DOI：10.13234/j.issn.2095-2805.2026.5.219 **中图分类号**：TM715 **文献标志码**：A

基于EGAT的高比例分布式光伏配电网的脆弱性辨识

王宇飞，吕晓宁，时 海，魏云峰
(国网冀北电力有限公司张家口供电公司，张家口 075000)

摘要：针对高比例分布式光伏PV(photovoltaic)配电网调控和运行方式的复杂性而采用传统方法难以辨识其脆弱性的问题，提出一种基于边缘特征图注意力神经网络EGAT(edge-feature graph attention network)进行状态估计、进一步结合越限指标以识别配电网脆弱性的方法。首先，将配电网母线作为图网络节点，母线间的传输线路视为边，根据节点和线路的关系矩阵构建配电网拓扑结构数据集；其次，将每条传输线路的功率和其连接的母线电压组成边缘特征矩阵；随后，利用EGAT层对特征进行提取学习，其中每个母线和传输线路被赋予1个注意力权重；然后，针对光伏配电网不同的运行场景，训练EGAT模型并整合加入迁移学习；最后，通过构建节点脆弱性指标和线路脆弱性指标，全面评估在不同场景下的配电网脆弱性情况。算例测试显示，该方法能有效应对高比例分布式光伏接入配电网时的脆弱性辨识挑战，准确识别高比例分布式光伏配电网中光伏出力不同及拓扑结构变化而产生的脆弱节点和线路。

关键词：分布式光伏；配电网；脆弱性辨识；边缘特征图注意力神经网络；节点脆弱性指标；线路脆弱性指标

Vulnerability Identification of High Proportion Distributed Photovoltaic Power Distribution Network Based on EGAT

WANG Yufei, LÜ Xiaoning, SHI Hai, WEI Yunfeng
(State Grid Jibei Electric Power Co., Ltd., Zhangjiakou Power Supply Company, Zhangjiakou 075000, China)

Abstract: To address the complexities in regulating and operating distribution grids with a high proportion of distributed photovoltaic (PV) systems, which challenges conventional methods in vulnerability identification, a novel methodology utilizing an edge-feature graph attention network (EGAT) is proposed for state estimation and further identification of vulnerabilities via over-limit indicators. Initially, busbars within the distribution network are conceptualized as nodes of a graph, with transmission lines serving as edges, thus forming a topological dataset grounded in their connectivity matrix. Subsequently, the power of each transmission line and the voltages at the connected busbars are consolidated into an edge feature matrix. The employment of EGAT layers facilitates targeted feature extraction and learning, where attention weights are attributed to each node and transmission line. In response to various operational scenarios of the PV distribution network, the EGAT model undergoes training with the integration of transfer learning techniques. Ultimately, by establishing indices for node vulnerability and line vulnerability, a thorough evaluation of the network's vulnerability under different scenarios is achieved. Demonstrative case studies validate the effectiveness of this approach in recognizing vulnerabilities within distribution networks with substantial integration of distributed PV systems, accurately identifying vulnerable nodes and lines induced by fluctuations in PV output and topological modifications.

Keywords: Distributed photovoltaic; distribution network; vulnerability identification; edge-feature graph attention network; node vulnerability index; line vulnerability index.

收稿日期：2024-01-18；**修回日期**：2024-02-28，2024-03-19，2024-04-12；**录用日期**：2024-05-06；**网络首发日期**：2024-06-19
基金项目：国网张家口供电公司 2023 年群众性创新项目(520107230002)
This work is supported by 2023 Mass Innovation Project of State Grid Zhangjiakou Power Supply Company under the grant 520107230002

为实现“双碳”目标，风能、太阳能等新能源正在加速向电网中渗透，逐步成为电网供应的主力能源。然而，随着分布式光伏规模和比重持续增长，电网内潜藏的脆弱性问题也日益凸显[1]。配电网脆弱性不仅受到结构因素影响，还与调控策略及光伏状态的快速转换密切相关[2]。这些脆弱性问题可能引发局部电网故障，进而危及整个电网的稳定运行，引发大面积停电事故[3]，已有研究明确指出，关键线路及节点的失效是引发严重电力事故的主要原因[4]。

近年来的研究中，文献[5]采用了复杂网络理论和电气介数进行脆弱性分析；文献[6]从复杂网络的视角，对电网的运行状态进行了深入探讨。但这些研究主要集中在电网的静态拓扑结构上，未充分考虑由于光伏系统引入的动态变化、功率不稳定性和实际电气特性。文献[7]从线路故障发生率和造成的影响出发，利用风险理论对输电线路进行脆弱性评估；文献[8]从系统角度计算潮流结果，并设置潮流增长率泰尔熵作为指标对脆弱线路进行辨识，然而，随着多个分布式光伏系统的加入，能量流动路径和分布模式变得更加复杂；文献[9]利用最小鉴别信息原理对光伏发电单元进行综合评价，提升了评价的客观性，但对数据质量的依赖较大；文献[10]利用灰狼算法优化的极限学习机 GWO-ELM(grey wolf optimizer-extreme learning machine)来提高逆变器开路故障的诊断精度；文献[11]通过主动频率偏移技术检测孤岛现象，尽管检测灵敏度和准确性得到提升，但在多种分布式资源共存的环境中容易受到外界干扰，而深度学习克服了传统潮流分析在动态变化适应和大规模数据处理上的局限，通过高效学习和精准故障诊断，为复杂电网系统带来可靠性和安全性提升；文献[12]采用改进径向基函数 RBF(radial basis function)神经网络诊断光伏系统中的故障类别和位置，但面对动态变化环境时对实时数据适应性有限；文献[13]基于门控循环单元-反向传播 GRU-BP(gated recurrent unit-back propagation)神经网络对锂离子电池部分充电数据进行健康状态 SOH(state of health)估计；文献[14]提出了基于卷积神经网络-长短期记忆 CNN-LSTM(convolutional neural network-long short-term memory)网络的直流微电网稳定性判别方法，表明深度学习方法在电气工程多个领域均具备应用价值。

在配电网脆弱性分析中，基于运行状态的脆弱性评估方法通常需构建直观指标，展示节点和线路的运行状态，文献[15]提出基于混合整数线性规划的加权最小绝对值状态估计方法能够提高估计精度，但计算复杂度较高；文献[16]通过构建城市跨层耦合模型，分析计及供水服务损失的电网脆弱性，进而提出相应的城市电网脆弱性评价指标；文献[17]通过基于多种拓扑结构的图数据训练神经网络得到配电网母线的电压状态；文献[18]提出了基于改进图卷积网络的物理-数据融合状态估计方法，上述方法虽然提高了状态估计的准确性和效率，但主要关注节点和节点间的关系，对电网线路特征的考虑较少。

相比之下，本研究提出的融合量测数据特征与电网结构特征的基于边缘特征图注意力神经网络 EGAT(edge-feature graph attention network)策略，旨在充分利用图卷积网络在特征提取方面的优势，并通过迁移学习策略提高模型的稳健性和泛化性。首先，将电网拓扑图与量测数据相融合，将其转化为描述电网中各节点与连接边的高维图特征；其次，为同时考虑配电网中节点和边的脆弱性，构建了 EGAT 模型，模型采用图注意力网络结构，不仅可以识别出脆弱性，还能根据电网运行状态调整对边与节点的重视程度；再次，为增强模型在面对不同拓扑结构配电网时的稳健性和泛化能力，引入迁移学习策略，使 EGAT 模型能够借鉴在已有电网结构上学到的知识，快速适应并优化对其他电网结构的分析；最后，构建节点和线路脆弱性评价指标，用以评估配电网脆弱性情况。这一综合策略不仅确保了脆弱性辨识的准确性，而且提高了模型的适用性和稳定性。

1 边缘特征图注意力神经网络

1.1 节点电压注意力模块

节点电压注意力模块负责接收配电网中节点

电压特征集 $\boldsymbol{X}$ 和边缘功率特征集 $\boldsymbol{E}$，生成新的节点电压特征集 $\boldsymbol{X}'$。EGAT 结构如图 1 所示，图中：$\boldsymbol{X}_m^L$ 为第 L 层中第 m 个注意力头所对应的节点特征矩阵；$\boldsymbol{E}'$为经过边缘映射矩阵变换后的公共形式边缘特征集；X_{final} 为最终输出的节点特征集。在边缘功率特征集 $\boldsymbol{E}$ 中，将 $\boldsymbol{E}$ 转换为公共形式 $\boldsymbol{E}'$。$\boldsymbol{E}'$ 中的每个元素均可表示为 e_{ij}，i 和 j 表示边两端的节点。从 $\boldsymbol{E}$ 到 $\boldsymbol{E}'$ 的变换通过 1 个 $N\times N\times M$ 张量的边缘映射矩阵 $\boldsymbol{M}_E$ 的矩阵乘法来实现，即

$$\boldsymbol{E}' = \boldsymbol{M}_E \boldsymbol{E} \tag{1}$$

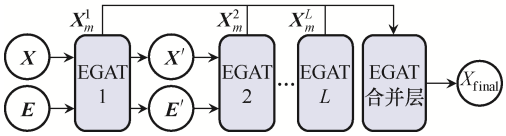


图 1　EGAT 结构

Fig. 1 Structure of EGAT

对注意力权重执行归一化

$$\alpha_{ij} = \frac{\exp[\text{LeakyReLU}(\boldsymbol{a}^{\mathrm{T}}[\boldsymbol{x}_i \,\|\, \boldsymbol{x}_j \,\|\, \boldsymbol{e}_{ij}])]}{\sum_{k\in N_i} \exp[\text{LeakyReLU}(\boldsymbol{a}^{\mathrm{T}}[\boldsymbol{x}_i \,\|\, \boldsymbol{x}_k \,\|\, \boldsymbol{e}_{ik}])]} \tag{2}$$

式中：LeakyReLU(·) 为非线性激活函数；$\boldsymbol{a}^{\mathrm{T}}$ 为权向量的转置用于参数化；$\boldsymbol{x}_i$、$\boldsymbol{x}_j$、$\boldsymbol{x}_k$ 分别为节点 i、j、k 的特征向量；$\boldsymbol{e}_{ij}$ 与 $\boldsymbol{e}_{ik}$ 分别为边 (i,j) 和 (i,k) 的边特征向量；‖表示向量连接操作；N_i 为节点 i 的一阶邻居和节点 i 本身的集合。

对加权和使用非线性激活函数 σ 进行计算，并作为该节点注意力模块的输出，可表示为

$$\boldsymbol{x}_i' = \sigma\Big(\sum_{j\in N_i} \alpha_{ij}\boldsymbol{x}_j\Big) \tag{3}$$

式中：$\boldsymbol{x}_i'$ 为更新后节点 i 的特征向量。

1.2　边缘功率注意力模块

通过聚合相邻线路功率特征来更新每条线路功率特征。如图 2 所示，切换图中节点和边的角色来实现聚合：在原始图的基础上创建一张新的图，其节点和边分别为原始图的边和节点。

节点特征集通过使用节点映射矩阵 $\boldsymbol{M}_X$ 转换成邻接形式，对于每条边 p，其归一化注意力权重 β_{pq} 可表示为

$$\beta_{pq} = \frac{\exp[\text{LeakyReLU}(\boldsymbol{b}^{\mathrm{T}}[\boldsymbol{e}_p \,\|\, \boldsymbol{e}_q \,\|\, \boldsymbol{x}_{pq}])]}{\sum_{k\in N_p} \exp[\text{LeakyReLU}(\boldsymbol{b}^{\mathrm{T}}[\boldsymbol{e}_p \,\|\, \boldsymbol{e}_k \,\|\, \boldsymbol{x}_{pk}])]} \tag{4}$$

式中：$\boldsymbol{b}^{\mathrm{T}}$ 为大小为 $R^{2F_E'+F_X'}$ 权向量的转置；$\boldsymbol{e}_p$、$\boldsymbol{e}_q$ 为边集合中的特征向量；$\boldsymbol{x}_{pq}$ 和 $\boldsymbol{x}_{pk}$ 分别为节点 (p,q) 和 (p,k) 的特征向量；N_p 为边 p 的一阶邻居集。

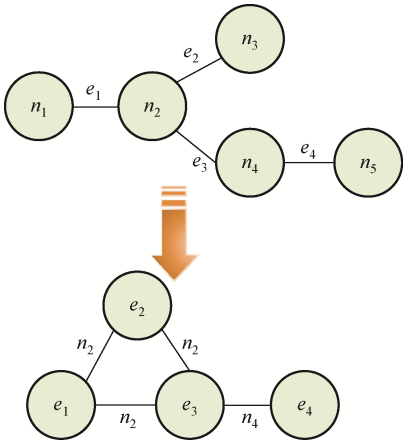


图 2　图形变换

Fig. 2 Graphic transformation

边缘功率特征集的计算可表示为

$$\boldsymbol{e}_p' = \sigma\Big(\sum_{q\in N_p} \beta_{pq}\boldsymbol{e}_q\Big) \tag{5}$$

式中，$\boldsymbol{e}_p'$ 为更新后边 p 的特征向量。

1.3　EGAT 架构

本研究采用 EGAT 方法评估未配置测量设备的节点电压和线路功率，从而实现对光伏配电网数据环境的全面洞察。根据脆弱性程度指标确定配电网脆弱节点和线路。如图 3 所示，节点 1、4、6、7 代表已配置测量设备，直线代表已配置测量设备

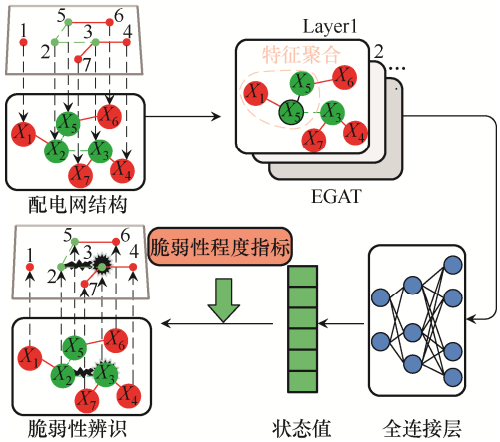


图 3　脆弱性辨识流程

Fig. 3 Flow chart of vulnerability identification

的线路；节点 2、3、5 表示未配置测量设备，虚线表示未配置测量设备的线路。

节点状态输出采用的损失函数 $\mathcal{L}_x$ 为

$$\mathcal{L}_x=\frac{1}{bK}\sum_{h=1}^{b}\sum_{i=1}^{K}(x_i-\hat{x}_i)^2 \tag{6}$$

式中：b 为 1 个批次训练的样本数量；K 为样本中的关键模型总数；x_i 为真实值；$\hat{x}_i$ 为估计值。

边上回归任务采用的损失函数 $\mathcal{L}_e$ 为

$$\mathcal{L}_e=\frac{1}{bK}\sum_{h=1}^{b}\sum_{i=1}^{K}(e_i-\hat{e}_i)^2 \tag{7}$$

式中：e_i 为实际值；$\hat{e}_i$ 为模型输出值。

总损失函数 $\mathcal{L}$ 为

$$\mathcal{L}=w_0\mathcal{L}_x+w_1\mathcal{L}_e \tag{8}$$

式中，w_0 和 w_1 为 2 类预测任务的权重，根据训练情况和实际需求来设定。根据配电网已知的节点与线路量测量的数量，初步设定本文中 $w_0=4$，$w_1=6$。

1.4 迁移学习

为适应配电网拓扑结构的复杂多样性，本文采用迁移学习方法设计了针对不同拓扑结构配电网脆弱性辨识的模型。其迁移学习原理如图 4 所示，具体步骤如下。

步骤 1 收集具有不同节点数量、负载水平、运行状况及安装配置的配电网结构及数据。

步骤 2 运用 EGAT 模型建立具备一定泛化能力的脆弱性辨识模型，以适应网络拓扑的变化。

步骤 3 保持 EGAT 模型的参数和架构不变，将其预训练后直接应用于具有新拓扑结构的配电网，使用新配电网运行数据作为测试集，以检验模型对新配电网的适应性。

步骤 4 根据特定配电网的拓扑结构和数据特征，通过微调方法进一步完善模型部署，采用预训练的模型参数作为起点，使用新配电网的数据进行训练，冻结所有隐藏层，仅对全连接层进行微调，以增强模型的应用性能。

将所有历史信息分割成多个子集，每个子集独立地执行相同的辨识流程。采用加权求和的策略综合利用各个子集的模型，即根据每个模型在验证集上的性能为其分配权重，然后将加权后的模型输出求和，如图 5 所示。图中：x 为节点序号；y 为验证集损失率不变或变大情况下的迭代次数；z 为迭

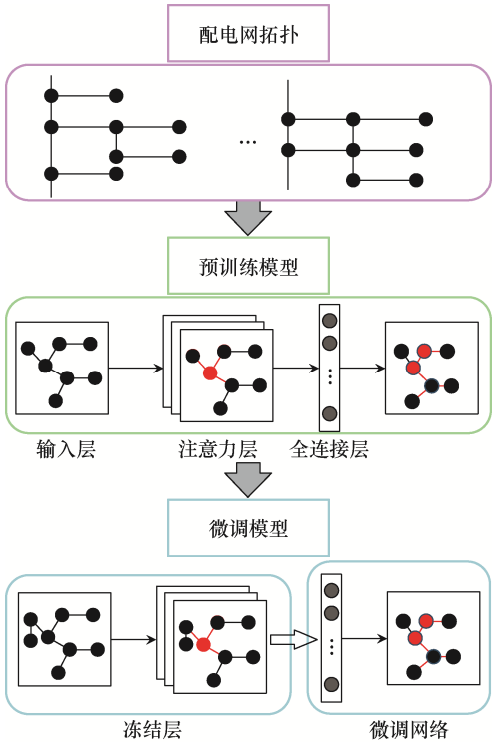


图 4 迁移学习流程

Fig. 4 Flow chart of transfer learning

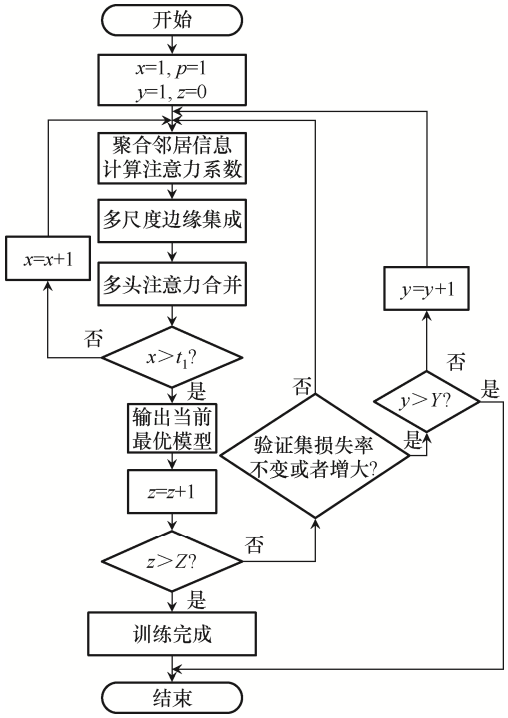


图 5 迁移学习预训练流程

Fig. 5 Flow chart of transfer learning pre-training

代次数；Z 、Y 分别为最大迭代次数和早停迭代次数，可以帮助模型在训练时既不过早地终止，也不过度迭代，确保模型的鲁棒性和泛化能力。

2　脆弱性评价指标

2.1　节点电压脆弱性指标

节点电压脆弱性指标表征了系统中各母线电压超出额定电压的程度，即

$$U^{*}=(U_i'-U_i)/U_i\times 100\% \tag{9}$$

式中：U^{*} 为母线 i 的电压越限情况；U_i' 为母线 i 的当前电压；U_i 为母线额定电压。

2.2　线路功率脆弱性指标

线路功率脆弱性指标表征了系统中各条线路输送功率超过额定功率的程度，即

$$P_p=(P_i-P_{i,\max})/P_{i,\max}\times 100\% \tag{10}$$

式中：P_p 为当前线路传输功率过载情况；P_i 为线路当前传输功率；$P_{i,\max}$ 为线路额定传输功率。

3　算例分析

3.1　实验数据及参数

本文在实验中采用仿真数据来建立量测系统，如图 6 所示，在 IEEE-33 节点系统中 9、14、18、22、25、28 和 33 母线节点装设有微型相量测量装置 μPMU (micro phasor measurement unit)量测设备，光伏发电分别设置在 5、12 和 30 节点。

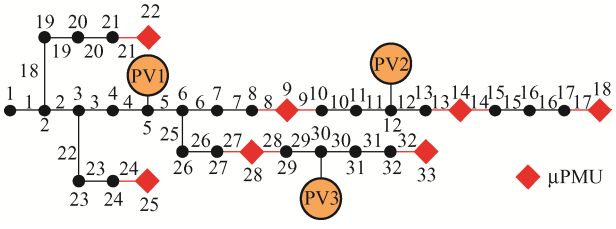


图 6　分布式光伏 IEEE-33 节点系统

Fig. 6 Distributed PV IEEE-33 node system

3.2　模型仿真

将数据集按照 8:1:1 比例进行划分，得到训练集、验证集、测试集样本数分别为 3 200、400、400。使用 7 个节点的电压信息和 10 条线路的功率信息预测其他节点和线路的电压和功率。节点特征矩阵为 7×1 的矩阵，边特征矩阵为 10×1 的矩阵，邻接矩阵维度为 33×33，节点之间有连接设为 1，反之为 0。将节点特征矩阵、边特征矩阵和邻接矩阵组合成 1 个输入张量，作为模型的输入。其中，图注意力层为 2 层，第一层有 8 个注意力头，每个注意力头输出维度为 16，经过第一层学习后，每个节点的特征维度变为 128；第二层有 1 个注意力头。迁移学习微调参数过程中使用 Adam 优化器并设置学习率为 0.001，相比于初始训练学习率更低，以免破坏已学习到的有用特征。使用 0.5 的 Dropout 减少过拟合，Early Stopping 中 patience=12，batch size=32，共进行 80 次迭代。损失率变化情况如图 7 所示，可以看出，模型迭代 10 次左右损失率快速下降，在迭代 70 次之后，损失率稳定在 0.01 左右。

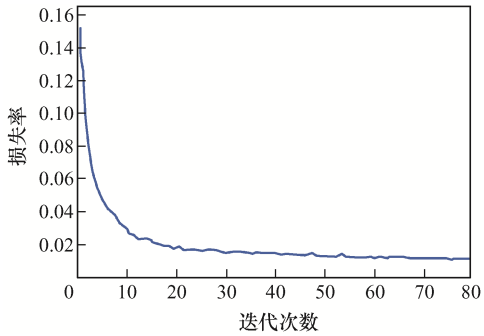


图 7　损失率变化情况

Fig. 7 Variation of loss rate

图 8 展示了利用迁移学习策略的模型在达到 90%精度时，所需的迭代次数远低于直接训练的

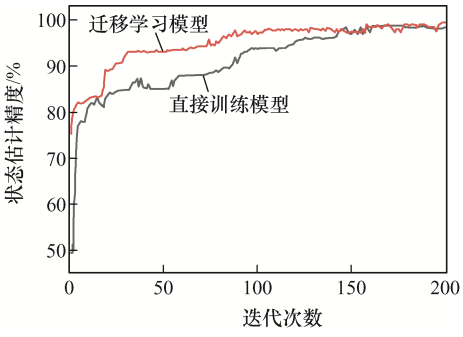


图 8　迁移学习前后效果对比

Fig. 8 Comparison of effects before and after transfer learning

模型。尽管两者最终都实现了高精度，但在初期训练阶段，迁移学习明显提高了模型的收敛速率。构建 9 种不同的典型拓扑结构，见表 1。通过运用迁移学习，能够有效地将之前在原始拓扑结构上学到的知识应用于这些新构造的拓扑结构上。

表 1 拓扑结构描述

Tab. 1 Description of topological structure

拓扑	在原始拓扑基础上的连接关系
拓扑 2	断开支路 14~15，连接支路 9~15
拓扑 3	断开支路 20~21，连接支路 8~21
拓扑 4	断开支路 28~29，连接支路 25~29
拓扑 5	断开支路 32~33，连接支路 18~33
拓扑 6	断开支路 11~12，连接支路 22~12
拓扑 7	断开支路 7~8，连接支路 21~8
拓扑 8	断开支路 24~25，连接支路 29~25
拓扑 9	断开支路 17~18，连接支路 21~8
拓扑 10	断开支路 21~22，连接支路 12~22

在配电网节点 5、12、30 接入不同容量的分布式光伏，光伏出力配置见表 2。

对不同方法进行对比：本文选取加权最小二乘 WLS(weighted least squares)、图注意力神经网络 GAT(graph attention network)、图 Transformer 模型(Graphormer)和图卷积网络 GCN(graph convolutional network)作为所提方法的对比算法。其中 GAT 模型 GAT 层设为 2 层，第一层使用 8 个注意力头，每个头的输出维度为 16；第二层使用 1 个注意力头，旨在对第一层的结果进行整合。激活函数采用 LeakyReLU 函数，Dropout 为 0.5，设优化器学习率为 0.005，权重衰减率为 5×10^{-4}，训练轮数为 500。每次参数更新，采用 batch size=32。

表 2 光伏出力配置

Tab. 2 Configuration of PV output

场景编号	节点 5 PV 有功功率/kW	节点 12 PV 有功功率/kW	节点 30 PV 有功功率/kW	节点 5 PV 无功功率/kvar	节点 12 PV 无功功率/kvar	节点 30 PV 无功功率/kvar
1	600.00	650.00	800.00	365.10	395.53	486.80
2	690.10	740.10	862.90	419.93	450.36	525.08
3	774.54	824.54	921.85	471.32	501.74	560.96
4	848.02	898.02	973.15	516.03	546.45	592.17
5	905.91	955.91	1 013.50	551.25	581.68	616.76
6	944.58	994.58	1 040.50	574.79	605.21	633.19
7	955.89	1 005.80	1 048.40	581.67	612.10	638.00
8	961.60	1 011.60	1 052.40	585.14	615.57	640.42

对节点电压幅值的估计情况如图 9 所示。本文所提方法不仅在节点电压估计方面精度高于其他 4 种算法，同时能够使用本方法计算线路上的传输功率。通过 4 种评价指标的对比可以看出，本文提出的方法在均方根误差 RMSE(root mean square error)上相对于 GAT 降低了 48.59%，相对于 Graphormer 降低了 4.35%，相对于 GCN 降低了 55.10%，相对于 WLS 降低了 71.05%，在平均绝对百分比误差 MAPE(mean absolute percentage error)与平均绝对误差 MAE(mean absolute error)指标上也相应有所降低，并且在决定系数 R^2 得分上取得最高分数。

在不同容量的分布式光伏接入配电网的情况下，使用 EGAT 模型进行状态估计，结果如图 10 和图 11 所示。

图 10 为在不同出力情况的分布式光伏接入配电网时，节点 5~18 及节点 26~33 构成了经过分布式光伏发电的主要传输路径，因此电压幅值的变化明显，有越限的风险。由图 11 可见，线路 1~11

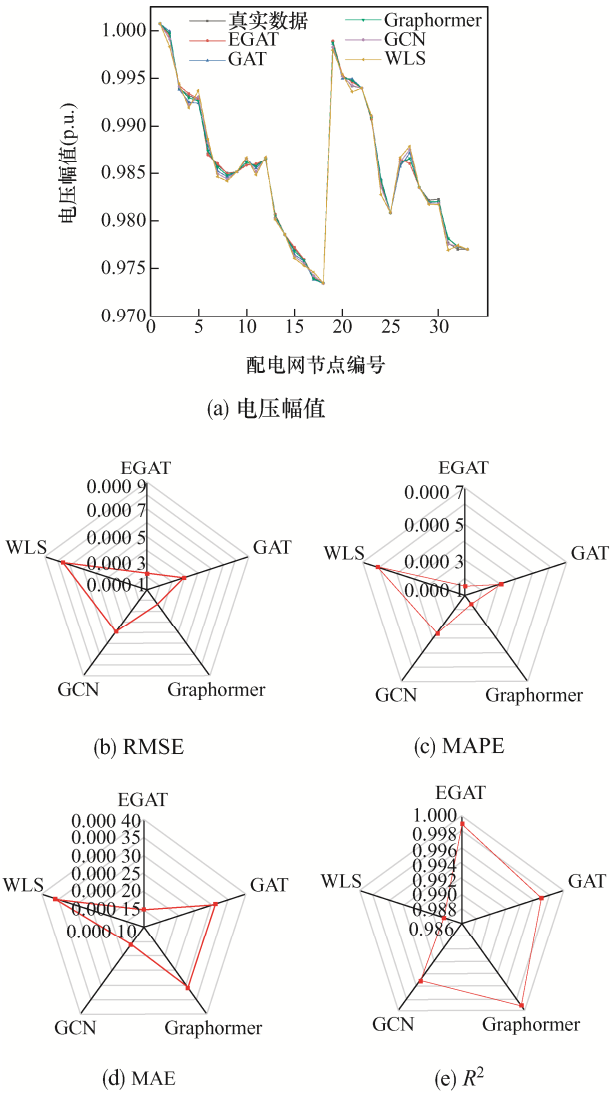


图 9　节点电压幅值估计结果

Fig. 9 Estimation results of node voltage amplitude

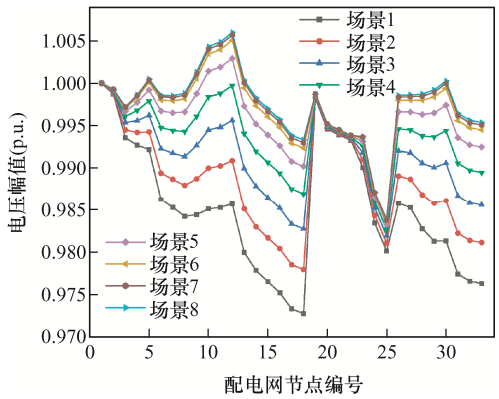


图 10　节点电压幅值

Fig. 10 Node voltage amplitude

及 25~29 的输送功率变动尤为显著。线路 1~11 与节点 5、12 直接相连，而这 2 个节点是接入光伏的主要节点。同样地，线路 25~29 与节点 30 直接相连。当光伏发电量波动时，由于这些线路与光伏节点直接相连，故首先受到影响，导致输送功率发生较大变化。

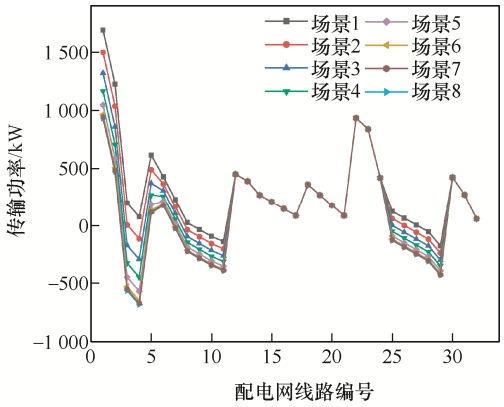


图 11　线路传输功率

Fig. 11 Line transmission power

当配电网的拓扑结构变化时，通过 EGAT 模型进行状态估计得到脆弱节点和线路。对不同的拓扑结构进行分析，由图 12 可见，在拓扑 2 中，节点 12、13、14 等电压差值显著增加，这是由于在节点 9 和 15 之间建立新的连接，改变了网络的电气特性。拓扑 6 在节点 12 处有显著的电压变化，原理上分析是因为节点 11~12 之间的连接被断开，而新的连接从节点 22~12 被建立，导致该节点的电气环境发生显著变化。

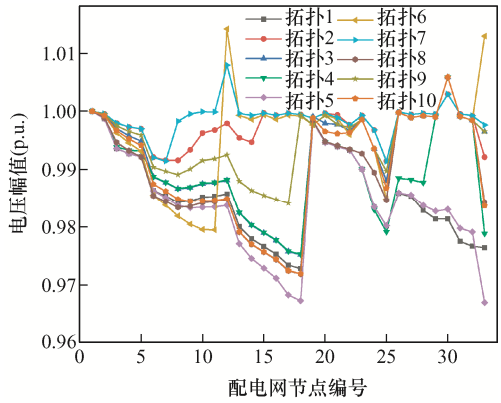


图 12　不同拓扑结构下配电网电节点电压幅值

Fig. 12 Node voltage amplitude of distribution network under different topologies

不同拓扑结构上线路的传输功率也会随着配电网拓扑结构的变化而产生不同的变化情况，如

图 13 所示，通过将拓扑 2~10 的线路传输功率情况与标准拓扑结构 1 进行对比，观察到支路 1、2、11、22、23 和 29 在不同拓扑调整下经历明显功率变化。这些明显的变动暗示这些支路与主要的分布式光伏接入点紧密相关。

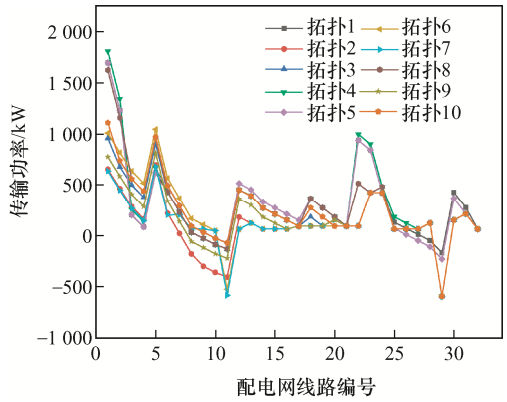


图 13 不同拓扑结构下配电网线路传输功率

Fig. 13 Line transmission power of distribution network under different topologies

在训练好的边缘特征图注意力神经网络模型中接入评价指标算法，其中包括节点电压脆弱性指标和线路潮流脆弱指标。通过模型训练得到不同分布式光伏装机容量接入及不同拓扑结构的情况下，配电网的脆弱性辨识结果。配电网不同拓扑结构下的脆弱性辨识见表 3。通过上述 2 个指标计算得到其中 IEEE-33 节点配电网在不同情况下的支路与节点脆弱性指标，见表 4。

表 3 配电网不同拓扑结构下的脆弱性辨识

Tab. 3 Vulnerability identification of distribution network under different topologies

拓扑结构	节点编号	线路编号
拓扑 2	18、17、16、15	1、22、2、29、23
拓扑 3	30、32、31、33	22、1、2、29、23
拓扑 4	30、32、31	29、30、28、1、2
拓扑 5	30、18、17、16	6、7、11、10、9
拓扑 6	33、12、18、17	22、1、3、4
拓扑 7	18、17、16、15	1、22、2
拓扑 8	30、32、31	22、29、23、3、4
拓扑 9	18、30、32、31、33	1、22、2、29、23
拓扑 10	30、32、31	22、1、2、29、23

表 4 不同出力下高比例分布式光伏配电网脆弱性辨识

Tab. 4 Vulnerability identification of high-proportion distributed PV distribution network under different outputs

脆弱性排序	节点(脆弱情况/%)	线路(脆弱情况/%)
1	18 (1.616 4)	27(2 349.674 1)
2	17(1.614 4)	4(733.739 7)
3	16(1.609 1)	8(660.755 0)
4	15(1.604 4)	9(622.914 3)
5	14(1.599 9)	28(381.300 7)
6	13(1.593 1)	3(291.348 6)
7	12(1.574 7)	26(288.232 5)
8	11(1.521 3)	10(211.972 1)
9	33(1.493 5)	25(152.495 8)
10	32(1.493 1)	11(141.979 8)
11	10(1.492 6)	29(113.525 7)
12	31(1.490 1)	7(83.621 1)
13	30(1.478 7)	5(62.562 6)
14	29(1.396 1)	2(47.232 3)
15	9(1.313 6)	6(44.639 3)
16	28(1.241 6)	1(34.472 9)
17	8(1.133 2)	17(0.060 4)
18	27(1.036 8)	16(0.053 1)
19	7(1.026 7)	13(0.045 7)
20	26(0.990 1)	15(0.044 4)
21	6(0.956 3)	32(0.043 7)
22	5(0.641 8)	12(0.040 8)
23	4(0.458 1)	14(0.035 7)
24	25(0.289 6)	31(0.033 4)
25	24(0.287 8)	30(0.029 8)
26	23(0.284 5)	22(0.024 7)
27	3(0.282 2)	23(0.020 7)
28	21(0.045 0)	24(0.019 4)
29	22(0.044 4)	18(0.003 2)
30	20(0.044 4)	19(0.003 0)
31	19(0.044 3)	20(0.002 9)
32	2(0.043 9)	21(0.002 9)

4 结论

本文在高比例分布式光伏接入配电网的背景下，研究了 2 种情况：分布式光伏出力不同的情况，以及光伏配电网在实际运行中拓扑结构发生变化

的情况。针对高比例分布式光伏背景下的配电网脆弱性辨识问题，本文提出了使用 EGAT 技术进行脆弱性辨识的方法，主要特点如下。

(1)采用 EGAT 技术对配电网的拓扑结构及数据进行特征学习，该方法能够捕捉节点间的直接关联，同时深入挖掘节点与线路之间的潜在交互关系。

(2)整合迁移学习，利用已有配电网场景的经验，减少训练数据并加速模型训练，增强模型在多种场景下的适应性。

(3)EGAT 相较于 GAT 与 WLS，对节点电压的状态估计精度更高，此外，EGAT 不仅可以输出节点电压，还能同时实现对传输线路功率的状态估计。

使用 EGAT 对 IEEE-33 节点的配电网进行状态估计，进而辨识节点和线路的脆弱性。模拟不同容量的分布式光伏接入固定节点，以及配电网在不同拓扑结构下的运行变化。结果显示，分布式光伏接入后，部分节点和线路表现出显著的脆弱性，且不同的拓扑结构对该脆弱性有较大影响。因此，本研究为电力系统规划和运营提供了关键参考，有助于制定措施确保电力供应稳定，并优化分布式光伏的布局和运营，进而更有效地融合可再生能源和传统电力系统。

参考文献：

[1] 葛昊. 高比例分布式光伏接入配电网的影响[J]. 电子技术, 2023, 52(3): 290-291.
Ge Hao. Impact of high proportion distributed photovoltaic integration into the grid network [J]. Electronic Technology, 2023, 52(3): 290-291.(in Chinese)

[2] 王子欣, 苗世洪, 郭舒毓, 等. 考虑分布式电源出力随机特性的配电网节点脆弱性评估[J]. 电力自动化设备, 2021, 41(8): 33-40.
Wang Zixin, Miao Shihong, Guo Shuyu, et al. Node vulnerability evaluation of distribution network considering randomness characteristic of distributed generation output [J]. Electric Power Automation Equipment, 2021, 41(8): 33-40. (in Chinese)

[3] Zang Tianlei, Wang Zian, Wei Xiaoguang, et al. Current status and perspective of vulnerability assessment of cyber-physical power systems based on complex network theory [J]. Energies, 2023, 16(18): 6509.

[4] Su Qingyu, Chen Cong, Sun Zhenglong, et al. Identification of critical nodes for cascade faults of grids based on electrical PageRank [J]. Global Energy Interconnection, 2021, 4(6): 587-595.

[5] 闫龙. 基于复杂网络理论的电网风险传播及防控研究[D]. 徐州: 中国矿业大学, 2021.
Yan Long. Research on power grid risk transmission and prevention and control based on complex network [D]. Xuzhou: China University of Mining and Technology, 2021. (in Chinese)

[6] 陈超洋, 周勇, 池明, 等. 基于复杂网络理论的大电网脆弱性研究综述[J]. 控制与决策, 2022, 37(4): 782-798.
Chen Chaoyang, Zhou Yong, Chi Ming, et al. Review of large power grid vulnerability based on complex network theory [J]. Control and Decision, 2022, 37(4): 782-798. (in Chinese)

[7] Zhou Dongyue, Hu Funian, Wang Shuliang, et al. Power network robustness analysis based on electrical engineering and complex network theory [J]. Physica A: Statistical Mechanics and its Applications, 2021, 564: 125540.

[8] Raj R P, Kowli A. Characterizing the ramps and noise in solar power imbalances [J]. Solar Energy, 2022, 247: 531-542.

[9] 张建, 夏烈, 徐亮辉, 等. 基于最小鉴别信息组合赋权法的光伏发电单元综合评价技术研究[J]. 电源学报, 2025, 23(5): 152-160.
Zhang Jian, Xia Lie, Xu Lianghui, et al. Research on comprehensive evaluation technology for photovoltaic power generation unit based on combined weighting method of minimum discriminant information [J]. Journal of Power Supply, 2025, 23(5): 152-160. (in Chinese)

[10] 姚芳, 姜涛, 刘明宇, 等. 基于 GWO-ELM 的逆变器开路故障诊断[J]. 电源学报, 2020, 18(1): 45-53.
Yao Fang, Jiang Tao, Liu Mingyu, et al. Open-circuit fault diagnosis of inverter based on GWO-ELM [J]. Journal of Power Supply, 2020, 18(1): 45-53. (in Chinese)

[11] 陈佳斌, 陈阿莲. 一种改进的主动频率偏移孤岛检测算法[J]. 电源学报, 2017, 15(3): 140-147.

Chen Jiabin, Chen Alian. An improved active frequency drift method of islanding detection [J]. Journal of Power Supply, 2017, 15(3): 140-147. (in Chinese)

[12] 王福忠, 裴玉龙. 光伏阵列故障类型的改进型 RBF 神经网络识别算法[J]. 电源学报, 2019, 17(1): 73-79.
Wang Fuzhong, Pei Yulong. Photovoltaic array fault identification algorithm based on improved RBF neural network [J]. Journal of Power Supply, 2019, 17(1): 73-79. (in Chinese)

[13] 张晓棋, 覃默, 熊波, 等. 基于 CNN-LSTM 的直流微电网稳定性判别方法[J/OL]. 电源学报, 1-11. (2025-02-09)[2026-04-24]. https://link.cnki.net/urlid/12.1420.TM.20250219.0824.004.
Zhang Xiaoqi, Qin Mo, Xiong Bo, et al. Stability discrimination method of DC microgrid based on CNN-LSTM [J]. Journal of Power Supply, 1-11. (2025-02-09)[2026-04-24]. https://link.cnki.net/urlid/12.1420.TM.20250219.0824.004. (in Chinese)

[14] 钟耿钦, 王学梅, 康龙云. 基于 GRU-BP 的锂电池部分充电数据 SOH 估计[J/OL]. 电源学报, 1-15. (2024-04-26)[2026-04- 24]. https://link.cnki.net/urlid/12.1420.TM.20240426.1058.038.
Zhong Gengqin, Wang Xuemei, Kang Longyun. SOH estimation of partial charging data for lithium batteries based on GRU-BP [J]. Journal of Power Supply, 1-15. (2024-04-26)[2026-04-24]. https://link.cnki.net/urlid/12.1420.TM.20240426.1058.038. (in Chinese)

[15] 马光, 朱文, 顾慧杰, 等. 基于加权最小绝对值状态估计的有源配电网拓扑辨识方法[J]. 中国电力, 2024, 57(1): 167-174.
Ma Guang, Zhu Wen, Gu Huijie, et al. Topology identification method for active distribution network based on weighted minimum absolute value state estimation [J]. Electric Power, 2024, 57(1): 167-174. (in Chinese)

[16] 严奕陆, 刘文霞, 石庆鑫, 等. 基于电-水跨层耦合模型的城市电网脆弱性评估[J].电工技术学报, 2024, 39(16): 5075-5090.
Yan Yilu, Liu Wenxia, Shi Qingxin, et al. Vulnerability assessment of urban power grid based on electricity-water cross-layer coupling model [J]. Transactions of China Electrotechnical Society, 2024, 39(16): 5075-5090. (in Chinese)

[17] 黄蔓云, 郭镜玮, 臧海祥, 等. 基于消息传递图神经网络的电力系统状态估计[J]. 电网技术, 2023, 47(11): 4396-4404.
Huang Manyun, Guo Jingwei, Zang Haixiang, et al. State estimation of power system based on a message passing neural network [J]. Power System Technology, 2023, 47(11): 4396-4404. (in Chinese)

[18] 王春义, 卢志鹏, 杨扬, 等. 基于改进图卷积网络的配电网状态估计方法[J]. 现代电力, 2023, 40(1): 133-142.
Wang Chunyi, Lu Zhipeng, Yang Yang, et al. An improved graph convolutional network-based state estimation method of distribution network [J]. Modern Electric Power, 2023, 40(1): 133-142. (in Chinese)



王宇飞

作者简介：

王宇飞(1991—)，男，通信作者，本科，高级工程师。研究方向：配电网规划与建设。E-mail：wang.yuf@jibei.sgcc.com.cn。

吕晓宁(1980—)，男，本科，工程师。研究方向：电力经济分析。E-mail：lv.xiaoning@jibei.sgcc.com.cn。

时海(1988—)，男，本科，高级工程师。研究方向：线损管理和可靠性管理。E-mail：shi.hai@jibei.sgcc.com.cn。

魏云峰(1998—)，男，本科，助理工程师。研究方向：配电网建设。E-mail：wei.yunfeng@jibei.sgcc.com.cn。

(责任编辑：耿越)