

基于网络拓扑的改进图卷积神经网络的电力通信毁伤韧性量化评估方法

田安琪, 于秋生, 孙超, 江颖洁, 李丽, 张璞

(国网山东省电力公司信息通信公司, 山东 济南 250001)

摘要: 当前电力网络毁伤韧性评估方法存在未能考虑电力网络本身所具有的功能特性、未能有效利用数据信息等问题, 导致评估结果的可靠性难以保障。为此, 提出基于网络拓扑的电力通信风险预测与毁伤韧性量化评估方法。首先, 采用基于改进图卷积神经网络与多头自注意力的电力通信风险预测模型实现风险预警量化评估, 同时构建基于业务的电力超网络, 进行节点重要度评估; 其次, 根据毁伤形态制定恢复策略, 依据恢复过程仿真计算出电力通信网络的总性能; 最后, 通过PRF曲线准确评估电力网络毁伤韧性。实验结果表明, 与最优基线相比, 所提模型的召回率和F1分数分别提升了9.87%和5.96%。该模型能有效提高电力通信风险预测性能, 实现电力通信网络毁伤韧性的精准量化评估。

关键词: 电力通信; 风险预测; 毁伤韧性评估; 图卷积神经网络; 多头自注意力

DOI: 10.11907/rjdk.251268

扫描二维码阅读全文:



中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2026)006-0134-08

An Assessment Method for Power Communication Destruction Toughness Based on Improved Graph Convolutional Neural Network with Network Topology

TIAN Anqi, YU Qiusheng, SUN Chao, JIANG Yingjie, LI Li, ZHANG Pu

(State Grid Shandong Electric Power Company Information and Communication Company, Ji'nan 250001, China)

Abstract: The current assessment methods for the damage resilience of power networks have problems such as not considering the functional characteristics of the power network itself and not effectively utilizing data information, which makes it difficult to guarantee the reliability of the assessment results. Therefore, a network topology based method for predicting power communication risks and quantitatively evaluating damage resilience is proposed. Firstly, a power communication risk prediction model based on improved graph convolutional neural network and multi head self attention is adopted to achieve quantitative risk warning evaluation. At the same time, a business based power super network is constructed to evaluate node importance; Secondly, develop recovery strategies based on the damage form, and calculate the overall performance of the power communication network through simulation of the recovery process; Finally, the PRF curve is used to accurately evaluate the damage resilience of the power network. The experimental results showed that compared with the optimal baseline, the recall rate and F1 score of the proposed model increased by 9.87% and 5.96%, respectively. This model can effectively improve the risk prediction performance of power communication and achieve accurate quantitative evaluation of the damage resilience of power communication networks.

Key Words: power communication; risk prediction; damage toughness assessment; graph convolutional neural networks; multi-head self-attention

收稿日期: 2025-05-20

基金项目: 国网山东省电力公司科技项目(520627240007)

作者简介: 田安琪(1992-), 女, 国网山东省电力公司信息通信公司工程师, 研究方向为信息与通信工程; 于秋生(1978-), 男, 国网山东省电力公司信息通信公司高级工程师, 研究方向为电力通信; 孙超(1993-), 男, 国网山东省电力公司信息通信公司工程师, 研究方向为电子与通信工程; 江颖洁(1989-), 女, 国网山东省电力公司信息通信公司高级工程师, 研究方向为信号与信息处理; 李丽(1993-), 女, 国网山东省电力公司信息通信公司工程师, 研究方向为电子与通信工程; 张璞(1986-), 男, 国网山东省电力公司信息通信公司高级工程师, 研究方向为电力通信。本文通讯作者: 孙超。

0 引言

随着智能电网的快速发展,电力通信网络规模不断扩大,其复杂的拓扑结构和海量的节点给运维管理带来巨大挑战^[1-2]。作为电力系统的关键基础设施,通信网络的可靠性直接影响着电网的运行安全^[3]。当前网络面临三大难题,即覆盖范围广导致异常检测困难、设备关联性强引发级联故障风险,以及动态拓扑变化降低传统方法的适应性等^[4-6]。现有基于机器学习的评估方法,如图注意力神经网络(Graph Attention Networks, GAT)、图卷积神经网络(Graph Convolutional Networks, GCN)虽然取得一定进展,但仍存在时空特征割裂、业务耦合性差等缺陷^[7]。因此,开发新型电力通信风险预测与韧性评估方法具有重要现实意义。

1 相关工作

1.1 电力通信风险预测

电力通信风险预测包括电力通信网络异常运行状态预警的溯源定位、节点业务在不同时间窗口的风险预警量化评估以及电力通信网络脆弱节点识别等方面。近年来,众多基于深度学习和人工智能的方法不断涌现。例如,文献[8]利用GCN模型对电网故障进行定位,该模型考虑到相连节点间的影响,具备较强的全局搜索能力,提高了故障定位精度。针对配电网络拓扑频繁变化的情况,文献[9]提出一种基于GAT的配电网故障定位方法,比GCN模型更能适应拓扑变化。文献[10]使用长短期记忆网络和深度前馈神经网络建立深度学习模型,进行电力通信数据的分析与预测,通过调整网络参数、结合自适应梯度算法、添加Dropout层和L2正则化项等进行优化,提升了电力通信主动性运行水平。文献[11]利用深度学习技术对电网运行情况进行实时监控,对无法正常运行的电力设备进行故障诊断、调度分析等。然而,以上研究仅停留在故障定位或状态预警层面,未涉及网络毁伤后的性能评估、修复资源分配与韧性量化。

1.2 毁伤韧性量化评估

电力通信网络的毁伤韧性是指在电力通信网络受到攻击或自然灾害等破坏性事件时,其承受、适应和快速恢复至正常状态的能力。电力通信网络的韧性越高,恢复能力越强。目前针对电力网络韧性评估的研究众多,常见的有基于可靠性理论、基于复杂网络理论、基于优化算法和基于风险评估的方法。在基于可靠性理论的方法方面,文献[12]通过构建故障树来分析导致电力网络失效的各种可能因素及其组合。文献[13]使用蒙特卡罗模拟法,通过随机抽样模拟电力系统的运行状态和故障情况。在基于复杂网络理论的方法方面,文献[14]通过研究电力网络的

拓扑结构特性,如节点度、介数等进行韧性量化评估。文献[15]分析了网络在遭受攻击或发生故障后的连通性变化。在基于优化算法的方法方面,文献[16]同时考虑多个目标,如成本、可靠性和韧性等,来优化网络配置。文献[17]在不确定性条件下寻找最优的电力网络规划和运行策略。在基于风险评估的方法方面,文献[18]通过考虑故障发生的概率和后果来评估电力网络的风险水平。文献[19]评估了不确定性和模糊性因素在风险评估中的影响。

虽然目前针对电力网络韧性评估的研究成果丰富,但 these 方法并非尽善尽美,例如未能考虑电力网络功能特性、未能有效利用数据信息等。为此,本文提出基于改进GCN的电力通信风险预测及毁伤韧性量化评估方法,通过充分挖掘电力数据中的时序关系,提高系统的风险预测性能;然后将节点风险概率转化为毁伤形态,并根据节点重要度分配修复资源,构建了融合可靠性理论、复杂网络理论、优化算法、风险评估的全面智能评估框架。该方法形成了从“风险预测”到“韧性评估”的全流程闭环,为电力通信网络的智能化运维提供了更全面、可靠的技术方案。

2 问题定义

本文研究的目标为针对电力数据 G, A, X , 利用深度学习技术检测网络异常运行状态并定位至脆弱节点 i 。根据脆弱节点 i 与邻近节点间的通信关联传导路径,预测在不同时间窗口波及节点的风险概率,从而实现节点在不同时间窗口的风险预警量化评估。定义基于业务的电力超网络 G_H , 进行超核分解并计算重要度 $I(i)$, 将获取到的节点毁伤概率转化为网络的毁伤形态,根据节点重要度 $I(i)$ 分配具体的修复预算 b 和修复资源 r , 计算基于各业务的实时性能 $F_s(t)$ 和电力通信网络在 t 时刻的总性能 $F(t)$, 进而计算电力网络毁伤韧性评估值 R 。

3 模型构建

图1为电力通信风险预测及毁伤韧性量化评估模型架构。该模型主要分为电力通信风险预测和毁伤韧性量化评估两个部分,其中电力通信风险预测部分包括数据处理、电力通信风险预测和因果学习三大模块。毁伤韧性量化评估部分包括基于业务的电力超网络构建、单元重要度计算和毁伤破坏形态确定、恢复策略分析、系统性能度量以及系统韧性评估五大模块。

3.1 电力通信风险预测

电力通信风险预测可实现运行监测阶段的实时风险预警与脆弱节点识别。本文通过对多源数据进行实时分析,利用风险预测模型进行风险预警量化评估,一旦监测到电力通信网络出现异常运行状态,及时发出预警信息,并且持续评估节点重要度,结合实时监测数据,精准识别




Fig. 1 Power communication risk prediction and damage toughness quantitative evaluation model architecture

图 1 电力通信风险预测及毁伤韧性量化评估模型架构

易受影响的脆弱节点,以便进行重点关注与保护。

3.1.1 数据处理模块

(1)数据描述。电力通信网可以表示为一个无向无权图,电力时序数据可构建为基于历史电力通信数据的图 $G^{(t)} = (V, E, A, X)$ 。其中, $V \in R^n$, 表示图 G 的节点; E 为图 G 的边; $A \in R^{n \times n}$, 为 G 的邻接矩阵, n 表示节点数量。对于 $V_{v_i}, v_j \in V$, 如果 $e_{ij} \in E$, 则 $A_{ij} = 1$, 否则 $A_{ij} = 0$ 。 $X^{(t)} \in R^{n \times m}$, 表示 t 时刻节点的属性信息, 其中 n 为图中的节点个数, m 为属性信息的维数。属性信息包括节点信息和通道信息, 节点信息包含该节点的网络丢包率、端对端通信延迟、业务类型、业务量、传输时间、节点连接数量、节点类型等; 通道信息包括发送节点、接受节点、通道编号、信道类型、信道带宽、流量等。

(2)因果关系分析。电网线路的时序传输数据蕴含长短期因果关联特征。本文模型通过动态因果图学习框架, 从时空图数据中分层提取多尺度因果关系。时间因果关系体现为节点的数据值能影响自身或其他变量的未来值。本文采用有向无环图(Directed Acyclic Graph, DAG)表示因果图, 采用祖先图(Ancstral Graph)建模条件独立性关系。模型中的节点分为外生和内生两类, 学习过程先从连接外生节点与内生节点的边入手, 然后学习内生节点上的子图。从全连接图开始, 先细化外生和内生节点间的边以学习长期关系; 然后细化内生节点间的边以学习短期关系。在细化边时, 若发现一对节点 (i, j) 条件独立, 则删除所有同源对的边, 如此逐步构建出能准确反映节点间因果关系的动态部分祖先图。

(3)数据处理。GCN通过聚合邻域信息来提取拓扑结构和局部信息。具体来说, 其从单个节点和相邻节点提取

信息, 并将节点特征信息与相邻节点特征信息聚合以得到新信息^[20]。GCN在图结构数据上的表达能力比普通卷积网络更强, 因此本文采用该网络来学习电网通信数据的特征。

电力通信数据首先通过一维卷积进行初步处理, 该卷积沿时间轴在所有节点的属性信息 X 上滑动来捕获时间依赖性; 其次利用异或运算捕捉差异; 最后通过 ReLU 函数激活强化。其公式化表达为:

$$Y = \delta(X \oplus (W_x * X + b_x)) \quad (1)$$

式中: $*$ 表示一维卷积, W_x 表示卷积核, b_x 表示偏置, $\oplus$ 表示异或运算, δ 表示 ReLU 激活函数。

一层 GCN 需要两部分输入, 即图上每个节点 i 的特征描述 $X^{(i)}$ 和图的邻接矩阵 A 。经过图卷积处理后输出电力通信特征矩阵 $H^{(l+1)}$ 。整个 GCN 由多个图卷积操作层构成, 第 l 层最简图卷积操作表示为:

$$f(X^{(l+1)}, A) = \delta(AX^{(l)W^{(l)}}) \quad (2)$$

式中: $W^{(l)}$ 表示第 l 层的权重矩阵; δ 表示激活函数, 此处选择 ReLU。

考虑到需要引入节点自身特征, 且鉴于电力通信图邻接矩阵 A 的对角线元素均为 0, 故将单位阵与其邻接矩阵 A 相加。表示为:

$$A = A + I \quad (3)$$

在多层卷积中多次与邻接矩阵 A 进行矩阵乘法运算会导致输出的特征向量大小改变, 从而影响网络稳定性, 因此需要对邻接矩阵 A 进行归一化处理, 使其每行的和为 1。其公式化表达为:

$$f(X^{(l)}, A) = \delta(D^{-\frac{1}{2}}AD^{-\frac{1}{2}}X^{(l)W^{(l)}}) \quad (4)$$

$$D = \text{diag}(\sum_{j=1}^N A(i, j)) \quad (5)$$

本文的GCN中还引入了注意力机制。该机制可以根据权重聚合节点与其邻接节点的信息,使模型更好地关注到重要节点的信息。多头自注意力层的输入为一个节点特征向量集合。表示为:

$$X = \{x_1, x_2, \dots, x_n\}, x_i \in R^m \quad (6)$$

式中: n 为节点个数, m 为节点的特征数, x_i 为节点 i 的特征向量。

自注意力层的输出为一个新的特征集合。表示为:

$$X' = \{x'_1, x'_2, \dots, x'_n\}, x'_i \in R^{m'} \quad (7)$$

由 $G(X, A)$ 到 $G(X', A)$ 需要经过注意力系数计算和特征聚合两个步骤^[21]。首先计算注意力系数 α_{ij} 。公式为:

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(Wx_i, Wx_j))}{\sum_{j \in N(i)} \exp(\text{LeakyReLU}(\alpha(Wx_i, Wx_j)))} \quad (8)$$

式中: $j \in N(i)$,为节点 i 的相邻节点; α 为可学习的权重向量; W 为可学习的权重矩阵;LeakyReLU为非线性激活函数。计算得到注意力系数 α_{ij} 后,按下式计算得到每个融合了邻域信息的节点的新特征:

$$x'_i = \sigma(\sum_{j \in N(i)} \alpha_{ij} Wx_j) \quad (9)$$

式中: $\sigma(\bullet)$ 为激活函数,此处采用eLU。表达式为:

$$\sigma(x) = \begin{cases} x, & x \geq 0 \\ \beta(e^x - 1), & x < 0 \end{cases} \quad (10)$$

$$X = \delta(X \oplus Y) \quad (11)$$

式中: $\oplus$ 表示异或运算; δ 表示激活函数,此处选择ReLU。

GCN和一维卷积组成时空图卷积网络(ST-Conv Block),经过两个时空图卷积网络的堆叠以融合来自空间和时间域的特征,从而逐步提取更高级别的特征;然后通过一维卷积得到最终的电力数据特征矩阵 H 。这种设计能够有效处理电力通信网络中的复杂关系和动态变化。

3.1.2 风险预测模块

在风险预测模块,将得到的特征矩阵 H 送入全连接层,对提取的节点电力通信特征信息进行融合,得到电力通信节点的风险概率。对于节点 i ,其风险概率 $\hat{y}_i$ 可以表示为:

$$H = f(W_h * X + b_h) \quad (12)$$

$$\hat{y}_i = f(W_y * H + b_y) \quad (13)$$

式中: H 为电力数据特征矩阵; W_h, W_y 为权重矩阵; b_h, b_y 为偏置向量; f 为线性映射函数。

以交叉熵损失为例,假设真实的异常标签为 y_i ,则损失函数 L_{pred} 可以表示为:

$$L_{pred} = -\frac{1}{N} \sum_{i=1}^N y_i \log_2(\hat{y}_i) \quad (14)$$

式中: y_i 为训练集第 i 个节点的实际值(稳定/存在风险); $\hat{y}_i$ 为对应的节点预测值。

3.1.3 因果学习模块

因果学习模块可更深入地挖掘和理解数据中的特征,捕捉更复杂的特征关系,进而提高模型的准确性和可靠性。对电力通信数据图 G 进行因果分析,得到图 G_{pag} ,对图 G_{pag} 执行与图 G 相同的操作,得到因果特征矩阵 H_{pag} 。在因果学习中,需要考虑节点之间的复杂相关性,包括节点内的数据相关性以及节点之间的相互相关性。从网络得到的电力数据特征表示为 H ,经过映射层映射后的特征表示为 Z ,给定特征序列为:

$$Z^0 = [H, A] \quad (15)$$

$$Z_{pag}^0 = [H_{pag}, A] \quad (16)$$

具体计算过程为:

$$Z^l = \text{LayerNorm}(Z^{l-1} + \text{MHSA}(Z^{l-1})) \quad (17)$$

$$Z^l = \text{LayerNorm}(Z^l + \text{FFN}(Z^{l-1})) \quad (18)$$

$$Z_{pag}^l = \text{LayerNorm}(Z_{pag}^{l-1} + \text{MHSA}(Z_{pag}^{l-1})) \quad (19)$$

$$Z_{pag}^l = \text{LayerNorm}(Z_{pag}^l + \text{FFN}(Z_{pag}^{l-1})) \quad (20)$$

式中: l 为堆叠层数;MHSA为多头自注意力;FFN为前馈网络;LayerNorm为层归一化。

为提高模型可信度,利用交叉熵损失控制损失权重。每次更新时,根据相对损失动态调整损失权重,确保 L_{CL} 和 L_{pred} 在整个更新过程中经历相对公平的下降。公式为:

$$\omega_p(t) = \frac{m_\omega [L_{pred}(t)]^\beta}{[L_{pred}(t)]^\beta + [L_{CL}(t)]^\beta} + (1 - m_\omega) \omega_p(t-1) \quad (21)$$

$$\omega_c(t) = 1 - \omega_p(t) \quad (22)$$

式中: $\omega_*(t)$ 为 t 时刻的损失权重; β 为控制损失权重更新程度的超参数; m_ω 为动量系数超参数。最终损失计算公式为:

$$L(t) = \omega_p(t) L_{pred}(t) + \omega_c(t) L_{CL}(t) \quad (23)$$

3.2 毁伤韧性量化评估

毁伤韧性量化评估可在故障处置阶段制定恢复策略并进行恢复过程仿真。当电力系统发生故障时,根据毁伤形态制定恢复策略,结合节点重要度和业务优先级确定优先恢复的节点和线路。然后根据恢复策略进行恢复过程仿真,计算电力通信网络在恢复过程中的总性能,评估策略有效性,并根据结果及时调整,确保电力系统快速稳定地恢复运行。

3.2.1 电力超网络构建

根据超图理论构建基于业务的电力超网络。具体结构见图2。以电力通信网地理接线图为基础,针对220 kV及以上高压输电电网通信系统构建简化电力通信网络拓扑模型,其中不包含配电网通信系统。在该模型中,忽略各厂站(如发电厂、变电站、换流站)与调度中心之间的差异,将其统一视为相同节点。鉴于通信线路可双向通信,节点间的通信线路均设为无向边。将拓扑模型抽象为无向图 $G=(V, E)$,其中 V 为节点集, E 为边集。同时定义网络中承载的业务路由由集合 $P = \{p_s^m\}$,其中 p_s^m 表示业务 s 的第 m 条

路由方案。基于该拓扑模型,将其节点映射到超网络中,将一条完整业务链路中的节点集合 $V' = V$ 映射为一条超边。定义基于业务的电力超网络为 $G_H = (V', E')$, 其中 V' 为节点集,可由 $V' = V$ 获得; E' 为边集,每条超边 $e \in E'$ 由

其所连接的节点组成,即 $e \subseteq V'$ 。遍历每条完整的业务链路 p_s^m ,若节点 v_i 和 v_j 在同一业务链路中,则将其添加到对应的超边中,直至所有节点和线路检索完毕。




Fig. 2 Service-based power supernetwork

图 2 基于业务的电力超网络

3.2.2 超核分解与节点重要度评估

超图作为网络的高阶概括,允许节点在任意大小的超边中交互。高阶相互作用可产生新的结构和现象,从而更好地表示网络特征。基于电力超网络进行超核分解可识别影响电力通信网络稳定性和传播特性的关键节点,从而更集中地研究网络的核心部分。电力单元重要度越高,节点在业务层面对于整体电力通信网络的影响越大。采用超图的核度中心性刻画节点重要度,具体方法为:首先设定超核分解参数,即超边数量 k 和超边度 c ,在 (k, c) -超核中,所有节点至少属于 k 个超边度大于等于 c 的超边;其次定义节点 v_i 的 c -壳索引为 $C_c(i) = k$,表示节点 v_i 连接了 k 个超边度为 c 的超边。 $S(k, c)$ 表示所有满足 $C_c(i) = k$ 的节点集合。节点重要度定义为其在超图中的核度中心度 $I(i)$ 。计算公式为:

$$I(i) = \sum_{c=2}^M g(c) C_c(i) / k_{\max}^c \quad (24)$$

式中: M 为超图中超边度的最大值; $g(c)$ 为任意权函数,表示不同规模的高阶作用具有不同的影响力,通常可简单地令 $g(c)=1$; $k_{\max}^c$ 为使 $S(k, c)$ 不为空的 k 的最大值。

采用基于网络拓扑关联的电力通信风险模型对各节点进行风险预测,识别电力网络中的脆弱环节,得到节点毁伤概率。随后使用蒙特卡罗模拟法将各单元的毁伤概率转化为网络的毁伤形态。

3.2.3 网络性能评估与韧性计算

节点重要度越高,其在网络中的影响力越强,遭受毁伤后造成的不良后果越严重。在毁伤修复过程中,由于网络节点繁多,修复资源有限,应优先满足重要度高的节点。根据节点重要度 $I(i)$ 的顺序分配具体的修复预算 b 和修复资源 r ,对节点进行抢修。多次迭代直至资源耗费达到上限或控制时间,使网络韧性恢复至可实现的最佳状态。

(1)业务的实时性能。根据输入的修复条件进行恢复过程仿真,检查各业务链路集合 P_s 的畅通状态,获得业务的实时性能 $F_s(t)$,表示电力通信网络中的业务 s 在 t 时刻的性能时程响应函数(Performance Response Function, PRF)。计算公式为:

$$F_s(t) = \frac{|\overline{P_s}|}{|P_s|} \frac{\left(\sum_{\omega \in W_s} Q_{\omega} / Z_{\omega} \right)}{|W_s|} \quad (25)$$

式中: P_s 表示业务 s 的路由集合; $\overline{P_s}$ 表示 P_s 中当前畅通的链路; W_s 表示该业务涉及子网络中的电力供需节点对的集合; Q_{ω} 表示点对 ω 的输电量, Z_{ω} 表示点对 ω 之间的等值阻抗,即将电网中的发电机、变压器、输电线路等多种电气设备的阻抗按照一定的规则合并计算,采用一个等效的阻抗来表示整个电网或电网某一部分在特定运行条件下对电流的阻碍作用,从功能维度上反映了电网的输电效能。

(2)电力通信网络在 t 时刻的总性能。基于各业务的实时性能 $F_s(t)$ 计算电力通信网络在 t 时刻的总性能 $F(t)$ 。公式为:

$$F(t) = \sum \theta_s F_s(t) \quad (26)$$

式中: θ_s 表示业务 s 的优先级权重系数。

记录数据并绘制网络 PRF 曲线,获取网络效能的动态表现。

(3)电力网络毁伤韧性评估值。根据 PRF 曲线计算电力网络毁伤韧性评估值,完成网络韧性评估。电力网络毁伤韧性的大小可表示为:

$$R = A_F / A_N = \int_{t_0}^{t_R} F(t) dt / \int_{t_0}^{t_R} N(t) dt \quad (27)$$

式中: $F(t)$ 为电力通信网络的 PRF; $N(t)$ 为网络正常通信时的效能函数,一般简化为常数处理; t_0 为起始控制时间; t_R 为结束控制时间。

4 实验方法与结果分析

4.1 实验环境

实验操作系统为 Ubuntu 20.04.3 LTS,内存为 256 GB DDR4 @3200MHz, CPU 为 AMD Ryzen Threadripper 3970X 32-Core Processor,显卡为 NVIDIA GeForce RTX 3090×2,编程环境为 Pytorch 1.12.0 和 Python 3.8.15。

4.2 数据集

使用国家电网某省电力通信网络监测数据建立数据集。该数据集包括 2023 年 6 月 15 日至 2024 年 6 月 15 日每隔半个小时采集一次的电力通信网络监测数据,共计 17 568 个时间点,233 865 216 条记录,按照 6:2:2 的比例划分为训练集、验证集和测试集。

4.3 评价指标

采用准确率(Accuracy)、精确度(Precision)、召回率(Recall)和 F1 分数作为评价指标,这 4 个指标的值越大,表示模型性能越好。

4.4 实验结果与分析

4.4.1 比较实验

选取 DCRNN^[22]、GWNet^[23]、GMAN^[24]、AGCRN^[25] 和 ASTGNN^[26] 5 个基线模型与本文模型进行比较。结果见表 1。可以看出,与基线模型相比,本文模型的所有指标分数均为最高。这是由于 DCRNN 依赖预定义固定扩散矩阵,无法适应电力网络故障重构或拓扑变更导致的动态连接变化。GWNet 基于图小波变换的频域分析对拉普拉斯矩阵进行特征分解,计算复杂度随节点数呈立方级增长,难以适用于大规模电力网络。GMAN 的多头注意力机制引入大量参数,在节点数较多时训练效率低下,无法满足电力系统秒级预警的实时性需求。AGCRN 虽通过自适应学习生成节点嵌入,但图结构在本质上为静态,无法显式建模不同时间窗口下节点间空间依赖的动态演化。ASTGNN 将时间与空间特征混合输入门控单元,导致时序特征的局部连续性被稀释。本文模型通过时空图卷积块分离空间与时间特征的提取路径,其中 GCN 层专注于捕获当前时刻的空间拓扑关联(如节点度、介数的实时影响);一维卷积层沿时间轴滑动提取时序局部连续性(如连续时段的负荷波动趋势),并且通过多层时空卷积层堆叠,提升模型对复杂动态场景的表征能力,计算复杂度远低于频域方法;同时采用因果学习模块降维,通过动态部分祖先图剔除伪相关边,降低了图结构复杂度,间接提升了计算效率。

Table 1 Performance comparison of different models

表 1 不同模型性能比较

基线模型	Accuracy	Precision	Recall	F1
GMAN	0.835 7	0.645 2	0.689 3	0.666 5
DCRNN	0.840 2	0.673 9	0.642 0	0.657 6
GWNet	0.854 6	0.762 9	0.574 3	0.655 3
ASTGNN	0.858 1	0.712 4	0.686 1	0.699 0
AGCRN	0.886 2	0.825 6	0.674 7	0.742 6
本文模型	0.901 7	0.838 6	0.741 3	0.786 9

4.4.2 消融实验

使用基于其他 GCN 的模型、仅使用一层 ST-ConV Block 的模型和未使用因果学习模块的模型进行消融实验。表 2 为本文模型和以上 3 种变体的性能指标结果。可以看出,相较于基于其他 GCN 的模型,本文模型在 Accuracy、Precision、Recall 和 F1 上分别提升 5.9%、19.2%、13.0% 和 16.0%。同样地,仅使用一层 ST-ConV Block 和未使用

因果学习模块也会使得模型性能下降。因此,GCN、两层 ST-ConV Block 和因果学习模块对于本文模型而言缺一不可。

Table 2 Ablation experiment result

表 2 消融实验结果

模型变体	Accuracy	Precision	Recall	F1
使用基于其他 GCN 的模型	0.851 2	0.703 6	0.656 1	0.679 0
仅使用一层 ST-ConV Block 的模型	0.777 6	0.529 6	0.534 6	0.532 1
未使用因果学习模块的模型	0.820 8	0.702 8	0.436 7	0.538 7
本文模型	0.901 7	0.838 6	0.741 3	0.787 0

4.4.3 参数敏感性

为研究因果学习模块中参数的敏感性,分析不同超参数对模型检测性能的影响。对模型的时间窗口 K 和隐变量维度 Z 展开分析,实验结果如图 3 和图 4 所示。由图 3 可知,模型性能会随时间窗口 K 的变化产生不同程度的波动,在本文实验涉及的 5 个维度中,当 $K=10$ 时,模型的风险预测性能最好。当时间窗口较小时,模型训练速度更快,但会削弱模型对时间序列的捕捉能力;反之,时间窗口过大不仅会使模型训练变慢,而且难以捕捉到小的异常事件,导致风险预测精度下降。




Fig. 3 Sensitivity analysis for time window K

图 3 时间窗口 K 的敏感性分析

由图 4 可知,本文模型对隐变量维度 Z 也较为敏感。当 $Z=40$ 时,模型表现最佳。当隐变量维度较小时,会导致大量信息损失,严重影响因果学习模块的学习效果;当隐变量维度过大时,信息过于复杂,容易出现过拟合现象。

4.4.4 毁伤韧性评估

节点重要度能确定哪些节点对电力通信网络连通性的影响较大,可为电力通信网络毁伤韧性评估奠定基础。表 3 为电力通信网络节点重要度的计算结果。可使用攻击模拟器来模拟网络攻击行为,在电力通信网络运行至第 3 h 时对其进行攻击,接着读取修复预算,并按照表 3 中的节点重要度排序对网络进行修复。

图 5 为修复预算 b 分别为 1 500 和 3 000 单位,以及修复资源 r 分别为 10 和 20 单位这 4 种情况下节点网络 PRF




Fig. 4 Sensitivity analysis for hidden variable dimension Z

图 4 隐变量维度 Z 的敏感性分析

Table 3 Node importance calculation result

表 3 节点重要度计算结果

节点序号	节点重要度	节点序号	节点重要度	节点序号	节点重要度
1	0.352	9	0.854	17	0.465
2	0.294	10	0.284	18	0.785
3	0.384	11	0.394	19	0.564
4	0.465	12	0.615	20	0.648
5	0.584	13	0.581	21	0.584
6	0.684	14	0.495	22	0.165
7	0.481	15	0.671	23	0.485
8	0.594	16	0.584	24	0.384

曲线的变化趋势。可以看出,电力通信网络遭受攻击后,增加修复预算 b 和修复资源 r 均会使 PRF 有所提高。




Fig. 5 PRF curve of node network

图 5 节点网络的 PRF 曲线

图 6 为不同修复预算和修复资源条件下的电力通信网络毁伤韧性评估结果。可以看出,增加修复预算 b 和修复资源 r 均能使网络韧性得到提升。但是,过度投入修复预算和修复资源会导致韧性提升到达瓶颈,从而导致一定的资源浪费。因而,应根据不同的决策场景和需求对修复预算 b 和修复资源 r 进行优化配置,以最集约的方式实现

最大体系韧性。




Fig. 6 Damage toughness assessment results

图 6 毁伤韧性评估结果

5 结语

本文针对现有电力网络韧性评估方法忽视业务功能特性、数据利用率不足的问题,提出基于改进 GCN 的电力通信风险预测及毁伤韧性量化评估方法,通过数据处理、时空图卷积与因果学习模块实现风险预测,通过构建基于业务的电力超网络来完成毁伤韧性量化评估。实验结果表明,所提方法预测性能良好。然而当前研究仍存在不足,即修复策略的智能化水平有待提升。后续计划结合强化学习技术,实现修复策略的自动化生成,提高决策的科学性和及时性,以更好地适配新型电力系统的需求。

参考文献:

- [1] LU X, WANG W, MA J. An empirical study of communication infrastructures towards the smart grid: design, implementation, and evaluation[J]. IEEE Transactions on Smart Grid, 2013, 4(1): 170-183.
- [2] XU L, GUO Q L, LIU X Z, et al. Robust optimization method of communication network to improve resilience of cyber-physical power system[J]. Automation of Electric Power Systems, 2021, 45(3): 68-75.
许璐,郭庆来,刘新展,等.提升电力信息物理系统韧性的通信网鲁棒优化方法[J].电力系统自动化,2021,45(3):68-75.
- [3] HAN X. Damage toughness assessment method of power backbone communication network based on power big data[J]. Telecommunications Science, 2023, 39(5): 136-143.
韩雪.基于电力大数据的电力骨干通信网络毁伤韧性评估方法[J].电信科学,2023,39(5):136-143.
- [4] QI Y, LI Q M, LIU F Y. Network fault intelligent diagnosis based on BP neural network[J]. Microelectronics and Computer, 2004, 21(10): 10-13.
戚涌,李千目,刘凤玉.基于 BP 神经网络的网络故障智能诊断方法[J].微电子学与计算机,2004,21(10):10-13.
- [5] HE Q S, ZHOU W T, XU H F, et al. Network fault location algorithm based on multi-domain partitioning in communication and information networks[J]. Journal of Nanjing University of Posts and Telecommunications

- (Natural Science), 2017, 37(1):79-84.
- 何清素,周文婷,许鸿飞,等. 基于多域划分的通信信息网络故障定位算法[J]. 南京邮电大学学报:自然科学版, 2017, 37(1):79-84.
- [6] NIE X Y, XIE G, LI Y, et al. Fault diagnosis of power communication network based on stacked relational sparse autoencoder[J]. Power System Protection and Control, 2019, 47(19):158-163.
- 聂晓音,谢刚,李洋,等. 基于栈式相关性稀疏自编码的电力通信网故障诊断[J]. 电力系统保护与控制, 2019, 47(19):158-163.
- [7] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[DB/OL]. <https://arxiv.org/abs/1710.10903>.
- [8] YANG H, LI X W, SI Z J, et al. Accident prediction of power distribution network based on graph neural network[J]. Computer Systems and Applications, 2020, 29(9):131-135.
- 杨华,李喜旺,司志坚,等. 基于图神经网络的配电网故障预测[J]. 计算机系统应用, 2020, 29(9):131-135.
- [9] LI T T, AN L P, ZENG C Y, et al. Identifying key nodes via GAT and topological potential [C]//Proceedings of the 2021 China Automation Conference, 2021:308-312.
- 李婷婷,安郎平,曾诚逸,等. 基于图注意力神经网络与拓扑势的关键节点识别[C]//2021中国自动化大会论文集, 2021:308-312.
- [10] FU H, WANG Y F. The application research of deep learning in electric power communication data analysis and prediction[J]. China Computer and Communication, 2023, 35(23):184-186.
- 付晖,王艳飞. 深度学习在电力通信数据分析与预测中的应用研究[J]. 信息与电脑, 2023, 35(23):184-186.
- [11] ZHANG S L, LIU J, YAN L C, et al. Failure diagnosis and intelligent reconstruction method based on deep learning in electric backbone communication networks[J]. Computer Engineering & Software, 2018, 39(3):194-198.
- 张书林,刘军,闫龙川,等. 基于深度学习的电力骨干通信网故障诊断研究[J]. 软件, 2018, 39(3):194-198.
- [12] BILLINTON R, ALLAN R N. Reliability evaluation of engineering systems[M]. New York: Plenum Press, 1992.
- [13] LI W. Risk assessment of power systems: models, methods, and applications[M]. New York: John Wiley & Sons, 2014.
- [14] ALBERT R, BARABÁSI A L. Statistical mechanics of complex networks [J]. Reviews of Modern Physics, 2002, 74(1):47.
- [15] CRUCITTI P, LATORA V, MARCHIORI M. Model for cascading failures in complex networks [J]. Physical Review E, 2004, 69(4):045104.
- [16] DEB K. Nonlinear goal programming using multi-objective genetic algorithms[J]. Journal of the Operational Research Society, 2001, 52(3):291-302.
- [17] KAMBLI A N. A robust optimization approach to manage uncertainty in local agricultural production in mid-western United States [D]. Columbia:University of Missouri-Columbia, 2019.
- [18] KAPLAN S, GARRICK B J. On the quantitative definition of risk [J]. Risk Analysis, 1981, 1(1):11-27.
- [19] ZADEH L A. Fuzzy sets [J]. Information and Control, 1965, 8(3):338-353.
- [20] SHI J. Research on temporal and spatial load forecasting and current optimization technology based on graph neural network [D]. Wuhan: Huazhong University of Science and Technology, 2021.
- 史炯. 基于图神经网络的时空负荷预测与潮流优化技术研究[D]. 武汉:华中科技大学, 2021.
- [21] ZHONG Z, GUAN L, SU Y S, et al. Power system transient stability assessment based on graph attention deep network[J]. Power System Technology, 2021, 45(6):2122-2130.
- 钟智,管霖,苏寅生,等. 基于图注意力深度网络的电力系统暂态稳定评估[J]. 电网技术, 2021, 45(6):2122-2130.
- [22] LI Y, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting [DB/OL]. <https://arxiv.org/abs/1707.01926>.
- [23] WU Z, PAN S, LONG G, et al. Graph wavenet for deep spatial-temporal graph modeling [DB/OL]. <https://arxiv.org/abs/1906.00121>.
- [24] ZHENG C, FAN X, WANG C, et al. GMAN: a graph multi-attention network for traffic prediction [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020:1234-1241.
- [25] BAI L, YAO L, LI C, et al. Adaptive graph convolutional recurrent network for traffic forecasting[DB/OL]. <https://arxiv.org/abs/2007.02842>.
- [26] GUO S, LIN Y, WAN H, et al. Learning dynamics and heterogeneity of spatial-temporal graph data for traffic forecasting[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(11):5415-5428.

(责任编辑:尹晨茹)