缘权重上, 而在每个神经元上对各条连接的函数输出做简单求和, 实现对数据特征的“先变后加”, 增强了神经网络的表达能力和效率, 从而解决了 MLP 中参数冗余和计算负担过重问题。

Kolmogorov-Arnold 定理作为 KAN^[21]的理论基础, 其出现和在神经网络中的应用标志着一项重要的理论整合。该定理揭示了有界域上的任何平滑多变量连续函数都可以由一系列单变量连续函数的有限多项式组合精确表示。因此, KAN 模型可将任意一个高维函数的学习过程简化为学习单变量函数的多项式组合的形式, 双层 KAN 模型结构图如图 3 所示。

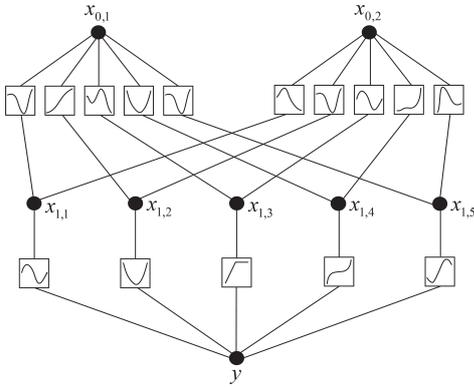


图 3 双层 KAN 模型结构图

Fig. 3 Structure of double layer KAN model

KAN 在各个边上均具有一个可学习的单变量激活函数 φ , 可以表示为基函数 $b(x)$ 加样条函数 $s(x)$ 的形式, 如式(16)所示。

$$\varphi = wb(x) + s(x) \quad (16)$$

式中: x 为输入特征; w 为 $b(x)$ 的可学习系数。

$b(x)$ 的加入相当于在 KAN 中考虑了残差连接, 这里采用 SiLU 函数作为基函数, 从而实现输入特征的平滑映射。

$$b(x) = \frac{x}{1 + e^{-x}} \quad (17)$$

样条函数(spline function)是传统 KAN 网络的核心数学基础, 它通过分段多项式在节点处满足特定连续性条件构建而成, 具有全局平滑特性。这种结构不仅能够高效逼近复杂函数, 而且其分段多项式组合形式在理论上具有精确逼近高维复杂函数的优势。以传统 B 样条函数(B-spline function)为例, 样条函数在数学上可表示为

$$s(x) = \sum_{r=1}^{D+J} c_r B_r(x) \quad (18)$$

式中: D 为 B-spline 定义的网格间隔数量; J 为样

条函数的分段多项式阶数; $B_r(x)$ 为具有局部支撑特性的规范基函数; c_r 为可训练系数。虽具有全局连续性优势, 但其固有平滑特性导致对高非线性突变特征的捕捉能力不足。同时, 单变量 B 样条的参数数量会随输入维度呈线性增长, 导致模型复杂度剧增、训练效率骤降, 严重制约了其在大规模高维场景的应用潜力。

综上, 单层 KAN 网络可以定义为一组单变量激活函数集的形式^[22], 如式(19)所示。

$$\Phi = \{\varphi^{(p,q)}\} \quad q=1,2,\dots,n_{in}, p=1,2,\dots,n_{out} \quad (19)$$

式中: $\varphi^{(p,q)}$ 为连接输入层第 q 个节点到输出层第 p 个节点的单变量激活函数; n_{in} 为该层输入维度; n_{out} 为该层输出维度。

在多层 KAN 网络架构中, 第 l 层网络的输入变量 $\mathbf{x}_{l,in}$ 至输出变量 $\mathbf{x}_{l,out}$ 的映射可通过边激活函数 $\varphi_i^{(p,q)}$ 的矩阵运算实现。

$$\mathbf{x}_{l,out} = \begin{bmatrix} \varphi_i^{(1,1)} & \varphi_i^{(1,2)} & \dots & \varphi_i^{(1,n_{L,in})} \\ \varphi_i^{(2,1)} & \varphi_i^{(2,2)} & \dots & \varphi_i^{(2,n_{L,in})} \\ \vdots & \vdots & & \vdots \\ \varphi_i^{(n_{L,out},1)} & \varphi_i^{(n_{L,out},2)} & \dots & \varphi_i^{(n_{L,out},n_{L,in})} \end{bmatrix} \mathbf{x}_{l,in} \quad (20)$$

采用 Φ_l 表示第 l 层 KAN 网络中所有激活函数构成的函数集, 则 L 层 KAN 网络构成的复合映射函数 $f_{KAN}(\mathbf{x})$ 如式(21)所示。

$$f_{KAN}(\mathbf{x}) = (\Phi_L \circ \Phi_{L-1} \circ \dots \circ \Phi_1) \mathbf{x} \quad (21)$$

式中: \mathbf{x} 为模型输入向量。

2.3 Transformer 网络模型

Transformer 架构^[23]的核心组件编码器采用模块化堆叠设计, 其结构由多头自注意力机制(multi-head self-attention mechanism, MHSA)与位置前馈网络(feed-forward network, FFN)构成层级计算单元。针对图节点分类任务的非自回归特性, 本研究主要聚焦编码器结构的分析。其中, 多头自注意力通过并行化的多头机制实现节点间多子空间依赖建模, 其计算过程可形式化表示为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \left(\text{Softmax} \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d^k}} \right) \right) \mathbf{V} \quad (22)$$

其中, 输入特征 \mathbf{X} 经过线性变换, 有 $\mathbf{Q} = \mathbf{X}\mathbf{W}_Q$, $\mathbf{K} = \mathbf{X}\mathbf{W}_K$, $\mathbf{V} = \mathbf{X}\mathbf{W}_V$, 且 \mathbf{W}_Q 、 \mathbf{W}_K 、 \mathbf{W}_V 是注意力头的可学习权重矩阵, d^k 表示 \mathbf{K} 矩阵的列数, 即向量的维度。

多头注意力机制具体表达式可定义为

$$\text{Multi-Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_h) \mathbf{W}_O \quad (23)$$

式中: Multi-Attention 表示多头自注意力机制,

$H_h = \text{Attention}(Q_h, K_h, V_h)$, 共有 h 个注意力头; W_o 表示多头注意力模块的输出线性变换权重矩阵, 用于将拼接后的所有注意力头输出整合回模型原始特征空间; $\text{Concat}(\cdot)$ 为拼接操作。

位置感知前馈网络作为 Transformer 架构的核心组件, 通过隐层维度扩展与压缩的线性变换架构, 并嵌入 ReLU 激活函数实现非线性映射, 对多头注意力输出的空间特征 $H = \text{Multi-Attention}(Q, K, V)$ 进行深度重构。

$$F(H) = \text{ReLU}(HW_1 + b_1)W_2 + b_2 \quad (24)$$

式中: $F(H)$ 表示前馈网络函数; W_1 、 W_2 和 b_1 、 b_2 分别为网络映射权值和偏置。最终经过多层编码器的堆叠, 模型能够逐步提取并融合图结构中的多层次信息, 从而为节点分类任务提供高质量的表示。

3 基于改进 GCN-Transformer 的脆弱性节点辨识模型

根据节点分类任务的特点, 本节提出一种融合 Cheb-KAN 网络的 GCN 与改进 Transformer 结构的节点分类模型。该模型一方面通过引入 Cheb-KAN 网络提升 GCN 的邻接节点特征提取能力, 优化节点特征在不同支路间的传播效果; 另一方面, 为更有效地融合节点的物理属性与拓扑结构信息, 提升模型对电网脆弱性特征的识别能力, 对 Transformer 框架进行改进, 引入模态间自注意力机制, 以更有效地捕捉不同模态特征之间的深层依赖关系。

3.1 基于 Cheb-KAN 的改进 GCN 网络

KAN 具备强大的非线性建模能力, 能够有效挖掘支路两端节点间隐含的复杂关系, 实现对支路特征的精准表达与加权融合。本节为了更加准确地分析复杂谱图网络中支路权重的非线性变化规律, 采用切比雪夫多项式(Chebyshev Polynomial)替代传统 B 样条作为 KAN 的基函数, 提出一种改进型 KAN 架构——Cheb-KAN。

切比雪夫逼近理论是数学分析中一种重要的逼近方法, 用于在给定的区间上寻找与给定函数最佳逼近的多项式。Chebyshev 多项式是满足在区间 $[-1, 1]$ 上具有正交性质的一组多项式函数, 多项式定义可表示为

$$T_n(x) = \cos(n \arccos x), -1 \leq x \leq 1 \quad (25)$$

且有递推形式:

$$T_0(x) = 1, T_1(x) = x, T_{b+1}(x) = 2xT_b(x) - T_{b-1}(x) \quad (26)$$

相比 B 样条, 其权重随阶数增加呈指数衰减特性, 且在区间 $[-1, 1]$ 上具有最优逼近特性, 能以最低阶数实现对目标函数的均匀逼近, 呈现出更强的数值稳定性和逼近能力。

基于上述理论, 本节对基函数 $s(x)$ 重新定义如式(27)所示, 用于提升模型对支路非线性特征的拟合能力。

$$s_T(x) = \sum_{r=1}^{D+J} c_r \cdot T_r(x) \quad (27)$$

式中: $T_r(x)$ 表示 Chebyshev 多项式。

新的激活函数为

$$\varphi_T = wb(x) + s_T(x) \quad (28)$$

根据式(19), 可采用 $\Phi_{lL} = \{\varphi_T^{(p,q)}\}$ 表示第 l 层 KAN 网络中所有激活函数构成的函数集, 经 Cheb-KAN 网络提取后的支路特征可表示为

$$W_{\text{edge}} = (\Phi_{lL} \circ \Phi_{lL-1} \circ \dots \circ \Phi_{l1} \circ \dots \circ \Phi_{l2} \circ \Phi_{l1})X_0 \quad (29)$$

式中: X_0 为输入支路特征, 本文采用支路两侧节点特征作为支路的初始特征。所述 Cheb-KAN 网络结构图如图 4 所示。

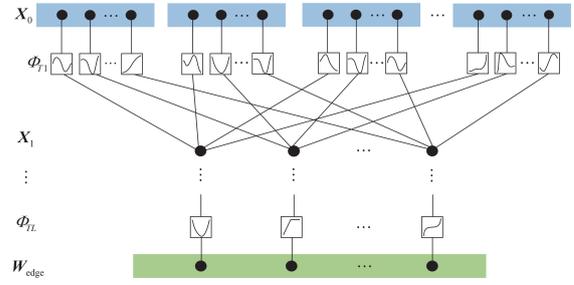


图 4 Cheb-KAN 网络结构图

Fig. 4 Structure of the Cheb-KAN network

自此, GCN 的节点信息传播由传统的无权传播优化为基于 Cheb-KAN 网络自更新的加权传播, 改进 GCN 卷积聚合在两种模态输入的形式为

$$\begin{cases} H_{\text{Phy}} = \sigma(\hat{D}^{-1/2}(A \odot W_{\text{edge}})\hat{D}^{-1/2}X_{\text{Phy}}W) \\ H_{\text{Topo}} = \sigma(\hat{D}^{-1/2}(A \odot W_{\text{edge}})\hat{D}^{-1/2}X_{\text{Topo}}W) \end{cases} \quad (30)$$

式中: W_{edge} 为 Cheb-KAN 网络输出的支路权重; \hat{D} 是加权邻接矩阵 $A \odot W_{\text{edge}}$ 的度矩阵, “ \odot ” 表示矩阵乘法; H_{Phy} 和 H_{Topo} 分别表示经过改进 GCN 特征提取后的节点动态物理状态属性和图连接关系与拓扑属性; X_{Phy} 和 X_{Topo} 分别表示节点初始物理和拓扑特征; W 为 GCN 的可训练权重矩阵。

式(30)实现了对不同模态信息的独立建模与图特征提取, 为后续两种模态特征的注意力融合奠定基础。

3.2 基于多模态融合的多头注意力机制

鉴于电网在受到复杂扰动过程中, 节点状态的演化以及系统整体的稳定性往往同时受到网络拓扑结构与物理状态特征的共同影响, 因此有必要在模型中建立两种模态数据(拓扑信息与物理信息)之间的有效关联。同时为了突破 GCN 基于局部邻域

聚合信息的限制,利用 Transformer 可以处理长距离多模态信息融合的特点,本小节在改进 GCN 特征提取的基础上,进一步引入 Transformer 进行节点间的信息交互,以提高模型的泛化能力。具体的多模态交叉注意力融合结构如图 5 所示。

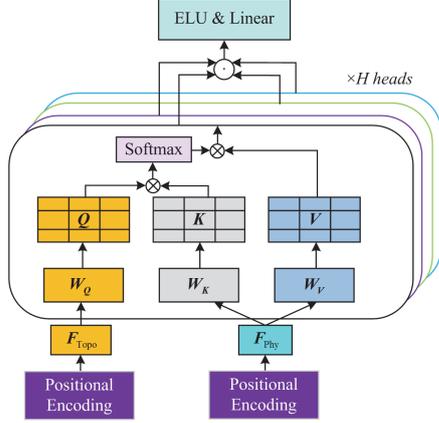


图 5 多模态交叉注意力融合结构图

Fig. 5 Multimodal cross-attention fusion mechanism

在将节点提取特征输入 Transformer 之前,需对节点特征进行位置编码。本小节采用奇异值分解(singular value decomposition, SVD)位置编码构建基于拓扑强化的节点嵌入,即对邻接矩阵 A 进行 SVD,从中提取与节点结构有关的潜在空间表示,分解过程如式(31)所示。

$$A = USV^T \quad (31)$$

式中: U 是左奇异矩阵,维度为 $m \times m$, 每一列对应一个奇异向量,反映了邻接矩阵的结构信息。通常选择左奇异矩阵 U 对应最大奇异值的前 z 个向量作为位置编码 Ω , 其中第 i 行就是对应第 i 个节点的位置编码,经过隐空间映射对位置编码与输入特征进行维度对齐后,此时经过编码的位置强化特征为

$$\begin{cases} F_{\text{Phy}} = H_{\text{Phy}} + \Omega \\ F_{\text{Topo}} = H_{\text{Topo}} + \Omega \end{cases} \quad (32)$$

将两种模态输入分别映射为查询向量(Q)、键向量(K)和值向量(V):

$$\begin{cases} Q_{\text{Phy}} = F_{\text{Phy}} W_Q \\ K_{\text{Topo}} = F_{\text{Topo}} W_K \\ V_{\text{Topo}} = F_{\text{Topo}} W_V \end{cases} \quad (33)$$

这里提出多模态交叉注意力融合机制,进一步捕捉节点间的全局交互关系,交叉注意力模块可表示为

$$\text{Attention}(Q_{\text{Phy}}, K_{\text{Topo}}, V_{\text{Topo}}) = \left(\text{Softmax} \left(\frac{Q_{\text{Phy}} K_{\text{Topo}}^T}{\sqrt{d^k}} \right) \right) V_{\text{Topo}} \quad (34)$$

为缓解深层网络中可能出现的梯度消散问题,引入 ELU 激活函数对多头注意力输出进行非线性处理,输出特征表示为

$$h_{\text{cat}} = \parallel_{h=1}^H \text{Attention}(Q_{\text{Phy}}, K_{\text{Topo}}, V_{\text{Topo}}) \quad (35)$$

$$\text{ELU}(x) = \begin{cases} x, & \text{if } x > 0 \\ \exp(x) - 1, & \text{if } x \leq 0 \end{cases} \quad (36)$$

$$h_{\text{ELU}} = \text{ELU}(h_{\text{cat}} W_{\text{Linear}} + b) \quad (37)$$

式中: h_{cat} 和 h_{ELU} 分别表示多头拼接及经 ELU 激活操作并线性映射后的图隐层特征; W_{Linear} 为线性映射的权重矩阵; b 为偏置项。

3.3 基于节点分类任务的模型训练

针对本文节点分类存在样本种类不平衡的问题,这里采用 Focal Loss 函数指导模型^[24]训练方向,缩小预测概率分布和真实标签之间的差异,其二分类公式为

$$FL(p_i) = -\alpha_i (1 - p_i)^\gamma \log(p_i) \quad (38)$$

式中: p_i 是模型对正确类别的预测概率; γ 是聚焦参数,调节“难分类样本”的权重; α_i 是类别平衡因子,用于解决样本的不平衡问题。

其中 p_i 是通过将输入特征向量进行变换和聚合得到的属性结果,再经 Softmax 函数进行归一化,获得节点属于不同类别的概率,该节点的分类预测结果可表示为

$$p_i = \text{Softmax}(y_i) = \begin{bmatrix} \frac{\exp(y_{1i})}{\exp(y_{1i}) + \exp(y_{2i})} \\ \frac{\exp(y_{2i})}{\exp(y_{1i}) + \exp(y_{2i})} \end{bmatrix} = \begin{bmatrix} p_{1i} \\ p_{2i} \end{bmatrix} \quad (39)$$

式中: $p_i = [p_{1i}, p_{2i}]^T$ 为判别脆弱性节点类别的二维概率向量。将概率较大的类别作为节点所属的类别。

基于上述模型,具体的脆弱性节点辨识模型框图如图 6 所示。

3.4 脆弱性节点辨识流程

依据前文工作,对基于改进 GCN-Transformer 的脆弱性节点辨识流程如下。

步骤一:基于 IEEE39 节点系统构建多种典型运行工况,利用 MATLAB/Matpower 进行潮流仿真,采集节点物理特征及拓扑结构参数。依据脆弱性综合评分结果划分脆弱性节点与非脆弱性节点,形成标签数据集。

步骤二:构建改进 GCN-Transformer 模型,将前述方式生成的节点多模态特征分别输入至 Cheb-KAN 网络与 GCN 网络中,充分挖掘节点信息在不同支路间的传播机制,通过改进 Transformer 多模态

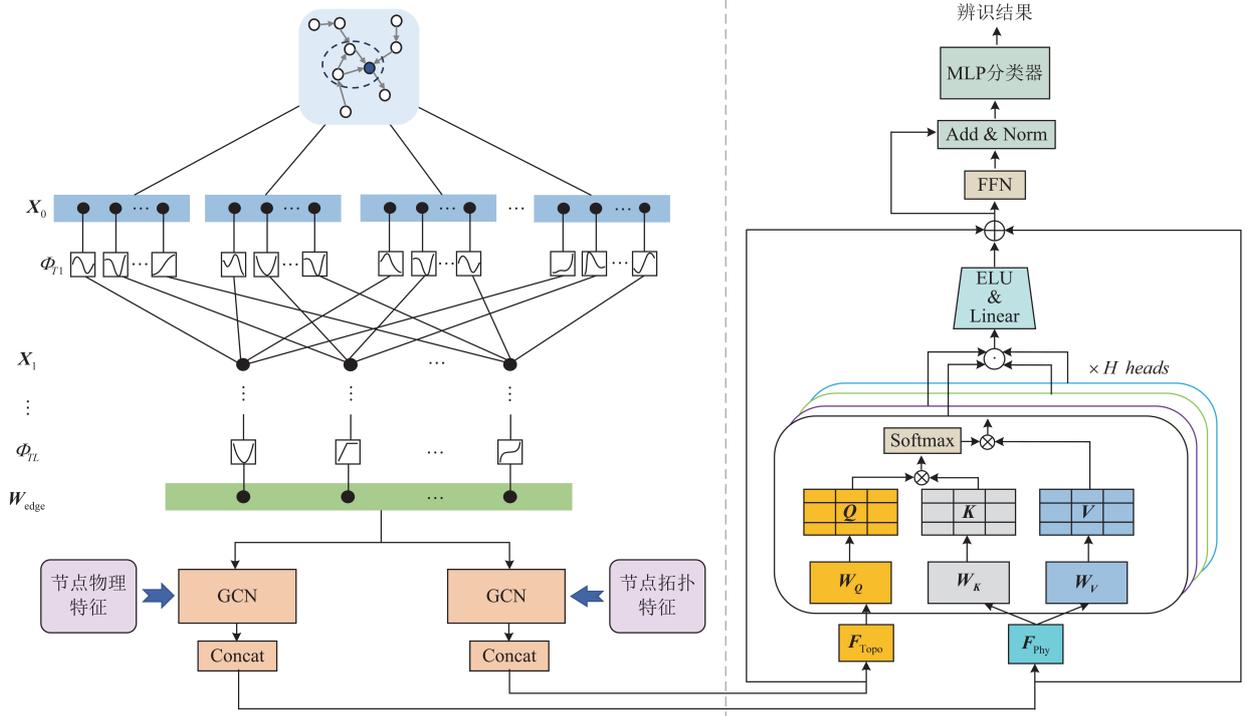


图 6 改进 GCN-Transformer 脆弱性节点辨识模型框图

Fig. 6 Framework of the improved GCN-Transformer for vulnerable node identification

注意力机制对融合后的特征进行全局建模与关联扩展, 提升对系统状态的理解与感知能力。

步骤三: 将融合特征输入全连接层, 通过 Softmax 函数输出节点类别概率。为解决样本不均衡问题, 引入 Focal Loss 作为损失函数指导训练过程。

步骤四: 模型采用训练集与测试集协同优化的策略, 结合前向传播与反向传播迭代学习。当损失函数收敛后, 转入验证阶段, 并在测试集上进行最终性能评估。评估过程严格遵循数据隔离原则, 确保模型结果的客观性与可置信度。

步骤五: 依据模型输出的脆弱性节点集, 依次移除脆弱性节点, 并分别针对剩余电网拓扑进行潮流计算, 动态监测电网的稳定性变化, 用以验证模型识别结果的准确性与工程适用性。

4 算例与结果分析

4.1 数据集的建立

本文采用 IEEE39 节点系统接线如图 7 所示, 有 39 个节点, 46 条线路。在输入数据集的建立过程中, 本文基于 Matpower 提供典型电网算例, 提取节点的物理特征; 同时结合复杂网络理论对传统拓扑参量进行部分改进, 定义新的节点拓扑特征。本文选取的节点特征如表 1 所示。

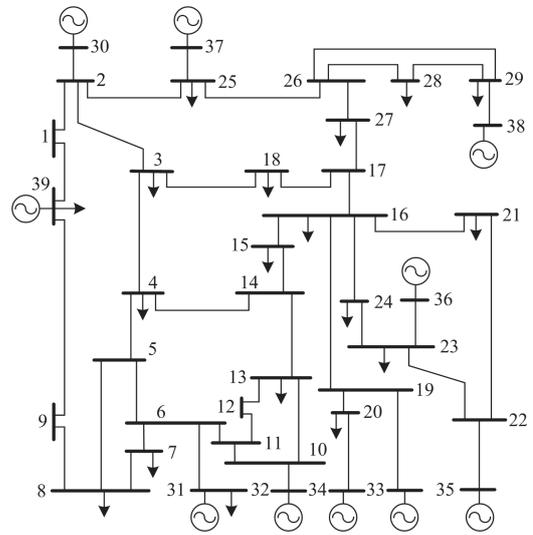


图 7 IEEE39 节点系统接线图

Fig. 7 Wiring diagram of IEEE39-node system

表 1 IEEE39 节点系统初始特征

Table 1 Initial characteristics of the IEEE39-node system

节点物理特征	节点拓扑特征
电压幅值	紧密度
电压相位	节点枢纽系数 ^[13]
有功负荷	局部聚类系数
无功负荷	节点距离度

为建立所有节点的脆弱性分类，这里利用前述第 2 节建立的脆弱性节点综合评价指标将所有节点以指标得分的形式进行排名，取前 20% 作为本系统的脆弱性节点。即对于本系统而言，得分前 8 名的节点被定义为脆弱性节点，作为脆弱性节点辨识模型的期望输出。其中脆弱性节点标记为 1，非脆弱性节点标记为 0。

为真实模拟电网运行^[25]，在不改变电网拓扑结构的基础上，本文采用典型网络数据，将发电机出力、线路电抗、节点负荷等网络参数在其 80%~120% 范围内随机变化，共生成 1000 组断面数据。通过仿真计算，除去不收敛的情况，共保留 930 组节点初始特征及其脆弱性节点分类结果。

4.2 基线模型

为充分验证所提模型的节点分类效果，本节选取 4 个典型基线模型进行对比实验，以验证本文方法的有效性。

1) 图卷积网络(GCN)^[10]: GCN 通过卷积方式提取特征，并结合目标节点及邻居节点学习相应的嵌入表示。

2) 图 Transformer(Graph Transformer): 图 Transformer 采用编码策略将图结构信息压缩到位置嵌入中，使模型在具备全局推理能力的同时也能有效捕捉图数据的拓扑信息。

3) 图采样与聚合网络(graph sample and aggregation, GraphSAGE): GraphSAGE 学习图中节点的低维表示，通过采样邻居节点并聚合生成节点表示。

4) 图同构网络(graph isomorphism network, GIN): GIN 将 W-L 同构检验进行推广，提出深度多集理论对通用多集函数进行参数化，从而提升 GNN 的表达能力。

4.3 参数设置

本节所有实验基于 Pytorch 2.3.1，搭配 CUDA 12.1 框架及 MATLAB 中 Matpower 8.0 工程包完成，物理实验平台为 Windows 11 操作系统，采用 Intel Core i7-14650HX CPU 与 NVIDIA GeForce RTX 4050 GPU 进行训练与仿真。为更好地与基线模型进行对比，本节选取准确率、F1 值和召回率作为模型性能的评估指标。

在模型训练过程中，本实验采用 Adam 优化器进行模型优化，初始学习率为 10^{-4} ，衰减因子设为 0.5，dropout 设为 10^{-5} ，每批次训练大小为 32，训练次数为 100。实验过程中的模型参数设置如表 2 所示。

4.4 模型辨识结果

所构建的脆弱性关键环节辨识样本集分别按 60%、20%、20% 的比例划分为训练集、验证集和测

试集，节点特征经归一化处理后输入模型。本文模型训练结果 F1 值与损失率曲线分别如图 8 和图 9 所示，在训练过程中迭代到 20 次后形成较好的结果。经过多次测试，模型在训练集、验证集和测试集上对脆弱性节点的各项评估指标如表 3 所示。

由于样本中脆弱性节点仅占总节点数的 20%，数据存在类别不平衡的情况。这种情况表明，模型在保持高准确率的同时表现出较高的精确率，尽管

表 2 模型实验参数设置

Table 2 Parameter settings for model experiments

模型	参数描述	取值
Cheb-KAN	输入特征维度	16
	隐藏层 1 特征维度	64
	隐藏层 2 特征维度	32
	隐藏层 3 特征维度	16
	输出特征维度	1
	多项式阶数	3
	网格点数	4
GCN	输入特征维度	4
	输出特征维度	16
Transformer	注意力头数	8

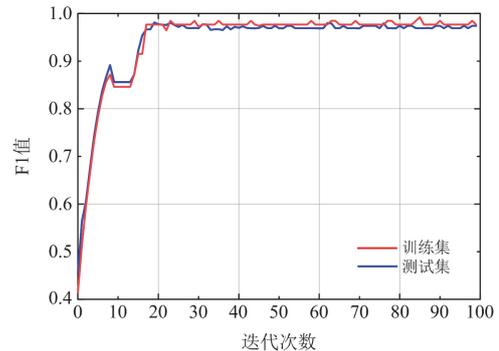


图 8 IEEE39 节点系统脆弱性节点辨识 F1 值
Fig. 8 F1 score of vulnerable node identification in the IEEE39-node system

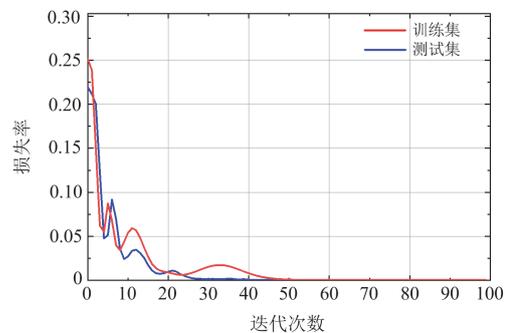


图 9 IEEE39 节点系统脆弱节点辨识损失率
Fig. 9 Load loss rate for vulnerable node identification in the IEEE39-node system

表 3 节点辨识模型各项指标

Table 3 Metrics of node identification model

	准确率/%	召回率/%	F1/%
训练集	98.11	96.54	98.11
验证集	99.43	93.75	99.43
测试集	98.69	96.94	98.46

召回率略低,但仍使得 F1 值与准确率接近。这表明模型对非脆弱性节点的辨识保持谨慎策略,具有较强的判别能力,能够有效避免误判问题。

实验结果表明,所提方法即使在有限样本条件下仍能实现较高的辨识准确率,充分验证了模型的小样本适应性与鲁棒性。同时,数据集具有可扩展性,可进一步应用于不同规模样本条件下更大范围的电网脆弱性分析中。

综上,本文所提出的模型无论是在训练集还是测试集上都取得了良好的辨识结果,辨识准确率满足一定的工程需求。

4.5 不同模型诊断效果对比

为证明改进 GCN-Transformer 模型在特征提取上的优势,在相同的样本库、模型框架等情况下,将本文所提模型与基线模型进行比较,不同模型脆弱性节点辨识 F1 值和损失率曲线分别如图 10 和图 11 所示。

由图 10 可以看出,本文提出的改进 GCN-Transformer 模型在训练初期迅速达到较高的 F1 值,拥有更快的收敛速度,显示出其在脆弱性节点辨识任务中的优越性。这表明所提模型能够更好地从图数据中提取节点与支路的局部和全局信息,同时以图 Transformer 和 GraphSAGE 为代表的图深度学习算法虽然可以捕捉节点之间的拓扑关系,但在节点依赖关系复杂的任务中缺乏对图全局结构的感知能力,可能会导致信息丢失,从而使后期 F1 值趋于饱和,难以进一步提升。

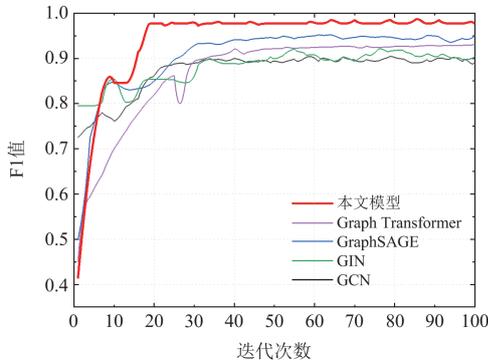


图 10 不同模型脆弱性节点辨识 F1 值

Fig. 10 F1 score of vulnerable node identification under different models

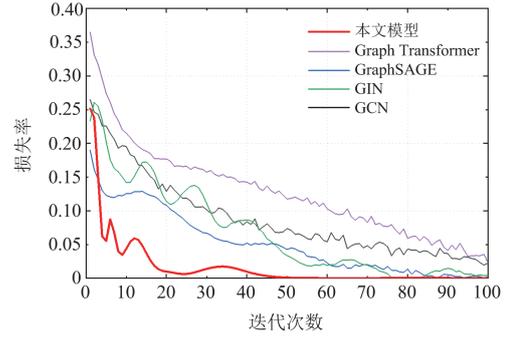


图 11 不同模型脆弱性节点辨识损失率

Fig. 11 Load loss rate of vulnerable node identification under different models

4.6 节点故障后的电网稳定性分析验证

为进一步验证本文节点辨识模型的有效性,考虑通过分析脆弱性节点部分退出后网络整体性能的变化,来判断模型对脆弱性节点的辨识效果。

节点辨识模型的效果判定流程包括:

1) 在 IEEE39 节点系统标准工况下,依次对模型辨识出的脆弱性节点进行叠加移除(第一次移除一个,第二次移除两个,以此类推)。每移除一次,更新网络架构并对可能存在的子网进行潮流计算以判断是否收敛;同时计算当前网络负荷损失、最大连通分量和电压偏差的变化情况,生成瓦解曲线,分析电网的稳定性指标变化情况。

2) 在发电机出力变化、节点负荷变化等多种工况下,观察系统脆弱性节点的排序变化,以验证本文方法节点排序在电力网络参数波动过程的稳定性。

本节定义负荷损失、最大连通分量及电压偏差作为电网稳定性的评价指标。

1) 负荷损失:指由于节点断电或潮流计算失败而导致的总负荷无法供电的比例。它衡量了电网在扰动下的服务能力退化程度,具体定义为

$$W_{\text{load}} = \left(1 - \frac{\sum_{i,j \in G'} F_{ij}}{\sum_{i,j \in G} F_{ij}} \right) \times 100\% \quad (40)$$

式中: F_{ij} 表示线路 ij 的传输功率; G 、 G' 分别表示故障前、后的电网。

2) 最大连通分量:部分节点崩溃后剩余节点所能组成的最大连通子网所含节点数,反映了系统结构的完整性与供电能力的潜在上限,具体定义为

$$M_{\text{CC}}(G) = \max_{C \subseteq G} |V(C)| \quad (41)$$

式中: C 是 G 的一个连通子网; $|V(C)|$ 表示其节点数。

3) 电压偏差:部分节点崩溃前后系统电压偏移的幅度,解释了无功与节点脆弱性之间的关系,具

体定义为

$$D_u = \sum_{L_o} \left| \frac{U_s - U_N}{U_N} \right| \quad (42)$$

式中： L_o 为负荷节点的集合； U_N 表示负荷节点的额定电压值； U_s 表示当节点故障后负荷节点的实际电压值。

本节基于 IEEE39 节点系统的典型负荷水平与发电机出力工况，对比分析了 3 种节点辨识方法，分别为本文所述节点辨识模型、传统的介数中心性 (Betweenness) 和内接近中心性 (Incloseness) 方法。3 种辨识方法的脆弱性节点排名如表 4 所示。通过逐步移除各方法识别出的脆弱性节点，观察系统各性能指标的变化趋势。

表 4 3 种辨识方法脆弱性节点排名

Table 4 Vulnerability node rankings obtained by three identification methods

排序	本文方法	介数中心性	内接近中心性
1	4	16	24
2	16	15	4
3	3	14	14
4	39	4	18
5	5	3	39
6	17	21	11
7	14	22	15
8	26	2	8

图 12 展示了脆弱节点移除后的负荷损失曲线。分析图 12 可知，本文方法在删除节点数达到 4，即删除节点 39 时，系统负荷损失已超过 85%，显著高于其余两种方法。这是由于在 IEEE39 节点系统中，节点 39 属于末端重负荷节点，其电压水平受上级节点潮流分布强烈影响。节点失效不仅会直接造成大规模负荷丧失，还会通过潮流转移使邻近支路过载，引发连锁反应。相比之下，其余两种指标仅

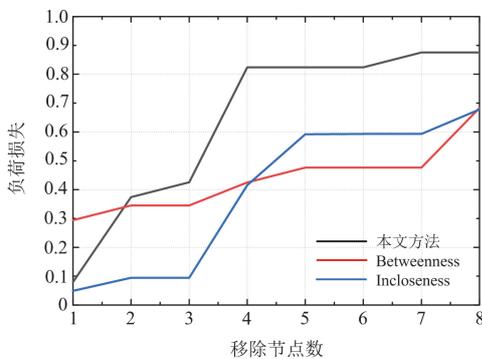


图 12 脆弱节点移除后的负荷损失曲线

Fig. 12 Load loss curve after removal of vulnerable nodes

从路径数量或距离出发，低估了节点 39 对系统供电能力的边际贡献，导致其排序靠后。

图 13 展示了节点移除后的电压偏移曲线。分析图 13 可知，本文方法所对应的节点移除同样导致了更剧烈的电压偏差波动，尤其是在第 4 至第 6 个节点被移除时，电压偏差达到峰值(超过 3.5%)。相比之下，介数中心性方法在整个过程中引起的电压偏差变化最小，内接近中心性方法在第 5 至第 6 个节点被移除时虽也表现出一定的扰动性，但整体弱于本文方法。

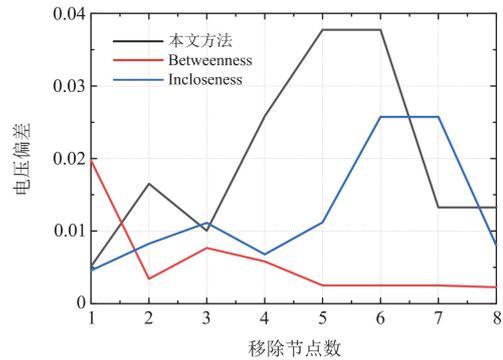


图 13 节点移除后的电压偏移曲线

Fig. 13 Voltage deviation curve after node removal

图 14 展示了节点移除后的最大连通分量曲线。分析图 14 可知，本文方法在移除前 4 个节点，即移除节点 16 后，最大连通分量显著下降。节点 16 作为关键枢纽节点，在电网拓扑中承担重要的潮流中转作用，其失效会导致系统解列，从而使最大连通分量显著降低。相比之下，介数中心性方法只在移除首个节点后最大连通分量显著下降，随后趋于平缓；内接近中心性方法则呈逐步下降趋势，但整体保持较高最大连通分量，最终结果与介数中心性方法接近。

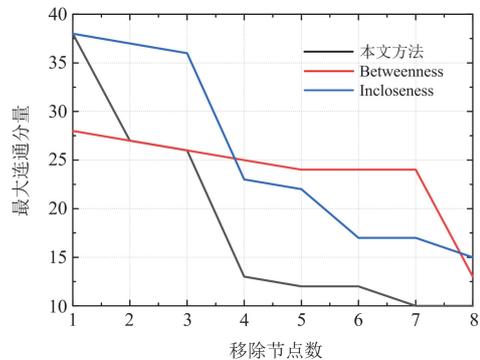


图 14 节点移除后的最大连通分量曲线

Fig. 14 Maximum connectivity component curve after node removal

同时,由表4可知,节点4在3种方法中均处于前列,这归因于其不仅是电网中的重要枢纽节点,同时还承担了较大的电力负荷。这种拓扑关键性与物理重要性的双重叠加,使得节点4成为系统运行中的核心脆弱性节点。这一结果表明,本文方法并非完全背离传统拓扑指标,而是在电力负荷约束下对拓扑特征进行了有效融合与修正。

最后,本节在典型工况的基础上,分别使发电机出力 and 节点负荷在其 0.9~1.1 范围内均匀增长,结果显示本文方法在大多数扰动情况下,排名前列的关键脆弱性节点保持相对稳定,仅在部分边界工况下中间排名节点可能出现次序变化。这说明所提方法能够较好地反映节点脆弱性的整体规律,同时对运行条件变化保持合理的敏感性。

综合分析可得,本文方法在电网节点脆弱性评估中表现出更高的有效性,其排序方式能够优先识别出对系统拓扑结构与电气特性均具有关键影响的节点,从而弥补了传统方法在电气系统中的局限性。这表明本文模型在脆弱性节点辨识中具有更高的应用价值。

5 结论

本文针对传统脆弱性节点辨识方法在准确性、实时性方面难以满足当前电网运行实际需求的问题,提出了一种基于前置支路特征提取与多模态交叉注意力融合的电网节点脆弱性辨识方法。通过算法验证,得出以下结论。

1) 通过融合复杂网络理论与改进信息熵-K壳算法,构建了能够综合反映节点脆弱性的评价指标体系,并基于评价指标分数确定节点脆弱性指标集。

2) 提出的改进 GCN-Transformer 模型,基于 Cheb-KAN 结构优化 GCN 对电网支路特征的提取能力,同时通过引入多模态交叉注意力融合机制,充分利用 Transformer 对节点多模态特征的长距离依赖建模优势,实现了对全局信息的精准捕捉。

3) 在 IEEE39 节点系统上的仿真实验结果表明,该模型在训练集和测试集上的辨识 F1 值分别达到 98.11% 和 98.46%,相较于其他图深度学习方法具有明显优势;同时,与传统的介数中心性和内接近中心性方法相比,所提模型在负荷损失、电压偏差等性能评价指标上表现出更优的识别效果,验证了所提模型在识别系统关键节点方面的有效性。

需要指出的是,本文模型的计算复杂度较传统方法有所增加,如何在保证准确性的同时提高计算效率,是未来工作的重点方向。此外,未来可以进一步探索多源异构数据的融合,如气象、设备状态

及历史故障数据,结合多模态深度学习技术,有望进一步提升脆弱性节点识别的可靠性。

参考文献

- [1] 戴志辉,张宇,吴桐,等. 含高比例新能源配电网的改进重合闸方案[J]. 电力系统保护与控制, 2025, 53(15): 103-112.
DAI Zhihui, ZHANG Yu, WU Tong, et al. An improved reclosing scheme for active distribution networks with high proportion of new energy[J]. Power System Protection and Control, 2025, 53(15): 103-112.
- [2] QIN Z, DAVIDSON J, FOUAD A A. Application of artificial neural network in power system security and vulnerability assessment[J]. IEEE Transactions on Power Systems, 1994, 9(1): 525-532.
- [3] 丁明,韩平平. 加权拓扑模型下的小世界电网脆弱性评估[J]. 中国电机工程学报, 2008, 28(10): 20-25.
DING Ming, HAN Pingping. Vulnerability assessment of small-world power grids based on weighted topological models[J]. Proceedings of the CSEE, 2008, 28(10): 20-25.
- [4] 刘文颖,梁才,徐鹏,等. 基于潮流介数的电力系统关键线路辨识[J]. 中国电机工程学报, 2013, 33(31): 90-98, 11.
LIU Wenyong, LIANG Cai, XU Peng, et al. Identification of critical line in power systems based on flow betweenness[J]. Proceedings of the CSEE, 2013, 33(31): 90-98.
- [5] 徐敬友,陈冲,罗纯坚,等. 基于改进复杂网络模型的电网关键环节辨识[J]. 电力系统自动化, 2016, 40(10): 53-61.
XU Jingyou, CHEN Chong, LUO Chunjian, et al. Identification of power grid key parts based on improved complex network model[J]. Automation of Electric Power Systems, 2016, 40(10): 53-61.
- [6] 李鹏,余涛,李立涅,等. 电力人工智能的演变与展望——从专业智能走向通用智能[J]. 电力系统自动化, 2024, 48(16): 1-17.
LI Peng, YU Tao, LI Licheng, et al. Retrospect and prospect of artificial intelligence for electric power system—from domain intelligence to general intelligence[J]. Automation of Electric Power Systems, 2024, 48(16): 1-17.
- [7] 谢李为,李勇,罗隆福,等. 基于复杂网络与运行因素的电网薄弱点辨识方法[J]. 电力系统保护与控制, 2022, 50(4): 83-91.
XIE Liwei, LI Yong, LUO Longfu, et al. A vulnerable points identification method based on complex network theory and an operation index[J]. Power System Protection and Control, 2022, 50(4): 83-91.
- [8] 杨茂,郭镇鹏,王达,等. 基于神经网络的短期风电功率群体预测方法[J]. 电力系统保护与控制, 2025, 53(19): 79-88.

- YANG Mao, GUO Zhenpeng, WANG Da, et al. Short-term wind power group forecasting method based on graph neural networks[J]. Power System Protection and Control, 2025, 53(19): 79-88.
- [9] 何小龙, 高红均, 黄媛, 等. 基于一维卷积和图神经网络的配电网故障区段定位方法[J]. 电力系统保护与控制, 2024, 52(17): 27-39.
- HE Xiaolong, GAO Hongjun, HUANG Yuan, et al. Fault section location for a distribution network based on one-dimensional convolution and graph neural networks[J]. Power System Protection and Control, 2024, 52(17): 27-39.
- [10] AHSAN F, DANA N H, SARKER S K, et al. Data-driven next-generation smart grid towards sustainable energy evolution: techniques and technology review[J]. Protection and Control of Modern Power Systems, 2023, 8(3): 696-737.
- [11] QU H, SONG Y R, LI R, et al. GNR: a universal and efficient node ranking model for various tasks based on graph neural networks[J]. Physica A: Statistical Mechanics and its Applications, 2023, 632.
- [12] SIMEUNOVIĆ J, SCHUBNEL B, ALET P J, et al. Interpretable temporal-spatial graph attention network for multi-site PV power forecasting[J]. Applied Energy, 2022, 327.
- [13] ZHUANG W, FAN J L, XIA M, et al. A multi-scale spatial-temporal graph neural network-based method of multi-energy load forecasting in integrated energy system[J]. IEEE Transactions on Smart Grid, 2024, 15(3): 2652-2666.
- [14] WU Z, JAIN P, WRIGHT M A, et al. Representing long-range context for graph neural networks with global attention[C/OL] // Proceedings of the Advances in Neural Information Processing Systems, December 6-14, 2021: 13266-13279.
- [15] BIALEK J. Tracing the flow of electricity[J]. IEE Proceedings-Generation, Transmission and Distribution, 1996, 143(4): 313-320.
- [16] 李长城, 吕金峰, 张翌晖, 等. 基于拓扑-运行综合特性的电网关键节点辨识方法[J]. 电力系统及其自动化学报, 2025, 37(10): 53-63.
- LI Changcheng, LÜ Jinfeng, ZHANG Yihui, et al. Method for identifying critical nodes in power network based on integrated topological and operational characteristics[J]. Proceedings of the CSU-EPSA, 2025, 37(10): 53-63.
- [17] KITSAK M, GALLOS L, HAVLIN S, et al. Identification of influential spreaders in complex networks[J]. Nature Physics, 2010, 6(11): 888-893.
- [18] 汪亭亭, 梁宗文, 张若曦. 基于信息熵与迭代因子的复杂网络节点重要性评价方法[J]. 物理学报, 2023, 72(4): 331-341.
- WANG Tingting, LIANG Zongwen, ZHANG Ruoxi. Importance evaluation method of complex network nodes based on information entropy and iteration factor[J]. Acta Physica Sinica, 2023, 72(4): 331-341.
- [19] 丁少倩, 林涛, 徐遐龄, 等. 基于改进的 AHP-熵权法的电网综合脆弱性评估方法研究[J]. 电测与仪表, 2017, 54(4): 28-33, 68.
- DING Shaoqian, LIN Tao, XU Xialing, et al. Research on comprehensive vulnerability of grid assessment method based on the improved AHP-entropy method[J]. Electrical Measurement & Instrumentation, 2017, 54(4): 28-33, 68.
- [20] HE L, BAI L, YANG X, et al. High-order graph attention network[J]. Information Sciences, 2023, 630: 222-234.
- [21] LIU Z, WANG Y, VAIDYA S, et al. KAN: Kolmogorov-Arnold networks[EB/OL]. [2024-09-05]. <https://arxiv.org/abs/2404.19756v5>
- [22] 刘栋, 郭国栋, 辛蜀骏, 等. 基于 KAN 的可解释净负荷概率预测方法[J]. 电力系统自动化, 2025, 49(15): 123-132.
- LIU Dong, GUO Guodong, XIN Shujun, et al. Probabilistic prediction method for interpretable net load based on Kolmogorov-Arnold network[J]. Automation of Electric Power Systems, 2025, 49(15): 123-132.
- [23] 李鑫, 陆伟, 马召祎, 等. 基于图注意力和改进 Transformer 的节点分类方法[J]. 电子学报, 2024, 52(8): 2799-2810.
- LI Xin, LU Wei, MA Zhaoyi, et al. A node classification method based on graph attention and improved Transformer[J]. Acta Electronica Sinica, 2024, 52(8): 2799-2810.
- [24] LIN T, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C] // 2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy: 2999-3007.
- [25] 王长刚, 王先伟, 曹宇, 等. 基于改进图注意力网络的电力系统脆弱性关键环节辨识[J]. 电力系统保护与控制, 2024, 52(15): 36-45.
- WANG Changgang, WANG Xianwei, CAO Yu, et al. Critical link identification of power system vulnerability based on modified graph attention network[J]. Power System Protection and Control, 2024, 52(15): 36-45.

收稿日期: 2025-06-03; 修回日期: 2025-10-13

作者简介:

刘伟(1971—), 男, 博士, 教授, 博士生导师, 研究方向为智能监测与诊断系统、可再生能源与智能控制; E-mail: 442780146@qq.com

梁悦帅(2000—), 男, 硕士研究生, 研究方向为图神经网络与电力系统安全评估。E-mail: lys15392530929@163.com

(编辑 魏小丽)