

DOI: 10.19783/j.cnki.pspc.231482

## 基于改进图注意力网络的电力系统脆弱性关键环节辨识

王长刚<sup>1,2</sup>, 王先伟<sup>2</sup>, 曹宇<sup>1,2</sup>, 李扬<sup>1,2</sup>, 吕琪<sup>2</sup>, 张耀心<sup>3</sup>

(1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室(东北电力大学), 吉林 吉林 132012;

2. 东北电力大学, 吉林 吉林 132012; 3. 国网天津市电力公司, 天津 300010)

**摘要:** 随着电网的扩大与新能源比例的增加, 电网的不确定性和随机性因素增加, 危及系统安全运行, 寻找出电网中的脆弱性关键环节来保障电网运行时的可靠性就显得尤为重要。针对当前传统电网脆弱性关键环节辨别方法识别速度慢、难以满足电网实际运行要求的问题, 提出了基于改进图注意力网络算法(improved graph attention network, IGAT)的电网脆弱性关键环节辨识方法。首先, 结合复杂网络理论和电网实际运行数据建立评价指标集。其次, 利用 IGAT 挖掘出电网运行时的各项指标与脆弱性关键环节之间的映射关系, 建立脆弱性关键环节辨识模型, 并且考虑到训练准确性和效率等需求, 对原始的图注意力网络进行优化。再次, 通过仿真得到原始数据集, 对辨识模型进行训练、验证和测试。最后, 利用所述模型应用于改进的 IEEE 30 节点系统和实际电网中, 结果表明所提方法具有可行性, 且准确性和速度优于传统方法, 有一定的工程利用价值。

**关键词:** 脆弱性关键环节; 复杂网络理论; 图注意力神经网络; 运行可靠性

### Critical link identification of power system vulnerability based on modified graph attention network

WANG Changgang<sup>1,2</sup>, WANG Xianwei<sup>2</sup>, CAO Yu<sup>1,2</sup>, LI Yang<sup>1,2</sup>, LÜ Qi<sup>2</sup>, ZHANG Yaoxin<sup>3</sup>

(1. Key Laboratory of Modern Power System Simulation and Control and Renewable Energy Technology, Ministry of Education, Northeast Electric Power University, Jilin 132012, China; 2. Northeast Electric Power University, Jilin 132012, China; 3. State Grid Tianjin Electric Power Company, Tianjin 300010, China)

**Abstract:** With the expansion of the power grid and the increase of the proportion of new energy sources, the uncertainty and random factors of the power grid increase, endangering the safe operation of the system. It is particularly important to find out the critical links of vulnerability in the power grid to ensure the reliability of the power grid operation. Aiming at the problem that the identification speed of the traditional critical link of vulnerability identification methods is slow and difficult to meet the actual operation requirements of the power grid, the improved graph attention network (IGAT) based identification method of the critical link is proposed. First, the evaluation index set is established by combining the complex network theory and the actual operation data of power grid. Secondly, IGAT is used to dig out the mapping relationship between various indicators and critical links of vulnerability during the operation of the power grid, establish the identification model of critical links of vulnerability, and optimize the original graph attention network considering the training accuracy and efficiency. Thirdly, the original data set is obtained through simulation, and the identification model is trained, verified and tested. Finally, the model is applied to the improved IEEE 30-node system and the actual power grid, and the results show that the proposed method is feasible, and the accuracy and speed are better than that of traditional methods. It has certain engineering utilization value.

This work is supported by the Natural Science Foundation of Jilin Province (No. YDZJ202101ZYTS149).

**Key words:** critical link of vulnerability; complex network theory; graph attention neural networks; operational reliability

## 0 引言

随着电网的逐步建设以及各地区互联互通和新

能源发电的兴起, 电网的复杂度和不确定性增加, 确定电网各个环节安全运行是保障电网可靠运行的前置条件<sup>[1-4]</sup>。在实际运行中, 某些线路或节点起到牵一发而动全身的作用, 如果这些环节发生故障, 对电网安全运行会产生巨大影响, 如何快速而准确地找到这些脆弱性关键环节、保证电力系统的运行可

基金项目: 吉林省自然科学基金项目资助(YDZJ202101ZYTS149)

靠性是亟待解决的问题<sup>[5-6]</sup>。

目前, 国内外对于电网关键环节的研究多包含在电力系统脆弱性的研究之中, 主要分为基于拓扑关系和运行状态两大类<sup>[7-11]</sup>。前者利用复杂网络理论选取特定的特征量(例如度数、介数), 考虑实际电网的拓扑结构, 融入系统物理特性, 构造脆弱性指标, 进而评估出关键环节。后者是通过电网的实际运行状态, 如潮流分布等, 来实现关键环节的辨识。文献[12]利用随机矩阵理论及熵理论对电网运行状态进行分析, 提出了具有普适性的电网薄弱节点判断指标; 文献[13]将复杂网络理论和运行状态有机结合, 利用组合权重法对不同节点指标进行权重分配, 建立电网薄弱节点组合指标, 并用实例证明有效性; 文献[14]提出了基于结构保持模型的暂态能量函数法结合有向电气介数的支路暂态脆弱性综合评估方法, 该方法可以快速判断容易失稳的脆弱支路以及临界机群, 保证了电网安全稳定运行; 文献[15]提出了考虑不同类型节点与相邻节点间传输转移的信息值及节点间非等概率传输特性的改进 PageRank 算法进行关键节点的辨识。综上, 这些方法都因模型较复杂、计算繁琐耗时, 不能很好地适应如今快速变化的电力系统, 也难以满足在线辨识的要求。

随着近几年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越来越广泛<sup>[16]</sup>。“离线训练, 在线辨识”是深度学习的功能之一, 能够快速准确地完成分类、预测等任务<sup>[17-20]</sup>。利用深度学习挖掘特征与标签之间的映射关系、建立分类模型是深度学习最为基本的任务之一。对于电力系统来说, 它是一个由众多线路和节点所组成的庞大系统, 拓扑结构是其相当重要的属性之一, 传统深度学习算法在电力系统中的应用只注意到挖掘数据之间的关系, 没有注意到电力系统各部分之间的拓扑关系, 进而导致模型的泛化能力不高。图深度神经网络<sup>[21]</sup>(graph neural network, GNN)相较于其他的深度学习, 不仅仅只关注自身的属性, 还会通过拓扑关系聚合相邻节点的特征信息, 使得特征提取过程更加立体, 涵盖更多的信息。其在电力系统优化调度<sup>[22-24]</sup>、故障诊断<sup>[25-26]</sup>方面得到良好的应用。文献[27]在此基础上提出了图注意力网络(graph attention network, GAT), GAT 的节点在聚合邻居表示时采用了注意力机制, 根据节点与邻居的相关性来为邻居分配注意力系数, 最后通过节点邻居特征及节点自身特征的加权平均值来更新节点特征。文献[28]发现原始 GAT 的节点只关注自己的邻居节点, 其注意力系数评分的排序不受查询节点(query node, 即自身节点表征)的限制, 这一事实影响了 GAT 的表现力; 其通过修改注意力

系数公式提高 GAT 的表达能力, 提出改进图注意力网络算法(improved graph attention network, IGAT)。

本文在现有研究的基础上, 构建了基于改进图注意力网络的电力系统脆弱性关键环节的辨识器。首先, 通过改进复杂网络理论模型寻找出电力系统中的脆弱性关键环节并建立样本集; 其次, 通过构建的样本集, 利用 IGAT 挖掘出电力系统运行时的各项数据和脆弱性关键环节之间的映射关系, 并构建辨识器。最后将本文方法应用于改进的 IEEE 30 节点系统和实际电网中, 结果表明本文方法可行, 且比传统计算方法更加快速、准确。

## 1 脆弱性关键环节的定义

### 1.1 复杂网络理论模型

复杂网络理论是一种通过对网络拓扑结构特征量统计规律进行研究来揭示各种复杂网络中共性的网络随机演化性质、结构稳定性及受到攻击时的动力学传播特性的理论方法<sup>[29]</sup>。其多适用于具有拓扑结构属性的对象, 如关系网、分子结构等。复杂网络理论的某些特定参数指标如下所述。

1) 度数。指节点所连边的个数。很明显, 度数越高, 这个节点在整个图中就越重要。

2) 最短路径。网络之中两节点之间的距离可以用连接这两个节点的最短路径来表示, 即两个节点之间的连线经过的最少边数。

3) 聚类系数。节点的聚类系数可以反映一个节点与其相邻节点的连接情况, 与邻居节点之间实际相连的边数和可能存在的最多相连边数的比值, 便是聚类系数。

4) 介数。介数分为节点介数和边介数, 定义节点或边的介数为: 在网络中所有最短路径中, 最短路径经过的某节点或边的路径数与总数的比值。

本文选取文献[30]的改进复杂网络理论模型作为电网脆弱性关键环节评估准则。其不仅仅只看节点或线路在整个拓扑上的重要性, 而且还会考虑节点或线路在整个电网运行时的各项数值。

### 1.2 脆弱性关键环节的定义

本文采用文献[30]提出的方法对关键环节进行评估, 该方法是在改进复杂网络理论的基础上, 融入了部分电力系统运行因素(如线路上实际传输的功率和传输能力)而提出的, 故此方法更侧重于在底层机理上辨识出电力系统的脆弱性关键环节。

电网中的脆弱性关键环节分为脆弱性关键节点和脆弱性关键线路, 电网中的某个节点的关键程度由优化节点度数簇和优化节点介数簇加权求和得到, 具体公式如下。

$$d_{Li} = \sum_j l_{ij} |a_{ij}| \quad (1)$$

$$d_{Ci} = \max \left( \sum_{j, a_{ij}=1} c_{ij} a_{ij}, \sum_{j, a_{ij}=-1} c_{ij} |a_{ij}| \right) \quad (2)$$

$$b_{Hi} = \frac{\sum_{j \in G, k \in L; j \neq k} \sum_{m=1}^{M(jk)} n^i(m)}{\sum_{j \in G, k \in L; j \neq k} M(jk)} \quad (3)$$

$$b_{Li} = \frac{\sum_{j \in G, k \in L; j \neq k} \sum_{m=1}^{M(jk)} w_{jk}(m) d_{jk}(m) n^i(m)}{\sum_{j \in G, k \in L; j \neq k} \sum_{m=1}^{M(jk)} w_{jk}(m) d_{jk}(m)} \quad (4)$$

$$b_{Ci} = \frac{\sum_{j \in G, k \in L; j \neq k} \sum_{m=1}^{M(jk)} w_{jk}(m) c_{jk}(m) n^i(m)}{\sum_{j \in G, k \in L; j \neq k} \sum_{m=1}^{M(jk)} w_{jk}(m) c_{jk}(m)} \quad (5)$$

式中： $d_{Li}$ 和 $d_{Ci}$ 为优化节点度数簇指标； $i$ 和 $j$ 为节点号； $l_{ij}$ 为节点 $i$ 与 $j$ 之间的电气距离(本文选取的电气距离为阻抗矩阵法)； $c_{ij}$ 为节点 $i$ 与 $j$ 之间的支路传输能力，即电网中两个节点最短路径所形成的线路集合中可承受的最小功率； $a_{ij}$ 为电网节点邻接矩阵的元素，由于电网实际上是一个有向图，所以 $a_{ij}$ 中的元素由 $i$ 流向 $j$ 为1，反之为-1，不相连为0。优化节点介数簇由 $b_{Hi}$ 、 $b_{Li}$ 、 $b_{Ci}$ 组成； $k$ 为负荷节点号； $G$ 为电网中所有发电节点的集合； $L$ 为电网中所有负荷节点的集合； $M(jk)$ 为发电节点 $j$ 与负荷节点 $k$ 之间的功率传输路径数； $w_{jk}(m)$ 为发电节点 $j$ 与负荷节点 $k$ 间的第 $m$ 条功率传输路径的权重系数，其数值等于这条线路上实际传输的功率； $n^i(m)$ 为发电节点 $j$ 与负荷节点 $k$ 的第 $m$ 条功率传输路径是否经过节点 $i$ 的标识，若经过节点 $i$ 为1，否则为0； $d_{jk}(m)$ 为发电节点 $j$ 与负荷节点 $k$ 的第 $m$ 条功率传输路径的电气距离； $c_{jk}(m)$ 为发电节点 $j$ 与负荷节点 $k$ 间的第 $m$ 条功率传输路径的传输能力。

电网节点 $i$ 的关键度指标是由 $d_{Li}$ 、 $d_{Ci}$ 、 $b_{Hi}$ 、 $b_{Li}$ 、 $b_{Ci}$  5个指标归一化后进行加权求和而得，用于辨识节点在电网结构和系统运行中的关键程度。

电网中某条线路的关键程度由优化线路介数簇加权求和得到，具体公式如下。

$$b_{He} = \frac{\sum_{j \in G, k \in L; j \neq k} \sum_{m=1}^{M(jk)} n^e(m)}{\sum_{j \in G, k \in L; j \neq k} M(jk)} \quad (6)$$

$$b_{Le} = \frac{\sum_{j \in G, k \in L; j \neq k} \sum_{m=1}^{M(jk)} w_{jk}(m) d_{jk}(m) n^e(m)}{\sum_{j \in G, k \in L; j \neq k} w_{jk}(m) d_{jk}(m)} \quad (7)$$

$$b_{Ce} = \frac{\sum_{j \in G, k \in L; j \neq k} \sum_{m=1}^{M(jk)} w_{jk}(m) c_{jk}(m) n^e(m)}{\sum_{j \in G, k \in L; j \neq k} w_{jk}(m) c_{jk}(m)} \quad (8)$$

式中： $b_{He}$ 、 $b_{Le}$ 、 $b_{Ce}$ 为线路的优化线路介数簇的3个指标值； $e$ 为支路号； $n^e(m)$ 为发电节点与负荷节点间的第 $m$ 条功率传输路径是否经过支路的标识，若经过支路为1，否则为0。

电网线路的关键度指标是由 $b_{He}$ 、 $b_{Le}$ 、 $b_{Ce}$  3个指标归一化后进行加权求和而得，用于辨识线路在电网结构和系统运行中的关键程度。

对于包含多个子指标的综合指标，可以采用多种方法来计算加权系数，例如改进灰色关联度法、层次分析法、熵权法等。此外，根据电网规划人员或运行人员的关注重点不同，也可以灵活设置加权系数。为了客观地分析各子指标对结果的影响程度，本文采用等权重设置方法，即每个综合指标的子指标都赋予相同的权重系数。这种方法能够避免主观因素的影响，使结果更加客观和可靠。

## 2 基于 IGAT 的电力系统脆弱性关键环节辨识

### 2.1 改进图注意力网络算法

图注意力网络<sup>[27]</sup>是一种基于图结构数据的神经网络架构，它通过引入注意力机制到基于空间域的图神经网络中，与基于谱域的图卷积神经网络不同，图注意力网络不需要使用拉普拉斯等矩阵进行复杂的计算，而是通过一阶邻居节点的信息来更新节点特征，如图1所示。

其注意力系数的计算公式如式(9)。

$$\alpha_{ij} = \frac{\exp\{\text{LeakyReLU}[\mathbf{a}^T(\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_j)]\}}{\sum_{m \in M(i)} \exp\{\text{LeakyReLU}[\mathbf{a}^T(\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_m)]\}} \quad (9)$$

式中： $\alpha_{ij}$ 为节点 $i$ 和节点 $j$ 之间的注意力系数； $m, j \in M(i)$ ， $M(i)$ 为节点 $i$ 的所有邻居节点集合； $\mathbf{a}$ 为可学习的参数向量；“ $\parallel$ ”为拼接操作； $\mathbf{W}$ 为可学习的参数矩阵； $\mathbf{x}$ 为节点特征向量；LeakyReLU为一种非线性函数。

之后，根据注意力系数对各节点信息进行加权聚合，并将其作为目标节点新的特征向量。

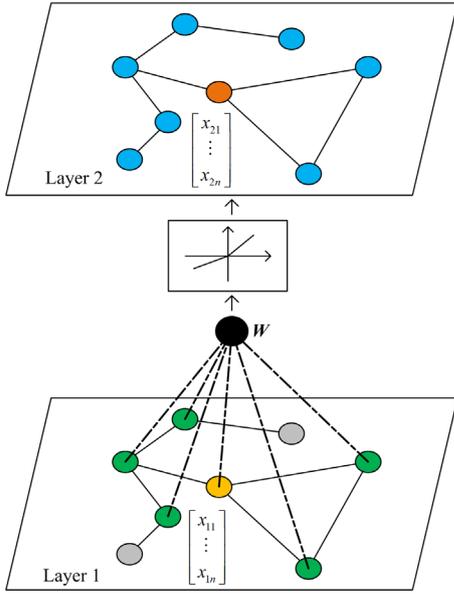


图 1 节点特征聚合示意图  
Fig. 1 Schematic of bus feature aggregation

$$\mathbf{x}_i^{(K)} = \sigma \left( \frac{1}{K} \sum_{K=1}^K \sum_{m \in M(i)} \alpha_{ij}^{(K)} \mathbf{W}^{(K)} \mathbf{x}_j \right) \quad (10)$$

式中:  $\sigma$  为激活函数;  $K$  为注意力头的数量。

原始的 GAT 的注意力函数是一种受限的静态的注意力<sup>[28]</sup>, 将式(9)的计算顺序调整就可以得到动态注意力, 如式(11)所示。

$$\alpha_{ij} = \frac{\exp\{\mathbf{a}^T [\text{LeakyReLU}(\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_j)]\}}{\sum_{m \in M(i)} \exp\{\mathbf{a}^T [\text{LeakyReLU}(\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_m)]\}} \quad (11)$$

本文选取具有动态注意力的图注意力网络解决问题, 即为改进的图注意力网络(IGAT)。

## 2.2 基于 IGAT 的电力系统运行脆弱性关键环节的辨识

电力系统本来就是一个错综复杂的网络, 其网络拓扑加相应的数据即可构成能反映电力系统运行状态的图数据。具体来讲, 其中发电站、负荷等即为图数据的节点, 而输电线路即为该图数据的边, 这样每个节点和支路都带有本身的属性特征, 本文选取特征量的维度如下: 节点的特征维度为 5 维, 支路的特征维度为 6 维, 见表 1。

在某一运行场景下对电网脆弱性关键环节进行仿真, 可以得到该状态下电网的脆弱性关键环节, 脆弱性关键环节的仿真识别结果可以表示为  $m$  和  $n$  维的向量,  $m$  为节点数,  $n$  为支路数, 作为脆弱性关键环节辨识器的期望输出, 两个向量中, 1 代表脆弱性关键环节, 0 代表非脆弱性关键环节。

表 1 脆弱性关键环节初始特征

Table 1 Initial features of vulnerability critical link	
节点特征	支路特征
度数	度数
节点所带负荷有功功率	支路电抗
节点所带负荷无功功率	支路流过的有功功率
电压幅值	支路流过的无功功率
电压相角	支路负载率
—	支路损耗

利用 IGAT 对辨识器的输入特征向量进行变换和聚合, 得到聚合后属性, 本文将聚合后的节点属性向量的维数设为 2, 即  $\mathbf{y}_i = [y_{1i} \ y_{2i}]^T$ , 然后采用 Softmax 函数对节点特征进行归一化, 获得节点或支路属于不同类别的概率。Softmax 函数公式如式(12)所示。

$$\mathbf{p}_i = \text{softmax}(\mathbf{y}_i) = \begin{bmatrix} \frac{\exp(y_{1i})}{\exp(y_{1i}) + \exp(y_{2i})} \\ \frac{\exp(y_{2i})}{\exp(y_{1i}) + \exp(y_{2i})} \end{bmatrix} = \begin{bmatrix} p_{1i} \\ p_{2i} \end{bmatrix} \quad (12)$$

式中:  $\mathbf{p}_i$  为判别脆弱性环节类别的二维向量;  $p_{1i}$  和  $p_{2i}$  分别为节点  $i$  属于脆弱性关键环节和非脆弱性关键环节的概率, 将概率较大的类别作为节点所属的类别。

## 2.3 基于 IGAT 的电力系统脆弱性关键环节辨识模型的训练

### 2.3.1 数据预处理

在训练模型之前, 样本集的准备不可或缺, 但是在 2.2 节得到的每个环节的特征、每个维度之间的数值差异过大, 比如节点度数和节点所带负荷的有功功率, 它们之间的数量级差异很大, 如果不处理就会出现训练集损失正常减小, 而验证集的损失没有明显的变化, 模型泛化能力弱, 不利于模型的训练, 所以本文在训练之前, 将具有同一属性的特征进行归一化处理, 使得每个维度的特征都转化为一个范围的数值, 这样既不会改变一组样本集上特征的差异, 也会使得训练适应度更高。

### 2.3.2 损失函数的选取

本文损失函数选取交叉熵损失函数, 在神经网络训练过程中, 由于 ReLU 等非线性激活函数的存在, 神经网络经常出现梯度消失问题。采用交叉熵损失函数可以一定程度上解决这个问题。原因是交叉熵损失函数对于预测错误的样本赋予了较高的梯度, 这样可以增加误差在反向传播中的传递, 从而加速优化过程, 并且可以防止出现模型在训练集上表现良好、在测试集上表现较差的过拟合现象。采

用交叉熵损失函数可以有效防止过拟合，这是因为交叉熵损失函数比均方差等传统损失函数更加敏感，更容易检测到噪声和异常值，从而避免模型过拟合，进一步提升模型泛化能力。其二分类公式为

$$L = \frac{1}{N} \sum_i L_i = \frac{1}{N} \sum_i [-x_i \log(p_{i1}) + (1-x_i) \log(1-p_{i1})] \quad (13)$$

式中： $L$  为单次迭代的总损失值； $L_i$  为第  $i$  个脆弱性关键环节的损失值； $N$  为单次训练脆弱性关键环节数量； $x_i$  为脆弱性关键环节的类别(是即为 1，反之为 0)。

### 2.3.3 其他优化策略

本文利用 Adam 优化器对得到的节点特征向量进行更新优化，并使用 Dropout 方法防止出现过拟合现象，同时采用多头注意力机制，头数为 2。

## 2.4 基于 IGAT 的电力系统脆弱性关键环节辨识模型的训练流程

基于 IGAT 算法的脆弱性关键环节辨识模型的训练流程关键部分在于利用图数据和注意力机制完成对图节点特征的聚合。IGAT 分类训练过程的伪代码如下：

---

**Algorithm1:** The classification training process of IGAT

---

**Input:** training set  $D\{(x^{(n)}, y^{(n)})\}$ , maximum number of iterations  $T$

- 1 Initial weight  $\omega$
- 2 **repeat**
- 3 Randomly order the samples of the training set;
- 4 **For**  $n=1, 2, \dots, N$  **do**
- 5 Select a sample  $(x^{(n)}, y^{(n)})$ ;
- 6 Calculate node and neighbor node attention coefficient;
- 7 Weighted aggregated node and neighbor node information;
- 8 Take the mean value of multiple attention node features;
- 9 Predict the categories according to formula(12);
- 10 **If**  $\hat{y}_i \neq y_i$  **then**
- 11 Calculate loss;
- 12  $\omega_{i+1} \leftarrow \omega_i - \gamma[\partial \text{loss}(\omega)/\partial(\omega)]$ ;
- 13  $l=l+1$ ;
- 14 **end**
- 15  $t=t+1$ ;
- 16 **if**  $t=T$  **then break**;
- 17 **end**
- 18 **until**  $t=T$

---

**Output:** Optimal IGAT model

---

## 2.5 模型结果评估

采用混淆矩阵呈现模型辨识结果，并使用其来计算准确率  $f_{\text{acc}}$ 、精确率  $f_{\text{pre}}$ 、召回率  $f_{\text{rea}}$  以及 F1 指标  $f_{\text{F1}}$ ，旨在全方位地评判测试结果，计算过程如式(14)一式(17)所示。

$$f_{\text{acc}} = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \times 100\% \quad (14)$$

$$f_{\text{pre}} = \frac{T_p}{T_p + F_p} \times 100\% \quad (15)$$

$$f_{\text{rea}} = \frac{T_p}{T_p + F_n} \times 100\% \quad (16)$$

$$f_{\text{F1}} = \frac{2f_{\text{pre}} \cdot f_{\text{rea}}}{f_{\text{pre}} + f_{\text{rea}}} \times 100\% \quad (17)$$

式中： $T_p$  代表预测为脆弱性关键环节并且实际结果也为脆弱性关键环节的数目； $F_p$  代表预测为脆弱性关键环节而实际结果并非脆弱性关键环节的数目； $F_n$  代表预测为非脆弱性关键环节而实际结果是脆弱性关键环节的数目； $T_n$  代表预测为非脆弱性关键环节并且实际结果也为非脆弱性关键环节的数目。

## 3 算例与结果分析

本文采用改进的 IEEE 6 机 30 节点系统和实际系统进行脆弱性关键环节辨识方法的验证与评估。首先利用 Matlab 中的 Matpower 工具包仿真得到数据集，之后利用 Python 集成开发环境搭建基于 GAT 算法的脆弱性关键环节辨识模型。

### 3.1 改进的 IEEE 30 节点系统

改进的 IEEE 30 节点系统接线如图 2 所示，有 30 个节点，41 条线路。本文在分析脆弱性关键节点和脆弱性关键线路时，考虑到计算的准确性和适用性，首先利用 2.1 节所示的方法将所有节点或线路的关键程度以指标得分的形式进行排名，然后将排在前 20% 的作为脆弱性关键节点或关键线路。所以对于此 30 节点系统，脆弱性关键节点选取得分前 6 名的，脆弱性关键支路选取得分前 8 名的。

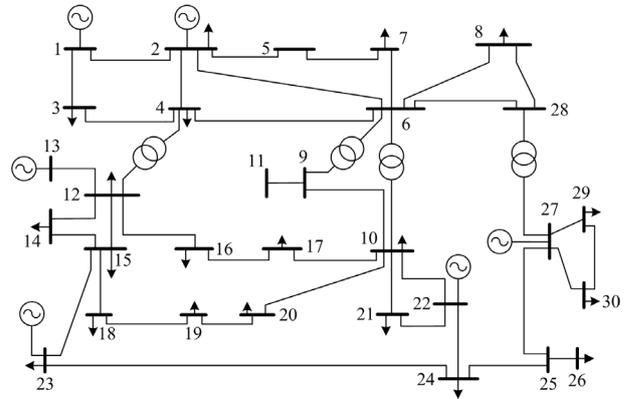


图 2 改进的 IEEE 30 节点系统接线图

Fig. 2 Wiring diagram of improved IEEE 30-node system

### 3.1.1 数据集的获取

为了可以真实模拟电网的运行, 在电网拓扑不变的情况下, 从发电机节点的出力、线路电抗和节点所带负荷方面更改参数来生成更多的断面数据, 发电机节点的出力范围、线路电抗和节点所带负荷修改为原始情况的 80%~120%, 这样共迭代出 11 000 个断面数据, 除去不收敛的情况, 共 10 350 个断面数据。

### 3.1.2 模型辨识结果

所建立的脆弱性关键环节辨识样本集按照 80%、10%、10% 的比例被分为训练集、验证集和测试集。训练集用于调整权重矩阵辨识器参数; 验证集用于检验模型训练过程中收敛、过拟合等情况, 确定最优迭代次数、学习率等超参数; 测试集用于测试最优辨识器的最终辨识能力。

通过改善注意力机制、优化数据预处理、设计交叉熵损失函数以及引入多头注意力机制等方法对传统的基于 GAT 算法的模型进行改进, 从而得到本文所建立的基于 IGAT 的脆弱性关键环节辨识模型。本文模型在训练过程中迭代到 20 次时已经找到最好的结果, 训练结果良好, 脆弱性关键节点和脆弱性关键线路的训练集和验证集损失率分别如图 3 和图 4 所示。

经过多次测试, 脆弱性关键节点在验证集上的准确率可以达到 98.43% 左右, 效果优异; 脆弱性关键线路在验证集上的准确率保持在 97.73% 左右, 效果优异, 如图 5 所示。这正与上述两图相对应, 在迭代 20 次左右正确率就满足基本要求。

综上, 本文所提出的模型无论是在训练集还是验证集都得到的良好的辨识结果, 辨识准确率满足一定的工程需要。

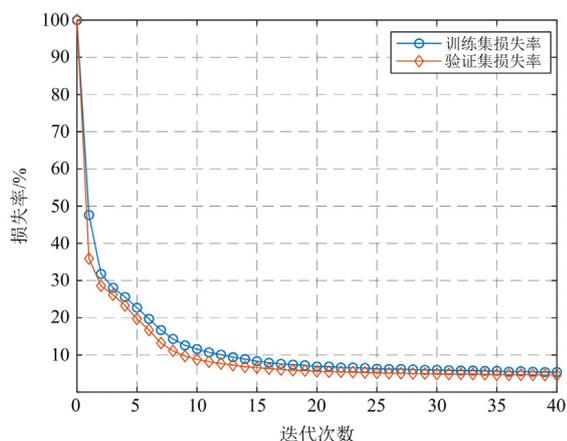


图 3 IEEE 30 节点系统脆弱性关键节点损失率  
Fig. 3 Loss rate of critical nodes of vulnerability in IEEE30-node system

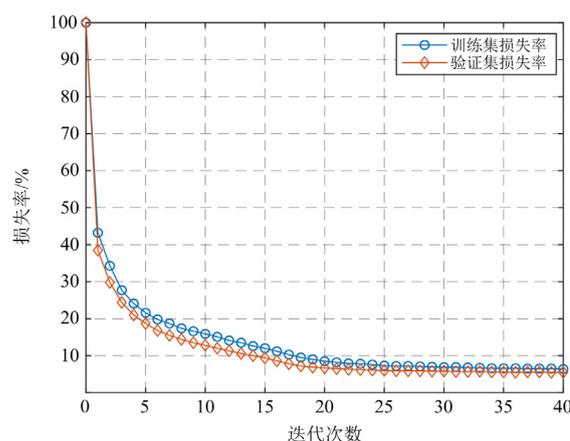


图 4 IEEE 30 节点系统脆弱性关键线路损失率  
Fig. 4 Loss rate of critical lines of vulnerability in IEEE 30-node system

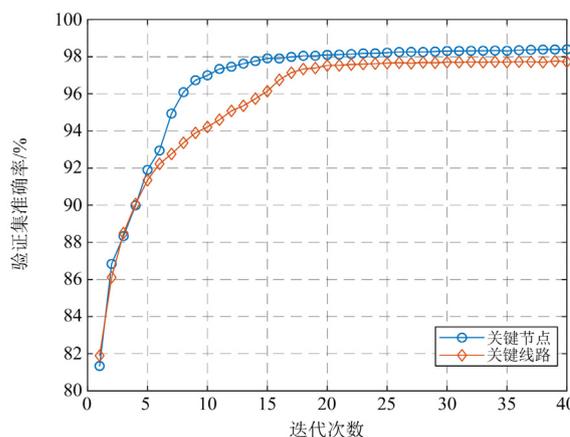


图 5 IEEE 30 节点系统脆弱性关键环节验证集损失率  
Fig. 5 Validation set loss rate of critical links of vulnerability in IEEE 30-node system

脆弱性关键节点和脆弱性关键线路的模型的混淆矩阵如表 2 和表 3 所示。

从表 2 可以算出本文设计出的脆弱性关键节点辨识模型的准确率、精确率、召回率及 F1 指标值分别为 98.43%、98.95%、99.10%、99.02%。从表 3 可以算出本文设计出的脆弱性关键线路辨识模型的准确率、精确率、召回率及 F1 指标值分别为 97.73%、98.95%、98.24%、98.59%。这些数据说明了本文

表 2 IEEE 30 节点系统脆弱性关键节点混淆矩阵

Table 2 Confusion matrix of critical nodes of vulnerability in IEEE 30-node system

混淆矩阵		实际结果	
		脆弱关键环节	非脆弱关键环节
预测结果	脆弱性关键环节	24 531	261
	非脆弱性关键环节	223	5975

表 3 IEEE 30 节点系统脆弱性关键线路混淆矩阵  
Table 3 Confusion matrix of critical lines of vulnerability in IEEE 30-node system

混淆矩阵		实际结果	
		脆弱性关键环节	非脆弱性关键环节
预测结果	脆弱性关键环节	33 732	357
	非脆弱性关键环节	602	7662

辨识模型无论是在脆弱性关键节点的辨识还是脆弱性关键线路的辨识都表现出良好的辨识结果，符合精度上的要求。辨识模型的各项指标如表 4 所示。

表 4 IEEE 30 节点系统辨识模型各项指标  
Table 4 Identification model index of IEEE 30-node system %

指标	脆弱性关键节点	脆弱性关键线路
准确率	98.43	97.73
精确率	98.95	98.95
召回率	99.10	98.24
F1 指标	99.02	98.59

在模型评估出脆弱性关键环节所消耗时间方面，本文选取 200 个场景作为测试样本来验证本文模型在速度方面的优势。本文所提方法的耗时由特征提取的时间和特征进入模型最后得到辨识结果的时间两部分组成。文献[30]中传统的基于仿真的方法在 30 节点系统得到脆弱性关键节点和支路的耗时在 51 s 左右(由于仿真生成的数据有随机性，所耗时间有微小误差)。本文方法在 30 节点系统耗时 4 s 左右(特征提取时间为 3 s 左右，特征进入模型最后得到辨识结果的时间大约为 1 s)，比传统方法快 12 倍，更能适应如今多变的电力系统。

### 3.1.3 不同模型之间的比较

为证明 IGAT 算法在特征提取上的优势，在相同的样本库、模型框架等情况下，选择深度神经网络(deep neural networks, DNN)、卷积神经网络(convolutional neural networks, CNN)、循环神经网络(recurrent neural network, RNN)、图卷积神经网络(graph convolutional networks, GCN)和本文所用的 IGAT 算法进行对比，各算法训练过程中验证集准确率如图 6 和图 7 所示，CNN、RNN 和 DNN 由于对权重初值要求高，结果不稳定，这里选择多次训练取平均值的方法来可视化其训练效果。

由图 6 和图 7 可知，在训练和测试中，以 IGAT 和 GCN 为代表的图深度学习算法在学习过程中考虑了节点和线路的电气特征和拓扑属性信息，因此在辨识准确性和模型稳定性方面优于仅考虑电气特征的深度学习算法，比如以 DNN、CNN、RNN 为代表的传统深度算法。

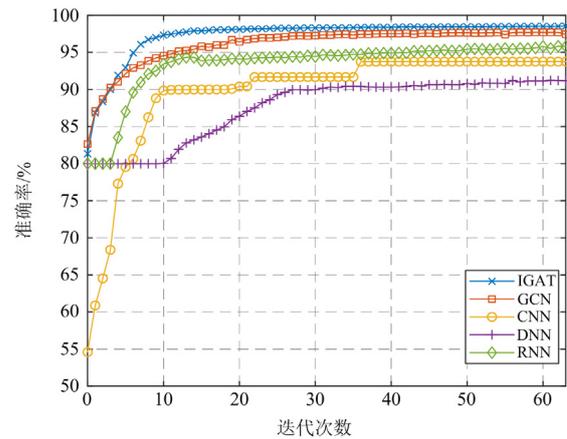


图 6 不同方法脆弱性关键节点验证集准确率  
Fig. 6 Validation set accuracy of critical nodes of vulnerability by different methods

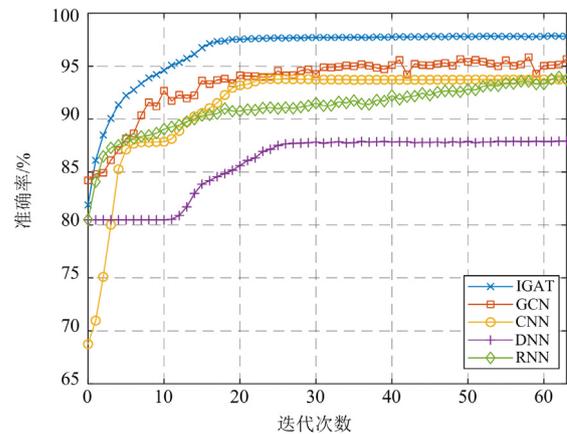


图 7 不同方法脆弱性关键线路验证集准确率  
Fig. 7 Validation set accuracy of critical lines of vulnerability by different methods

### 3.2 实际电网案例

本文选择东北某省的 220 kV 电网，该电网由 126 个节点(其中 28 个发电厂，98 个变电站/母线)、167 条输电线路构成，如图 8 所示。

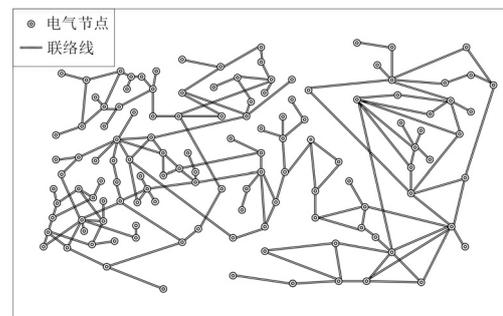


图 8 实际电网接线图  
Fig. 8 Wiring diagram of an actual power grid

首先, 利用 1.2 节方法评估各运行场景下脆弱性关键环节, 根据系统规模定义线路或节点为脆弱性关键环节, 其中, 将评估指标值前 20 个节点定义为脆弱性关键节点, 将评估指标值前 30 个线路定义为脆弱性关键线路; 之后, 根据实际运行数据和评估结果构建训练样本集。考虑到电网运行具有连续性、周期性等特点, 选择具有代表性的运行场景。然后通过更改发电机节点出力 and 负荷节点所带负荷的方式进行扩充样本集, 改变范围为原始情况的 80%~120%。本文选择一天中连续的 4 个小时作为原始数据进行扩充, 共生成 5000 组数据(其中原始数据 240 组, 仿真生成数据 4760 组)。最后, 对模型进行训练与测试, 验证其有效性。模型训练结果如图 9 所示。

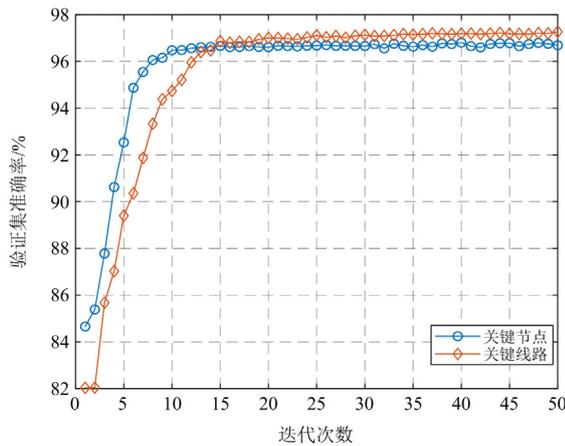


图 9 实际电网脆弱性关键环节验证集准确率

Fig. 9 Validation set accuracy of critical link of vulnerability in an actual power grid

经过多次测试, 实际电网脆弱性关键环节的辨识模型的准确率可以达到 96.56%和 97.23%。模型的各项指标如表 5 所示。从表 5 可以看出, 基于本文方法的实际电网辨识模型具有良好的性能, 能够满足在线辨识的任务。

表 5 实际电网系统辨识模型各项指标

Table 5 Identification mode index of an actual power grid %

指标	脆弱性关键节点	脆弱性关键线路
准确率	96.56	97.23
精确率	97.77	98.12
召回率	98.17	98.50
F1 指标	97.98	98.31

继续利用 200 个场景作为测试样本, 利用传统评估方法得到脆弱性关键环节所需时间为 1200 s 左右, 本文方法所需时间为 97 s 左右(特征提取时间

96 s, 模型辨识时间 1 s)。这与上文仿真系统的结果一致, 本文方法比传统方法评估脆弱性关键环节的时间大约快 12 倍。

#### 4 结论与展望

随着电网规模不断扩大和复杂度不断增加, 现有的传统脆弱性关键环节辨识方法在速度和准确性方面无法满足当前电网运行的实际需求。本文提出了一种基于 IGAT 算法的脆弱性关键环节识别方法。该方法利用图深度学习的优势, 通过 IGAT 算法深入挖掘电网运行状态与脆弱性关键环节之间的潜在联系, 实现了在新的运行状态下对脆弱性关键环节的快速、准确辨识。经过改进的 IEEE 30 节点系统和实际电网案例的验证, 证实了所提方法的有效性和可行性。

主要结论如下所述。

1) 与传统的辨识方法相比, 本文基于 IGAT 算法构建的辨识器在离线训练后, 能够显著提高对新运行状态下脆弱性关键环节的识别速度, 更适用于在线应用中对脆弱性关键环节的识别。

2) 与基于深度学习的辨识方法相比, 采用图深度学习的方法能够同时对线路属性信息及其所处的拓扑位置进行深入学习, 从而获得更全面的辨识信息, 提高了辨识结果的准确率。

值得说明的是, 本文在所应用的脆弱性关键环节辨识模型中主要考虑了电力系统的拓扑关系, 而如何在本文模型基础上改进使其更能适应如今新能源并网情况下的脆弱性关键环节的辨识、脆弱性关键环节评估后对于连锁故障的影响、新的人工智能技术的应用等, 将是未来需要进一步研究的问题。

#### 参考文献

- [1] 辛保安, 李明节, 贺静波, 等. 新型电力系统安全防御体系探究[J]. 中国电机工程学报, 2023, 43(15): 5723-5731. XIN Baoan, LI Mingjie, HE Jingbo, et al. Research on security defense system of new power system[J]. Proceedings of the CSEE, 2023, 43(15): 5723-5731.
- [2] 邓慧琼, 罗杰, 王晓铭, 等. 考虑安全性和经济性的连锁故障预防控制策略[J]. 电力建设, 2022, 43(5): 100-108. DENG Huiqiong, LUO Jie, WANG Xiaoming, et al. Preventive control strategy of cascading failure considering security and economy[J]. Electric Power Construction, 2022, 43(5): 100-108.
- [3] MA Zhiyuan, SHEN Chen, LIU Feng, et al. Fast screening of vulnerable transmission lines in power grids: a PageRank-based approach[J]. IEEE Transactions on Smart Grid, 2019, 10(2): 1982-1991.

- [4] 尹项根, 陈庆前, 王博, 等. 基于四层集合模型的复杂电力系统脆弱性评估体系[J]. 电工技术学报, 2013, 28(1): 225-233.  
YIN Xianggen, CHEN Qingqian, WANG Bo, et al. Vulnerability assessment system of complicated power system based on four-level set model[J]. Transactions of China Electrotechnical Society, 2013, 28(1): 225-233.
- [5] 孙立强, 李鹏, 刘宣廷, 等. 考虑连锁故障的覆冰灾害下输电线路脆弱性分析模型[J]. 高压电器, 2022, 58(1): 155-161, 169.  
SUN Liqiang, LI Peng, LIU Xuanting, et al. Analysis model of transmission line under ice coating disaster considering cascading fault[J]. High Voltage Apparatus, 2022, 58(1): 155-161, 169.
- [6] 林攀, 吴佳毅, 黄涛, 等. 电力系统脆弱性评估综述[J]. 智慧电力, 2021, 49(1): 22-28.  
LIN Pan, WU Jiayi, HUANG Tao, et al. Overview of vulnerability assessment for power systems[J]. Smart Power, 2021, 49(1): 22-28.
- [7] 王涛, 刘雨濛, 顾雪平, 等. 基于连锁故障时空图的电网脆弱线路辨识[J]. 中国电机工程学报, 2019, 39(20): 5962-5972.  
WANG Tao, LIU Yumeng, GU Xueping, et al. Vulnerable lines identification of power grid based on cascading fault space-time graph[J]. Proceedings of the CSEE, 2019, 39(20): 5962-5972.
- [8] 倪良华, 闻佳妍, 张晓莲, 等. 基于受冲击与断开后果脆弱度的电网关键线路识别[J]. 电力系统保护与控制, 2020, 48(1): 81-87.  
NI Lianghua, WEN Jiayan, ZHANG Xiaolian, et al. Critical lines identification in power grid based on vulnerability of line under impact and disconnection consequence[J]. Power System Protection and Control, 2020, 48(1): 81-87.
- [9] 陶鸿飞, 谢栋, 赵福林, 等. 含大规模风电并网电力系统的關鍵线路综合辨识[J]. 电力系统保护与控制, 2020, 48(6): 115-123.  
TAO Hongfei, XIE Dong, ZHAO Fulin, et al. Comprehensive identification of critical line in power systems with large-scale wind power integration[J]. Power System Protection and Control, 2020, 48(6): 115-123.
- [10] 王佳裕, 顾雪平, 王涛, 等. 一种综合潮流追踪和链接分析的电力系统关键节点识别方法[J]. 电力系统保护与控制, 2017, 45(6): 22-29.  
WANG Jiayu, GU Xueping, WANG Tao, et al. Power system critical node identification based on power tracing and link analysis method[J]. Power System Protection and Control, 2017, 45(6): 22-29.
- [11] LIU B, LI Z, CHEN X, et al. Recognition and vulnerability analysis of key nodes in power grid based on complex network centrality[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2018, 65(3): 346-350.
- [12] 王波, 王佳丽, 刘涤尘, 等. 基于高维随机矩阵理论的电网薄弱点评估方法[J]. 中国电机工程学报, 2019, 39(6): 1682-1691, 1864.  
WANG Bo, WANG Jiali, LIU Dichen, et al. Research on evaluating vulnerability of power network based on high-dimensional random matrix theory[J]. Proceedings of the CSEE, 2019, 39(6): 1682-1691, 1864.
- [13] 黄燕, 李华强, 黄涛, 等. 基于复杂网络和暂态能量函数的支路暂态脆弱性评估[J]. 电力系统保护与控制, 2014, 42(20): 69-74.  
HUANG Yan, LI Huaqiang, HUANG Tao, et al. Branch transient vulnerability assessment based on the complex network and transient energy function[J]. Power System Protection and Control, 2014, 42(20): 69-74.
- [14] 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.
- [15] 朱大锐, 王睿, 程文姬, 等. 基于改进 PageRank 算法的输电网关键节点辨识方法研究[J]. 电力系统保护与控制, 2022, 50(5): 86-93.  
ZHU Darui, WANG Rui, CHENG Wenji, et al. Critical transmission node identification method based on improved PageRank algorithm[J]. Power System Protection and Control, 2022, 50(5): 86-93.
- [16] 杨挺, 赵黎媛, 王成山. 人工智能在电力系统及综合能源系统中的应用综述[J]. 电力系统自动化, 2019, 43(1): 2-14.  
YANG Ting, ZHAO Liyuan, WANG Chengshan. Review on application of artificial intelligence in power system and integrated energy system[J]. Automation of Electric Power Systems, 2019, 43(1): 2-14.
- [17] 刘彤, 李少岩, 顾雪平, 等. 基于图注意力网络算法的电网连锁故障关键线路辨识[J]. 中国电机工程学报, 2022, 42(15): 5448-5459.  
LIU Tong, LI Shaoyan, GU Xueping, et al. Critical line identification of cascading failures in power grid based on graph attention network algorithm[J]. Proceedings of the CSEE, 2022, 42(15): 5448-5459.
- [18] 欧旭鹏, 任涛, 王玉鹏, 等. 基于改进麻雀搜索算法优化深度学习网络超参数的短期风电功率预测[J]. 智慧电力, 2023, 51(3): 31-38, 52.

- OU Xupeng, REN Tao, WANG Yupeng, et al. Short-term wind power prediction by optimizing deep learning network hyper-parameters based on ISSA[J]. Smart Power, 2023, 51(3): 31-38, 52.
- [19] 董雷, 陈振平, 韩富佳, 等. 基于图卷积神经网络与 K-means 聚类的居民用户集群短期负荷预测[J]. 电网技术, 2023, 47(10): 4291-4301.
- DONG Lei, CHEN Zhenping, HAN Fujia, et al. Short-term load forecasting of residential user groups based on graph convolutional neural network and K-means clustering[J]. Power System Technology, 2023, 47(10): 4291-4301.
- [20] 纪鹏志, 李光肖, 王琳, 等. 基于 Transformer 深度学习网络的主动配电网多元源荷灾损辨识方法[J]. 电力建设, 2023, 44(3): 56-65.
- JI Pengzhi, LI Guangxiao, WANG Lin, et al. Transformer-based evaluation method of power outage in active distribution networks with multiple sources and loads[J]. Electric Power Construction, 2023, 44(3): 56-65.
- [21] 马帅, 刘建伟, 左信. 图神经网络综述[J]. 计算机研究与发展, 2022, 59(1): 47-80.
- MA Shuai, LIU Jianwei, ZUO Xin. Survey on graph neural network[J]. Journal of Computer Research and Development, 2022, 59(1): 47-80.
- [22] 赵晋泉, 夏雪, 徐春雷, 等. 新一代人工智能技术在电力系统调度运行中的应用评述[J]. 电力系统自动化, 2020, 44(24): 1-10.
- ZHAO Jinquan, XIA Xue, XU Chunlei, et al. Review on application of new generation artificial intelligence technology in power system dispatching and operation[J]. Automation of Electric Power Systems, 2020, 44(24): 1-10.
- [23] 冯斌, 胡轶婕, 黄刚, 等. 基于深度强化学习的新型电力系统调度优化方法综述[J]. 电力系统自动化, 2023, 47(17): 187-199.
- FENG Bin, HU Yijie, HUANG Gang, et al. Review on optimization methods for new power system dispatch based on deep reinforcement learning[J]. Automation of Electric Power Systems, 2023, 47(17): 187-199.
- [24] 朱继忠, 董瀚江, 李盛林, 等. 数据驱动的综合能源系统负荷预测综述[J]. 中国电机工程学报, 2021, 41(23): 7905-7923.
- ZHU Jizhong, DONG Hanjiang, LI Shenglin, et al. Review of data-driven load forecasting for integrated energy system[J]. Proceedings of the CSEE, 2021, 41(23): 7905-7923.
- [25] 和敬涵, 罗国敏, 程梦晓, 等. 新一代人工智能在电力系统故障分析及定位中的研究综述[J]. 中国电机工程学报, 2020, 40(17): 5506-5516.
- HE Jinghan, LUO Guomin, CHENG Mengxiao, et al. A research review on application of artificial intelligence in power system fault analysis and location[J]. Proceedings of the CSEE, 2020, 40(17): 5506-5516.
- [26] 陈桂芳, 董秀成, 郑永康, 等. 基于长短期记忆网络的继电保护测试故障诊断研究[J]. 电力系统保护与控制, 2022, 50(5): 65-73.
- CHEN Guifang, DONG Xiucheng, ZHENG Yongkang, et al. Fault diagnosis of a relay protection test based on a long short-term memory network[J]. Power System Protection and Control, 2022, 50(5): 65-73.
- [27] VELIKOVI P, CUCURULL G, CASANOVA A, et al. Graph attention networks[C]// Proceedings of the International Conference on Learning Representations, Vancouver, Canada.
- [28] BRODY S, ALON U, YAHAV E. How attentive are graph attention networks?[C]// The Tenth International Conference on Learning Representations (Virtual), April 25-29, 2022.
- [29] 蔡泽祥, 王星华, 任晓娜. 复杂网络理论及其在电力系统中的应用研究综述[J]. 电网技术, 2012, 36(11): 114-121.
- CAI Zexiang, WANG Xinghua, REN Xiaona. A review of complex network theory and its application in power systems[J]. Power System Technology, 2012, 36(11): 114-121.
- [30] 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.

收稿日期: 2023-11-21; 修回日期: 2024-02-17

作者简介:

王长刚(1987—), 男, 博士, 讲师, 主要研究方向为电力系统稳定与控制; E-mail: wangcg@ncepu.edu.cn

王先伟(2000—), 男, 硕士研究生, 主要研究方向为人工智能在电力系统中的应用; E-mail: 1655309882@qq.com

曹宇(1986—), 男, 通信作者, 博士, 教授, 主要研究方向为高比例可再生能源并网的电力系统优化调度。E-mail: ycao@ncepu.edu.cn

(编辑 魏小丽)