

华北电力大学

专业硕士学位论文

基于深度学习的交直流混联电网拓扑变化下 暂态稳定分析与控制

Transient Stability Analysis and Control of AC-DC Hybrid Power Grid Under Topology Changes Based on Deep Learning

林晗星

2022 年 5 月

国内图书分类号：TM712

国际图书分类号：621.3

学校代码：10079

密级：公开

专业硕士学位论文

基于深度学习的交直流混联电网拓扑变化下 暂态稳定分析与控制

硕士研究生：林晗星

导师：刘崇茹教授

企业导师：孙珂

申请学位：工程硕士

专业领域：电气工程

培养方式：全日制

所在学院：电气与电子工程学院

答辩日期：2022年5月

授予学位单位：华北电力大学

Classified Index: TM712

U.D.C: 621.3

Thesis for the Professional Master's Degree

**Transient Stability Analysis and Control of AC-DC
Hybrid Power Grid Under Topology Changes Based
on Deep Learning**

Candidate:	Lin Hanxing
Supervisor:	Prof. Liu Chongru
Enterprise mentor:	Sun Ke
Academic Degree Applied for:	Master of Engineering
Speciality:	Electrical Engineering
Cultivation ways:	Full-time
School:	School of Electrical and Electric Engineering
Date of Defence:	May, 2022
Degree-Conferring-Institution:	North China Electric Power University

摘 要

如何快速、准确地对电力系统进行暂态稳定分析和紧急控制是保障电力系统安全稳定运行的两个重要问题。随着新能源的大规模并网和特高压直流线路的大规模投运,我国电力系统逐渐形成交直流混联大电网,电网拓扑变化频繁、工况日益复杂,功角失稳和电压失稳现象经常同时出现,为电力系统暂态稳定分析和紧急控制带来了新的挑战。传统的基于物理模型的方法难以适应当前复杂的电网,而基于传统深度学习模型的方法可解释性较差,对拓扑变化场景的泛化能力不足。图深度学习的发展为拓扑变化下的暂态稳定分析与控制提供了新的思路。本文对基于图深度学习的交直流混联电网暂态稳定评估和控制进行了深入研究,主要研究内容如下:

(1) 针对交直流混联电网的暂态稳定评估问题,提出了一种基于图卷积聚合网络的暂态稳定评估方法。根据图神经网络的原理选择了输入特征并设计了图数据处理方法,建立了多个评估指标,基于图卷积聚合网络构建了能够有效学习电力系统拓扑结构信息的模型,通过多任务学习方式实现了模型对功角稳定和电压稳定的同步评估,验证了所提出模型的优越性。

(2) 针对评估模型缺乏可解释性问题,提出了基于梯度类激活映射和图神经网络解释器的评估模型解释方法。分析了不同解释方法的特点,通过梯度计算得到节点热力值,从母线重要性角度对评估模型进行了解释,通过特征扰动得到结构掩码和特征掩码,进一步从线路和特征重要性角度对评估模型进行了解释。

(3) 针对交直流混联电网的紧急控制问题,提出了一种基于深度图强化学习的紧急控制方法。采用图神经网络提取了环境特征,针对紧急控制任务设计了强化学习的状态空间、动作空间、奖励函数,结合暂态稳定分析,构建了紧急控制策略框架,实现了故障后的有效紧急控制决策,验证了该方法在拓扑变化场景下的有效性。

本文研究内容能够提升暂态稳定评估模型对拓扑变化的适应性,增强评估模型的可解释性,根据系统运行工况进行有效的紧急控制决策,有助于保证当前复杂电网的暂态稳定。

关键词: 深度学习; 图神经网络; 拓扑变化; 暂态稳定评估; 可解释性; 紧急控制

Abstract

How to quickly and accurately conduct transient stability analysis and emergency control of power systems are two important issues to ensure the safe and stable operation of power systems. With the large-scale grid connection of new energy and the large-scale operation of UHV DC lines, my country's power system has gradually formed a large-scale AC-DC hybrid power grid. The grid topology changes frequently, the working conditions are increasingly complex, and the power angle and voltage instability Phenomena often appear simultaneously, bringing new challenges to power system transient stability analysis and emergency control. Traditional methods based on physical models are difficult to adapt to the current complex power grid, while methods based on traditional deep learning models have poor interpretability and insufficient generalization ability to topological change scenarios. The development of graph deep learning provides a new idea for transient stability analysis and control under topology changes. In this paper, an in-depth study of transient stability assessment and control of AC-DC hybrid power grid based on graph deep learning is carried out. The main research contents are as follows:

(1) Aiming at the transient stability assessment problem of AC-DC hybrid grid, a transient stability assessment method based on graph convolution aggregation network is proposed. According to the principle of the graph neural network, the input features are selected and the graph data processing method is designed, and multiple evaluation indicators are established. Based on the graph convolution aggregation network, a model that can effectively learn the topology information of the power system is constructed. Simultaneous evaluation of the power angle stability and voltage stability of the model is carried out, which verifies the superiority of the proposed model.

(2) Aiming at the lack of interpretability of the evaluation model, an evaluation model interpretation method based on gradient class activation mapping and graph neural network interpreter is proposed. The characteristics of different interpretation methods are analyzed, the thermal value of nodes is obtained through gradient calculation, the evaluation model is explained from the perspective of bus importance, the structure mask and feature mask are obtained through feature disturbance, and the evaluation is further evaluated from the perspective of line and feature importance.

(3) Aiming at the emergency control problem of AC-DC hybrid grid, an emergency control method based on deep graph reinforcement learning is proposed. The graph neural network is used to extract the environmental features, and the state space, action space, and reward function of reinforcement learning are designed for emergency control tasks. Combined with the transient stability analysis, an emergency

control strategy framework is constructed to realize effective emergency control decision after failure. The effectiveness of the method in the topology change scenario is verified.

The research content of this paper can improve the adaptability of the transient stability assessment model to topology changes, enhance the interpretability of the assessment model, and make effective emergency control decisions according to the system operating conditions, which is helpful to ensure the transient stability of the current complex power grid.

Keywords: Deep learning, Graph neural network, Topological change, Transient stability assessment, Interpretability, Emergency control

目 录

摘 要	I
Abstract	II
第 1 章 绪论	1
1.1 研究背景与意义	1
1.2 国内外研究现状	2
1.2.1 电力系统暂态稳定分析研究现状	2
1.2.2 电力系统紧急控制研究现状	6
1.3 论文的主要工作和章节安排	8
第 2 章 基于 GraphSAGE 网络的暂态稳定评估	10
2.1 引言	10
2.2 GraphSAGE 模型	10
2.2.1 图神经网络	10
2.2.2 GraphSAGE	11
2.3 基于 GraphSAGE 网络的暂态稳定评估	15
2.3.1 时域仿真计算	15
2.3.2 输入特征选择	15
2.3.3 建模过程	16
2.4 算例分析	21
2.4.1 测试系统	21
2.4.2 生成样本集	22
2.4.3 模型评估性能测试	22
2.4.4 不同输入特征下模型性能对比	25
2.4.5 新拓扑下模型泛化能力测试	26
2.5 本章小结	27
第 3 章 暂态稳定评估模型的可解释性分析	28
3.1 引言	28
3.2 基于 Grad-CAM 的暂态稳定评估可解释性分析	28
3.2.1 Grad-CAM 理论	28
3.2.2 基于 Grad-CAM 的暂态稳定评估解释方法	31
3.3 基于 GNNExplainer 的暂态稳定评估可解释性分析	31

3.3.1 GNNExplainer 理论	32
3.3.2 基于 GNNExplainer 的暂态稳定评估解释方法	33
3.4 算例分析	34
3.4.1 基于 Grad-CAM 的预测结果解释	34
3.4.2 基于 GNNExplainer 的预测结果解释	37
3.5 本章小结	39
第 4 章 基于深度图强化学习的紧急控制策略	40
4.1 引言	40
4.2 深度强化学习	40
4.2.1 基本原理	40
4.2.2 深度 Q 网络	43
4.2.3 深度 Q 网络的改进	44
4.3 基于 DGRL 的紧急控制决策方法及流程设计	45
4.3.1 控制流程	45
4.3.2 状态空间	46
4.3.3 动作空间	47
4.3.4 奖励函数	47
4.4 基于 DGRL 的紧急控制策略框架	48
4.5 算例分析	49
4.5.1 样本生成	49
4.5.2 紧急控制决策效果分析	49
4.5.3 拓扑变化适应性分析	51
4.6 本章小结	52
第 5 章 总结与展望	53
5.1 总结	53
5.2 展望	54
参考文献	55
攻读硕士学位期间发表的论文及其它成果	61
致 谢	62

第 1 章 绪论

1.1 研究背景与意义

2020 年,全国碳排放中的 35%由电力行业产生^[1],为了实现我国“碳达峰、碳中和”目标,电力系统需要进行低碳转型,由于新能源低碳又经济,在电力系统中大力发展新能源,并构建以新能源为主体的新型电力系统,是持续推进碳减排工作,实现双碳目标的重要保证之一。具有波动性和随机性的新能源接入会加剧电力系统的不确定性;此外,电动汽车充电桩、大容量储能元件等新型负荷不断接入,会降低系统抗扰能力。随着新能源接入和新型负荷增加而不断引入的电力电子装置容易产生谐波,引发谐振,使电网调节能力下降。当前电力系统已呈现出高维度、复杂化、强非线性的特点,面临的安全稳定问题日益严峻。

电力系统发生严重故障时,若不能采取及时有效的安全防御措施,会导致系统失稳而造成大规模的停电事故,给社会带来严重的影响。近几年来,大停电事故发生在全球多地。2016 年澳大利亚“9·28”大停电事故^[2],南澳电网全停 50 小时,经济损失巨大;2017 年台湾省“8·15”大停电事故^[3],造成 3 起火警,1 人死亡,668 万户停电;2018 年巴西“3·21”大停电事故^[4],导致巴西近四分之一用户停电;2021 年美国得州“2·15”大停电事故^[5],电价涨近 200 倍,对生产生活造成严重影响。电力系统暂态失稳是引发这些大规模停电事故的内在原因。因此,暂态稳定问题仍是电力系统最关键的问题之一,对电力系统进行快速准确的暂态稳定分析和评估,以及故障后实施及时有效的控制,保证系统安全稳定运行显得尤为重要。

电力系统不同的稳定问题因基本特点不同,对应的有效控制策略通常也不同。若采用单一的稳定性分析,在系统不同失稳类型同时出现的情况下难以确定准确有效的紧急控制策略。传统的紧急控制策略是“离线预决策,实时匹配”的模式^[6],一般利用离线仿真获取的事故集寻找系统薄弱区域和重载线路,从而制定决策表,需要时根据实际情况匹配可行的策略。但当前电网运行工况复杂多变,实际运行工况往往无法与离线工况相匹配,需要调度人员依托主观经验加以操作。而“在线预决策,实时匹配”的模式尽管能在一定程序上避免离线决策无法匹配实际的问题,但需要足够快的计算速度,面对现代电力系统变化多端的场景一样存在局限性。因此,研究基于实时响应的,能够同时保证功角稳定和电压稳定的“实时决策,实时匹配”的紧急控制策略具有重大意义。

近年来,人工智能技术迅速发展,深度学习作为其中一项发展成果^[7],广泛

应用于诸多领域，具有精确、快速、适应性强等优势，通过对电网大数据的特征提取，能够充分利用数据蕴含的信息，具备应用于电力系统暂态稳定分析评估和暂态故障后紧急控制策略生成的潜力。以 TensorFlow、Pytorch 为代表的深度学习框架的成熟和图形处理器 (Graphics Processing Unit, GPU)、张量处理器 (Tensor Processing Unit, TPU) 等处理器性能的显著提升，为人工智能技术提供了软硬件平台。电力系统的广域测量系统 (Wide Area Measurements Systems, WAMS) 日益成熟，能够以较高频率实时采集电力系统的运行状态信息，为在线实时的暂态稳定评估和控制策略生成提供有效的数据源。

由于设备检修和自然灾害的影响，电网的拓扑结构变化频繁，影响系统动态特性。常规深度学习方法最初用于自然语言处理和语音识别等领域，没有考虑具有图拓扑连接关系的领域，而电力系统的节点经过线路连接形成网络，所以常规深度学习方法无法有效描述系统的拓扑连接关系，导致基于常规深度学习方法的暂态稳定分析和紧急控制策略的准确性和有效性下降。近年来兴起的图神经网络作为一种深度学习方法^[8]，能够对图结构进行有效学习，为提取系统拓扑结构信息提供了基础。此外，大多深度学习是“黑箱”模型，无法从人类角度完全理解和解释模型的决策过程。欠缺可解释性是深度学习难以实际应用于电力系统的主要障碍之一。在暂态稳定分析评估问题中，可解释性代表着寻找出影响暂态稳定的关键因素，阐明深度学习模型决策过程，给出令调度人员能够理解的结果。

鉴于以上背景和意义，本文基于图深度学习方法研究能够应对电力系统拓扑变化的暂态稳定分析评估方法，研究该方法的可解释性，并提出相应的紧急控制策略。

1.2 国内外研究现状

1.2.1 电力系统暂态稳定分析研究现状

根据 2019 年新版《电力系统安全稳定导则》，电力系统稳定性指电力系统遭受扰动后保持稳定运行的能力。本文研究的稳定问题为其中的暂态功角稳定和暂态电压稳定，其中，暂态功角稳定是指大扰动后系统各同步发电机保持同步运行并过渡到新的或恢复到原来稳态运行方式的能力；暂态电压稳定是指大扰动后系统所有母线保持稳定电压的能力。目前暂态稳定分析方法主要分为时域仿真法、直接法和机器学习法。

(1) 时域仿真法

时域仿真法，又称间接法，根据系统拓扑和元件数学模型建立由微分、代数方程组构成的全系统数学模型，以系统潮流计算结果为初值，基于上述方程组，

通过数值积分法对暂态过程求取时间解,得到各变量的随时间响应的轨迹,从而判断系统的暂态稳定性。时域仿真法可给离线样本添加稳定性标签且因为模型是根据系统中的网络拓扑关系和元件数学模型建立的,所以时域仿真法具有可解释性。时域仿真法计算精度高,能适应不同详细程度的元件模型和故障情况,但耗时较长,研究人员针对该问题进行了研究。

文献[9]基于波形松弛法设计了一种并行计算方法,具有很高的计算效率,文献[10]利用瞬时松弛法优化计算过程,避免了波形松弛法的缺陷,提升了计算效率,文献[11]利用多维泰勒级数进行线性近似,克服了牛顿法的收敛问题,文献[12]提出了一种能缩短时域仿真的时长的快速终止算法。

随着电网规模扩大和拓扑结构的不断变动,元件参数不便获取,时域仿真法计算困难,即使采用并行算法等方法改进也难以满足实时的在线安全稳定分析,更适合于离线分析。

(2) 直接法

直接法从能量观点出发,利用李雅普诺夫理论分析电力系统稳定性,通过比较系统故障切除时的能量与临界能量来判断系统稳定性,从而无需通过各状态变量的时域计算进行暂态稳定分析。从1947年Magnusson首次在电力系统暂态稳定分析中考虑使用李雅普诺夫函数开始^[13],之后30年中,Aylet^[14]、Gless^[15]、El-Abiad^[16]和Athay^[17]等研究人员陆续针对电力系统中李雅普诺夫函数的构建进行深入研究。从此开始,直接法在国内外的研究得到充分发展。对于计及转移电导的多机系统,难以找到严格的李雅普诺夫函数^[18],一般用暂态能量函数近似。目前,直接法主要包含以下几种:

1) 主导不稳定平衡点法(Controlling Unstable Equilibrium Point, CUEP),由Athay等学者首次提出^[17],采用近似故障轨迹,考虑了故障位置的影响,但在多机系统中的结果很难确保可靠性,计算量大耗时长。

2) 势能边界面法(The Potential Energy Boundary Surface, PEBS),由Kakimoto等学者首次提出^[19],通过在持续故障轨迹上寻找势能最大点,将对应势能视为临界能量,减小了计算量,但用在大规模系统中缺乏准确度。

3) 稳定域边界的主导不稳定平衡点法(Boundary of Stability Region Based Controlling Unstable Equilibrium Point, BCU),由Chiang等学者首次提出^[20],将势能边界面法和主导不稳定平衡点法有效结合,降低了计算难度,提高了计算精度。

4) 扩展等面积法(Extended Equal Area Criterion, EEAC),由我国薛禹胜院士首次提出^[21,22],利用等面积法则对由多机系统等值的单机无穷大系统进行稳定性分析。该方法基于系统降维,判断稳定性所需时间较短,尽管还存在一定争议,

但已在工程实践中表现出优异的准确性^[18]。

5) 综合法, 由我国倪以信等人提出^[23], 该方法综合了 CUEP、PEBS 和 EEAC 三种方法, 可靠性较高、计算速度快, 有良好的应用基础。

综上所述, 直接法避免了求解大量方程, 有较快的计算速度, 可额外求得稳定裕度, 但是在面对复杂电力系统时构建能量函数存在困难, 结果保守, 适应性不足。

(3) 机器学习法

机器学习法, 用数据驱动方法将复杂的物理模型和运行机理转化为数据之间的联系, 为电力系统暂态稳定分析提供了新思路。该方法利用离线训练好的模型, 能够在极短时间内完成暂态稳定评估, 有极大的应用前景。1989 年, Sobajic 等学者最早将神经网络应用于电力系统暂态稳定分析^[24], 实现故障临界切除时间的预测。尽管机器学习法起步较晚, 但随着大数据和计算机技术发展, 出现大量模型和算法的研究, 本世纪以来迅速发展, 已在多个领域成功应用, 研究内容包含暂态稳定评估的各个阶段, 其中评估模型的构建是研究的重点。机器学习法可分为浅层机器学习模型和深度学习模型。

1) 浅层机器学习方法

目前基于浅层机器学习的暂态稳定评估模型主要包括策略树 (Decision Tree, DT)、随机森林 (Random Forest, RF)、支持向量机 (Support Vector Machine, SVM)、极限学习机 (Extreme Learning Machine, ELM)、人工神经网络 (Artificial Neural Network, ANN) 等。文献[25]提出了一种计及正负样本不平衡性的 DT 模型, 并提出了利用新增样本的增量学习策略。文献[26]提出一种基于 RF 的电力系统暂态稳定评估方法, 通过多个 DT 的组合提升模型性能, 相较于经典 DT 效果更好。文献[27]基于核心向量机进行暂态稳定评估, 降低了计算复杂度, 提高了模型准确度。文献[28]通过设计不同的特征集作为输入, 训练多个 SVM 模型, 综合各个 SVM 的结果得到最终的暂态稳定评估结果, 有较高的准确度。文献[29]设计了两阶段 SVM, 在暂态稳定评估外, 还可以快速提供一种预防控制策略。文献[30]提出了一种线上更新的 ELM 暂态稳定评估模型, 获取新的运行数据后, 不需要更新所有模型参数, 缩短了更新模型所需时间, 提高了学习速度。文献[31]在经典 ELM 基础上, 考虑了误分类代价, 减小了漏警率。

文献[32]利用聚类后的训练样本输入 ANN 进行评估, 综合多个输出得到最终结果, 显著提升了算法的准确性。文献[33]将评估分为两阶段, 先利用概率神经网络划分故障场景, 再基于径向基函数 (Radial Basis Function, RBF) 网络进行暂态稳定评估, 降低了网络的训练难度。

2) 深度学习方法

由于浅层机器学习方法的学习能力有限,在应用于交直流混联系统时泛化能力差。近年来,深度学习得到了长足的发展,为电力系统暂态稳定评估提供了新思路。深度学习继承人工神经网络的优点,模仿人脑的认识模式,通过多层非线性网络结构将底层特征抽象为更高层次的表示,提取数据中蕴藏的信息。曾经深度学习的研究和应用因训练方法的缺陷止步不前,直到 2006 年, Hinton 对深度学习的提出和模型训练方法的改进重新带动了深度学习的发展,其在《科学》杂志提出的深度置信网络 (Deep Belief Net, DBN), 以及非监督贪心逐层训练方法 [34,35], 很好地解决了深度学习的训练问题, 由此掀起了深度学习的热潮。近些年已出现许多将深度学习用于电力系统暂态稳定分析的研究, 由于高性能计算的飞速发展, 一个训练好的暂态稳定评估模型完成预测的时间已缩短至 10ms 以内 [36], 为电力系统“实时决策, 实时匹配”的实现提供了方向。常用的深度学习模型有卷积神经网络 (Convolutional Neural Networks, CNN)、循环神经网络 (Recurrent Neural Network, RNN)、DBN 和堆叠自动编码器 (Stacked Auto Encoder, SAE) 等。

文献[37]基于 CNN 进行暂态电压稳定评估, 首先对电网分区, 在每个分区选择一个评估节点, 使用粒子群算法优化卷积核设置, 具有高准确性。文献[38]利用系统暂态过程数据的时序特性进行暂态稳定评估, 并采用 t 分布随机近邻嵌入降维方法提升准确度。文献[39]利用 DBN 将特征空间降维为二维空间, 提出了一种基于 DBN 的电力系统暂态稳定评估方法, 基于稳定域对模型学习到的暂态稳定规则的物理意义进行了解释。文献[40]提出了一种将堆叠降噪自动编码器 (Stacked Denoising Auto Encoder, SDAE) 和 SVM 结合的暂态稳定评估方法, 能够对失稳情况提供安全时间裕度, 并给出了可信度分析。

上述方法都是基于欧式数据, 即能以向量、矩阵形式存储, 且具有平移不变性的数据, 而电力系统拓扑连接关系和节点构成的是图数据, 属于非欧数据, 所以上述方法无法直接提取系统拓扑关系的特征, 在目前拓扑频繁变化的场景下准确性下降。此外, 上述研究对所采用的深度学习方法的解释性研究不足。已有部分学者展开相应研究。文献[41]根据消息传递图神经网络特性将系统的母线、线路特征和拓扑关系都建立到模型中, 使用 Set2Set 网络作为读取函数, 得到了能够面熟系统拓扑变化的评估模型, 在 IEEE39 节点上验证了该方法的有效性, 表明该模型在训练集中不包含的新拓扑场景下具有更好的泛化能力。文献[42]提出了一种基于图注意力深度网络 (Graph Attention Network, GAT) 的暂态稳定评估方法, 通过多头注意力改善评估效果, 设计带权重的交叉熵损失函数减小漏判率, 并提出了相应的并行训练方式来加速训练过程, 该模型能够聚合节点观测信息, 有助于提升模型的可解释性。不同于上述两种方法使用图神经网络, 文献[43]

结合 Node2vec 图嵌入算法提出了一种暂态稳定评估模型, 利用 Node2vec 将图数据转化为包含拓扑结构信息和电气量信息的特征向量, 从而使模型在拓扑变化场景下有较强的泛化能力, 在此基础上基于 CNN 和双向长短期记忆网络实现有效的暂态稳定评估。文献[44]使用局部可解释性方法 (Local Interpretable Model-agnostic Explanations, LIME) 进行了特征重要度排序, 提高了模型的可信度, 但只能针对单个样本的评估结果进行解释, 解释结果之间会存在偏差。文献[45]基于代理模型解释暂态稳定评估模型预测逻辑, 但没有严密的数学基础。文献[46]利用沙普利值加法解释方法 (Shapley Additive Explanations, SHAP) 对基于 Catboost 模型的暂态电压稳定评估方法进行可解释性分析, 对单个具体样本解释各个特征如何决定评估结果, 也可从全局角度进行解释, 提高了评估结果的可信度。

上述以深度学习为代表的人工智能方法, 通过学习数据间的映射关系可实现快速的暂态稳定分析, 深度学习理论和方法的不断更新以及国内外学者的后续研究将继续推动基于深度学习的电力系统在线暂态稳定分析的发展。

1.2.2 电力系统紧急控制研究现状

紧急控制基于完备的控制系统, 在系统大扰动或故障下, 通过紧急控制措施保证系统能继续安全稳定运行, 是我国电力系统安全防御体系中的第二道防线。目前的紧急控制方法主要分为时域仿真法、直接法和基于响应和机器学习的方法。本文主要针对紧急控制措施中最常采用的切机与切负荷进行研究^[47]。

1) 时域仿真法

时域仿真法将紧急控制问题转化为包含微分代数方程的优化问题, 以最小化控制代价为目标, 通过数值仿真寻找最优控制。

文献[48]在暂态稳定约束中采用启发式稳定指标, 将非线性约束转化为灵敏度指标形式的线性约束, 在实际大电网中验证了该方法的有效性。文献[49]通过控制参数化将切机切负荷问题转化为非线性规划问题, 提出了“微步离散法”, 实现快速切机切负荷策略。文献[50]利用简约空间内点法求解最有切机切负荷策略, 结合多线程并行技术缩短求解时间, 占用内存较小。文献[51]将原优化问题分为仿真层和优化层交替求解, 能以较少的离散点数得到较精确的结果。

时域仿真法需重复多次计算, 计算耗时长, 不适于大规模电力系统的在线应用。

2) 直接法

直接法, 也称能量函数法, 将李雅普诺夫函数应用于电力系统, 通过将紧急控制的约束条件转化为关于稳定裕度的灵敏度问题, 从而求得紧急控制的切机量

或切负荷量,主要包括 UEP、PEBS、EEAC 等方法。文献[52]使用灵敏度计算确定系统的主导 UEP 和稳定域边界,在此基础上求得切机量或切负荷量。文献[53]基于 PEBS 和暂态稳定裕度求得紧急控制方案,并利用灵敏度指标分析不同方案的优劣,从而找出最优策略。文献[54]基于 EEAC 进行定量分析,修正切机量。文献[55]基于发电机转子运动方程分析了系统不同状态下的特性,根据系统受扰后的暂态不平衡加速能量确定切机量。文献[56]将仿真和修正暂态能量函数相结合,提出了研究系统稳定裕度的混合法,结合插值法仅需 2 次仿真计算即可得到切机量,易于操作。

直接法从能量观点出发,无需对微分方程大量迭代计算,具有计算速度快的优势,但在目前日益复杂的电力系统下,直接法的精度会下降。

3) 基于响应和机器学习的方法

基于时域仿真法和直接法的紧急控制需要正确对电网建模才能有效,而现代电网运行特性复杂,以上方法出现建模困难、计算结果准确度不高等问题。现代电网需要紧急控制具有更高的实时性和准确性,WAMS 的日益成熟和机器学习方法的发展使基于实时响应的紧急控制有望实现。

基于响应的紧急控制依靠 WAMS 获取的信息和高速通信的建设。文献[57]提出一种适用于在线实时紧急控制的方法,利用 EEAC 将系统等值为简单受控系统,结合广义 Hamilton 理论求得切机量,该方法计算量少。文献[58]通过判断转速差-功角差的变化趋势,作为紧急控制的启动依据,基于两级系统相对动能的概念和 EEAC 计算切机量,该方法仅使用 WAMS 的采集的信息,具有实现实时紧急控制的前景。

基于机器学习方法的紧急控制方法依靠训练好的机器学习模型能够快速获得紧急控制策略。文献[59]利用 SVM 得到系统的稳定规则,构造可实时计算的稳定性指标,使用 SVM 求取稳定裕度,实现紧急控制决策。文献[60]利用随机森林评估暂态稳定裕度,并基于控制灵敏度寻找最优紧急控制策略。以上研究均基于机器学习中的浅层学习方法,近年来有学者研究基于深度学习方法的紧急控制,以提高结果准确性的同时保证较短的决策时间。文献[61]依据 EEAC 实现双机等值,通过长短期记忆网络(Long Short-Term Memory, LSTM)对等值机动态响应信息进行预测,继而计算切机量,实现紧急控制,该方法计算精度高、时效性强。文献[62]提出一种基于深度强化学习的紧急控制方法,运用 CNN 提取电网信息的特征,继而利用强化学习中的 Q-Learning 选择最优动作,实现切机点和切机量的决策。文献[63]提出了一种基于改进 AlexNet 网络的紧急控制方法,通过改进 AlexNet 网络预测系统失稳功角轨迹从而划分临界机群,并预测切机切负荷灵敏度,用于选择紧急控制的备选母线,进而求解优化函数得到最优控制策

略。

综上所述,紧急控制的研究正在从基于时域仿真法和直接法的离线决策匹配阶段,逐渐过渡到基于响应和机器学习的实时决策阶段,近年来基于响应和机器学习的紧急控制仍在起步阶段,目前大多数是在传统方法的基础上应用深度学习方法,而直接应用深度学习的研究中,大多基于经典模型,缺少利用改进的深度学习模型提高决策精度的研究,此外针对实际电网高维度的特点,还应探索提高模型学习效率的方法。

1.3 论文的主要工作和章节安排

综上所述,各种不同的方法为问题的解决提供了多种选择,但大多数应用于上述两类问题的方法在电力系统拓扑变化的场景下泛化能力较差,可解释性和准确性难以兼顾。因此,本文重点关注电力系统暂态稳定评估及可解释性和紧急控制策略问题,通过引入图深度学习的思想,提出新的解决方法。本文的主要内容框架和各章节安排如图 1-1 所示。

第 1 章为绪论,阐明了课题的研究背景和意义,归纳总结了当前电力系统暂态稳定评估方法和紧急控制方法的国内外研究现状,分析了基于深度学习的暂态稳定评估和紧急控制的研究存在的不足,并简要说明了全文组织结构和章节安排。

第 2 章研究了基于图深度学习的暂态稳定评估方法。首先,介绍了图神经网络的基本概念,介绍了图卷积分网络(Graph Sample and Aggregate, GraphSAGE)的基本工作原理;其次,建立基于 GraphSAGE 网络的多任务学习模型,分析了输入特征的选择,介绍了评估模型的训练方法,并建立多个评估指标;最后,通过算例分析,对比了多种模型在不同数据集下的效果,分析了不同特征集下模型的效果,对比了在新拓扑下不同模型的性能,进一步衡量了模型预测的准确率和泛化能力。

第 3 章研究了基于图深度学习的暂态稳定评估模型的解释方法。首先,介绍了梯度类激活映射(Gradient Class Activation Map, Grad-CAM)的基本理论,并建立基于 Grad-CAM 的评估模型解释方法,从母线重要性角度解释模型结果;其次,介绍了图神经网络解释器(Graph Neural Networks Explainer, GNNExplainer)的基本原理,并建立基于 GNNExplainer 的评估模型解释方法,进一步从线路和特征重要性角度解释模型结果;最后,在第 2 章建立的图神经网络模型的基础上,通过算例对模型预测行为进行解释,对比了不同故障下解释结果的区别。

第 4 章研究了基于深度图强化学习(Deep Graph Reinforcement Learning, DGRL)的紧急控制策略。首先,介绍了深度强化学习的基本原理和算法及其改进方法;其次,结合第 2 章图深度学习的研究基础,设计了基于 DGRL 的紧急

控制方法的控制流程及状态空间、动作空间和奖励函数；再次，基于第 2、3 章的研究内容，构建了基于 DGRL 的紧急控制策略框架；最后，利用算例验证了所提方法的有效性，并分析了该方法在拓扑变化下的适应性。

第 5 章为总结与展望，总结了本文的研究工作和主要结论，并对下一步的研究工作进行了展望。




图 1-1 论文内容框架和章节安排

第 2 章 基于 GraphSAGE 网络的暂态稳定评估

2.1 引言

人工智能技术利用大数据为快速、准确的电力系统暂态稳定分析提供了基础。近年来, 研究者们使用 SVM、RF、CNN、DBN 等人工智能方法对暂态稳定评估进行了大量研究。由于以上模型是为欧式数据分析设计的, 无法有效学习电力系统的拓扑结构信息, 在电力系统拓扑频繁变化的场景下易受到制约, 并不能很好地实现暂态稳定评估。

近年来, 深度学习领域迅速发展的图深度学习技术在提取拓扑结构信息上展现出了强大能力。目前, 图深度学习技术已广泛应用于网络数据分析、推荐系统、自然语言处理等许多前沿领域, 而近几年才刚出现将该技术应用于电力系统的研究。GraphSAGE 是一种较经典的图深度学习模型, 它通过对节点信息的采样和聚合提取节点特征和结构特征, 能够有效对图数据进行学习, 有较高的预测准确率。

本章对 GraphSAGE 模型的原理进行介绍, 提出基于 GraphSAGE 网络的多任务暂态稳定评估方法, 实现对暂态功角稳定和暂态电压稳定的预测, 并对测试多种模型的评估能力, 从不同角度分析了模型性能。

2.2 GraphSAGE 模型

2.2.1 图神经网络

图神经网络利用图的属性信息和结构信息, 基于传统深度学习模型和图数据操作, 采用了根据图中节点的依赖关系在节点上传播信息的计算方式, 成功使深度学习能够正确处理图数据的输入, 并且保留图的结构信息。


早期的图神经网络通过迭代地传播邻居节点信息周期性地更新节点状态, 直到达到不动点, 迭代过程中发现节点状态满足收敛标准时, 将最后一步的节点状态输入到输出层, 通过交替进行的节点状态传播和网络参数更新来训练图神经网络。图神经网络中, 图数据用 $G=(V, E)$ 的形式表示, 其中 V 为节点的集合, E 是边的集合, 用 $v_i \in V$ 表示节点 i , 用 $e_{ij}=(v_i, v_j) \in E$ 表示节点 j 指向节点 i 的边。图神经网络通过邻接矩阵 $A^{n \times n}$ 表示节点连接关系, 其中当 $e_{ij} \in E$ 时, $A_{ij}=1$; 当 $e_{ij} \notin E$ 时, $A_{ij}=0$, n 为节点个数。一个图可能包括节点属性和边属性, 其中节点


属性用节点特征矩阵 $X \in R^{n \times D}$ 表示, 该矩阵由节点特征向量 $x_v \in R^D$ 组成, D 为节点特征个数。近年来, 随着图深度学习方法日渐收到广泛关注, 涌现出了很多图神经网络模型的研究。目前图神经网络主要分为四类, 分别是图卷积神经网络^[64-71]、循环图神经网络^[72,73]、图自动编码器^[74-77]和时空图神经网络^[78-80]。

图卷积神经网络的出现得益于传统卷积神经网络在多领域的成功应用。卷积神经网络利用其平移不变性, 对欧式数据进行特征提取, 而非欧数据的不规则结构使得传统卷积无法直接应用于非欧数据的特征提取, 例如在二维矩阵中每个节点和其他节点的空间关系是固定的, 周围节点个数也固定, 对矩阵边缘进行填充后, 一个卷积核即可扫描所有数据, 而图数据中节点的度差异很大, 一个卷积核无法适用于所有的节点。由此近些年出现了许多重新定义图卷积概念的方法, 主要分为基于谱方法^[64-68]和基于空间方法^[69-71]两类。图卷积神经网络利用多个图卷积层汇总节点特征和邻居节点的特征, 计算节点表示, 通过在每层中使用不同的参数避免了早期图神经网络因参数共享而产生的计算代价太大的问题。

2.2.2 GraphSAGE

GraphSAGE 最早由 Hamilton 等学者提出^[81], 该网络属于基于空间方法的图神经网络, 通过聚合图上的信息来定义图卷积。GraphSAGE 的基本思想是通过学习节点的信息是如何依靠其邻居节点的特征聚合而更新, 得到聚合函数, 从而将学习到的聚合函数与已知的各个节点的特征和连接关系结合, 就可以得到新的节点表示, 继而用于后续预测, 其流程如图 2-1 所示, 可分为 3 个步骤: 采样邻居节点, 聚合邻居节点的信息, 利用聚合后的节点信息进行预测。





c)进行预测

图 2-1 GraphSAGE 网络结构

2.2.2.1 采样邻居节点及聚合信息

一般各个节点的邻居节点分布并不平均，区别于以往模型简单地考虑全部邻居节点，GraphSAGE 随机采样固定数量的邻居节点作为待聚合信息的节点，通过这种方式降低计算复杂度。对于邻居节点数量小于采样数量的节点，采用有放回采样方法以确保采样数量一致。

对于一个图 $G=(V,E)$ ，其中节点 v 的邻居节点为 $N(v)$ ，设网络层数为 K ，即聚合 K 次，则需要有 K 个聚合函数 $Agg^{(k)}, \forall k \in \{1,2,...,K\}$ ，用于聚合邻居节点的信息，以及权重矩阵 $W^{(k)}, \forall k \in \{1,2,...,K\}$ ，用于在不同层之间传播信息。在每一层中，对每一个节点，使用上一层其邻居节点的表示生成该层邻居节点的聚合信息，然后将其与上一层该节点的表示拼接，经过非线性变换得到该节点于该层的表示，具体过程如下：

(1) 对节点 v 进行固定大小的 K 阶邻居节点采样；

(2) 在节点上进行 K 次信息聚合的计算，计算中第 k 层节点 v 的邻居节点的聚合信息 $h_{N(v)}^k$ 由第 $k-1$ 层的邻居节点的表示生成，若 $k=1$ ，第 $k-1$ 层的节点表示为原始输入特征：

$$h_{N(v)}^k = Agg^{(k)}(\{h_u^{k-1}, \forall u \in N(v)\}) \quad (2-1)$$

(3) 获得第 k 层的聚合信息后，将其与第 $k-1$ 层节点 v 的表示拼接，通过非线性函数 σ 转化以及标准化，得到节点 v 在第 k 层的节点表示 h_v^k ：

$$h_v^k = \sigma(W^k \cdot \text{CONCAT}(h_v^{k-1}, h_{N(v)}^k)) \quad (2-2)$$

$$h_v^k = h_v^k / \|h_v^k\|_2 \quad (2-3)$$

(4) 将 K 次计算后得到的节点 v 的表示作为节点 v 的最终特征，用于后续预

测任务。

$$z_v = h_v^K, \forall v \in V \quad (2-4)$$

2.2.2.2 聚合函数的选取

与传统的深度学习所用的结构数据不同，图神经网络使用的图数据中，节点的邻居是无序的，所以聚合函数在具有较高的表达能力之外，还需要能适用于一组无序的向量，使得输入顺序的改变不会影响函数的输出。

(1) 平均聚合

该方法直接对邻居节点取平均，接着与目标节点拼接，通过激活函数非线性转换，得到目标节点于第 k 层的表示：

$$h_{N(v)}^k = \text{mean}(\{h_u^{k-1}, u \in N(v)\}) \quad (2-5)$$

$$h_v^k = \sigma(W^k \cdot \text{CONCAT}(h_v^{k-1}, h_{N(v)}^k)) \quad (2-6)$$

(2) 卷积聚合

该方法是一种改进的基于均值的聚合，直接对目标节点和邻居节点的 $k-1$ 层表示拼接后取平均，再将结果进行非线性变换，得到目标节点的第 k 层表示，可显著提高模型的性能：

$$h_v^k = \sigma(W \cdot \text{mean}(\{h_v^{k-1}\} \cup \{h_u^{k-1}, \forall u \in N(v)\})) \quad (2-7)$$

(3) LSTM 聚合

该方法基于 LSTM 结构，表达能力强于平均聚合，但需要以顺序的方式处理输入，其结构不对称，使用时需要先随机排序邻居节点，再将产生的节点序列作为输入。




图 2-2 LSTM 的传递过程

典型 LSTM 结构下的信息传递过程如图 2-2 所示，其中状态为 t 时， c^t 、 h^t 、 x^t 、 y^t 分别为当前状态下的细胞状态、隐藏状态、输入和输出，应用于聚合函数时，各个输入为排序后的不同的邻居节点。




图 2-3 LSTM 内部结构

LSTM 内部结构如图 2-3 所示，遗忘门 f^t 、输入门 i^t 和输出门 o^t 对模型的训练起重要作用，如式 (2-8)、(2-9)、(2-10)：

$$f^t = \sigma(U_f h^{t-1} + W_f x^t) \quad (2-8)$$

$$i^t = \sigma(U_i h^{t-1} + W_i x^t) \quad (2-9)$$

$$o^t = \sigma(U_o h^{t-1} + W_o x^t) \quad (2-10)$$

(4) 池化聚合

该方法先通过全连接层对邻居节点表示进行非线性变换，再利用最大池化或平均池化获取邻居节点的突出表示或综合表示，以此作为邻居节点在第 k 层的聚合信息，将其与目标节点的在 $k-1$ 层的表示拼接，得到所求目标节点的表示，采用最大池化时公式如下：

$$h_{N(v)}^k = \max \left\{ \left\{ \sigma(W_{\text{pool}} h_{u_i}^h + b), \forall u_i \in N(v) \right\} \right\} \quad (2-11)$$

$$h_v^k = \sigma(W^k \cdot \text{CONCAT}(h_v^{k-1}, h_{N(v)}^k)) \quad (2-12)$$

2.2.2.3 参数学习

在定义好聚合函数之后，就要利用聚合得到的信息进行预测任务，而准确的预测需要模型学习各个聚合函数的参数，因此需要设计一个损失函数，根据目标任务和学习形式的区别有所不同，主要分为无监督和有监督两种情况。

(1) 无监督学习

对于无监督学习，损失函数需要让临近的节点具有相似的表示，而偏远的节点的表示区别尽可能不同，采用的损失函数如下：

$$J_g(z_u) = -\log(\sigma(z_u^T z_v)) - Q \cdot \mathbb{E}_{v \sim P_n(v)} \log(\sigma(-z_u^T z_v)) \quad (2-13)$$

其中， z_u 是节点 u 的最终特征，节点 v 是通过固定数量的随机采样获取的节点 u 的邻居节点， P_n 为负采样的概率分布， Q 定义负采样的数量，节点表示之间

的相似度通过对不同节点表示进行向量点积计算得到。

(2) 有监督学习

对于有监督学习，根据具体任务区别而设置，对于一般的分类任务采用交叉熵损失函数：

$$J = -\frac{1}{M} \sum_{c=1}^M \sum_{i=1}^N p(x_{ci}) \log(q(x_{ci})) \quad (2-14)$$

其中， M 为样本个数； N 为类别数量； $p(x_{ci})$ 为样本 c 的类别为 i 的真实概率， $q(x_{ci})$ 为样本 c 的类别为 i 的预测概率。

通过前向传播过程获取节点的最终表示，计算损失函数后利用基于梯度下降的方法进行反向传播，从而更新网络中各个参数，以此训练网络。

2.3 基于 GraphSAGE 网络的暂态稳定评估

2.3.1 时域仿真计算

本文使用时域仿真生成评估模型训练所需的样本。通过改变负荷水平、故障位置和拓扑结构来获取丰富多样的样本。获得所需样本后，依据暂态稳定指数（Transient Stability Index, TSI）将样本划分为暂态功角失稳样本和暂态功角稳定样本^[82]，如式 (2-15) 所示。稳定样本标记为 (1, 0)，失稳样本标记为 (0, 1)，以此给样本数据增加暂态功角稳定标签。

$$TSI = \frac{180^\circ - |\Delta\delta_{\max}|}{180^\circ + |\Delta\delta_{\max}|} \quad (2-15)$$

式中， $\Delta\delta_{\max}$ 为仿真时长内任意两台发电机的最大功角差值，当 $TSI < 0$ 时则认为系统暂态功角失稳；当 $TSI > 0$ 时，认为系统暂态功角稳定。

同时，根据暂态电压稳定实用判据^[83]对样本数据进行暂态电压稳定类别的划分，并以此增加暂态电压稳定标签。若母线节点电压在故障后低于 0.75p.u. 的时间不超过 1 秒，判定为暂态电压稳定，标记为 (1, 0)；反之则判定为暂态电压失稳，标记为 (0, 1)。

2.3.2 输入特征选择

深度学习模型评估性能受输入特征的构成影响。系统中的特征量有很多，虽然输入的特征越多，保留的系统信息就越多，但模型训练所需的时间越长，评估时间也会增加，会大大降低深度学习模型的运行效率，所以需要选择合理且合适的特征量作为模型的输入特征，从而在提高模型的评估性能的同时提升模型的运

行效率。

从时间角度看，特征分为静态特征和动态特征。静态特征为系统稳定运行时的特征，包括母线电压、线路潮流、发电机和负荷的有功功率和无功功率等，反映系统的运行方式；动态特征为系统故障时和故障后的特征，包括发电机功角、转子动能等，反映系统受扰的严重程度。

从空间角度看，特征分为电网参数特征和发电机参数特征。电网参数特征包括母线电压、负荷有功无功、线路潮流等特征，发电机参数特征包括发电机输出功率、电压、功角等特征。

从系统规模角度看，特征分为元件级特征和系统级特征。元件级特征即单个元件的特征，随着系统规模增大其数量会增加；系统级特征为综合多个元件特征得到的指标，反映系统整体的状态，但损失了元件的具体信息。

由于本文同时研究暂态功角稳定和暂态电压稳定，电压、相角、有功功率和无功功率均为重要特征，考虑图神经网络处理的图数据的特性，本文选取发电机的有功功率和无功功率、负荷的有功功率和无功功率、母线的电压和相角、线路潮流等元件级特征以及故障信息作为输入特征，如表 2-1 所示。

表 2-1 选取的原始特征

元件类型	特征符号	特征描述
发电机	$P_{ik_1}^G$ 、 $Q_{ik_1}^G$	节点 i 所连发电机 k_1 输出的有功功率和无功功率
负荷	$P_{ik_2}^L$ 、 $Q_{ik_2}^L$	节点 i 所连负荷 k_2 吸收的有功功率和无功功率
母线	V_i 、 θ_i	节点 i 的电压和相角
	F_i	节点 i 的故障信息
线路	$P_{i,j}$ 、 $Q_{i,j}$	节点 i 到节点 j 的线路上注入 i 端的功率

2.3.3 建模过程

本文采用多任务学习方式对模型进行训练和评估，图 2-4 为基于 GraphSAGE 的暂态稳定评估模型建立过程：




图 2-4 GraphSAGE 多任务模型评估流程图

具体步骤如下：

(1) 数据预处理。

时域仿真阶段直接获得的是长向量形式数据，需要将其处理为可输入 GraphSAGE 的图数据。将系统的母线视为图数据中的节点，系统的线路视为图数据中的边，这样节点的特征对应系统母线的特征，如图 2-5 所示。




图 2-5 图数据的构建

考虑到母线可能既连接发电机又连接负荷，取母线的总注入有功功率 P_i 、总

注入无功功率 Q_i 、电压 V_i 、相角 θ_i 以及故障信息 F_i 作为其特征，故障信息是一个 0-1 变量，该母线出现故障则为 1，否则为 0。因此，构建的图数据中每个节点 i 的特征可表示为五维向量 $[P_i, Q_i, V_i, \theta_i, F_i]$ ，总注入有功和总注入无功的计算如式 (2-16) 所示：

$$\begin{cases} P_i = \sum_{k_1=1}^{K_1} P_{ik_1}^G - \sum_{k_2=1}^{K_2} P_{ik_2}^L + \sum_{j \in N(i)} P_{i,j} \\ Q_i = \sum_{k_1=1}^{K_1} Q_{ik_1}^G - \sum_{k_2=1}^{K_2} Q_{ik_2}^L + \sum_{j \in N(i)} Q_{i,j} \end{cases} \quad (2-16)$$

其中， K_1 、 K_2 分别为节点 i 所连发电机和负荷的总数， $N(i)$ 为与节点 i 相连的节点集合。此外，用邻接矩阵表达样本的拓扑信息，与节点特征一起作为整体表示系统运行场景。

为了消除不同特征之间因数量级差异导致的难收敛问题，防止数据之间出现“大数吃小数”现象，使用 MinMax 归一化方法将样本的节点特征数据进行归一化处理，使各个特征处于相同的数量级，均在 0 到 1 之间，如式 (2-17) 所示。

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2-17)$$

式中， X' 为归一化后的特征， X 为原始特征数据， $X_{\max}$ 和 $X_{\min}$ 分别为样本中该特征的最大值和最小值。

此外，每个图数据都含有两个图级别的标签，分别为暂态功角稳定标签 L_1 和暂态电压稳定标签 L_2 ， $L_1, L_2 \in \{(1,0), (0,1)\}$ 。

(2) 样本划分。

依据设定的比例将样本集随机划分为训练样本 X^{train} 、验证样本 X^{val} 和测试样本 X^{test} ，并划分对应的样本标签为训练样本标签 Y^{train} 、验证样本标签 Y^{val} 和测试样本标签 Y^{test} 。

(3) 搭建模型结构。

暂态过程中功角失稳和电压失稳可能同时发生，都需要进行稳定分析评估，目前多数基于深度学习的暂态稳定分析研究采用单任务学习构建稳定评估模型，若采用单任务学习方式，需要训练两个不同的暂态稳定评估模型，占据更多的运算资源。而多任务学习在训练中共享不同任务的信息，结合不同任务的损失函数构造综合损失函数，从而调整模型参数，可以同时多个任务进行模型训练和评估，提高学习效率。本文设置任务一为暂态功角稳定评估，任务二为暂态电压稳定评估，建立多任务暂态稳定评估模型，模型中多任务学习关键结构如图 2-6 所示。




图 2-6 多任务学习模型关键结构

搭建的暂态稳定评估模型由如下各层组成：输入与数据重构层、两个 GraphSAGE 层、图池化层，以及任务一和任务二各有的两个分类器，分别包括两个全连接层和一个 Softmax 层。经过调试寻优，本文设置两个 GraphSAGE 层的节点输出特征维数都为 32，第一个全连接层的输出特征维度为 16，第二个全连接层输出特征维度为 2。首先，数据通过数据重构层变换为 5 维的节点特征和邻接矩阵，节点输入特征依次经过两个 GraphSAGE 层以及相应的 Relu 层，转化为 GraphSAGE 学习后的 32 维的节点特征，其中 Relu 层对输入作非线性变换，如式 (2-18)所示。

$$Relu(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (2-18)$$

经网络提取后的特征通过图池化层缩小尺寸。本文选取最大图池化作为图池化方式，能够减少全连接层的参数数量，加快计算速度同时防止过拟合，并且额外提取分类性能最佳的特征。随后将该特征分别输入至任务一和任务二的分类器，经过 Softmax 函数转化最终得到系统不同稳定结果的概率。Softmax 函数如式 (2-19)所示：

$$S(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2-19)$$

式中， n 为输入 Softmax 的元素总数， x_i ， x_j 为输入的元素。

(4) 模型训练。

模型构建完成后，开始使用样本数据训练模型。训练中，使用样本标签和模型输出的预测值计算损失函数，本文选取交叉熵损失函数衡量模型预测结果与真实值的差距。以任务一为例，其预测结果有暂态功角稳定和暂态功角失稳两类，其损失函数的计算如式 (2-20)所示。

$$L = -\frac{1}{M} \sum_{c=1}^M \left[p(x_{c1}) \log(q(x_{c1})) + (1 - p(x_{c1})) \log(1 - q(x_{c1})) \right] \quad (2-20)$$

式中， M 为样本个数， $p(x_{c1})$ 为样本 c 的暂态功角稳定的真实概率， $q(x_{c1})$ 为样本 c 暂态功角失稳的预测概率。

在多任务学习方式下，结合任务一和任务二的损失函数得到整体的损失，以整体损失减小的方向训练模型，通过 Adam 优化器更新模型内部参数，直到迭代次数达到设定值为止。优化器的初始学习率设置为 0.01，学习率随训练次数增加而减小，每经过 50 轮迭代学习率衰减至 90%，训练批尺寸设置为 64。此外，采用 Dropout 防止模型过拟合，提高泛化能力。

(5) 模型评估

对于电力系统暂态稳定评估，通常认为漏判的代价更大。若把稳定样本误判成失稳样本，调度人员可能误操作；而把失稳样本漏判成稳定样本，会导致调度人员无法及时采取控制措施，使得系统严重失稳。因此对于电力系统暂态稳定评估，除了准确率外，还需考虑漏判率、误判率等指标。本文基于混淆矩阵对暂态稳定评估模型进行综合评价，如表 2-2 所示。

表 2-2 基于混淆矩阵的评价

预测结果	真实类别	
	暂态稳定	暂态失稳
暂态稳定	TP	FP
暂态失稳	FN	TN

使用准确率 A_p 、失稳样本判准率 S_p 和稳定样本判准率 W_p 作为模型性能的评价指标，如下式 (2-21)、(2-22)、(2-23) 所示。

$$A_p = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (2-21)$$

$$S_p = \frac{TN}{TN+FP} \times 100\% \quad (2-22)$$

$$W_p = \frac{TP}{TP+FN} \times 100\% \quad (2-23)$$

准确率 A_p 为所有预测正确的样本个数在总样本数中的比例，是评价模型整体性能的主要指标。失稳样本判准率 S_p 为预测正确的失稳样本在所有失稳样本中的比例，表征了系统的漏判率。稳定样本判准率 W_p 为预测正确的稳定样本在所有稳定样本中的比例，表征了系统的误判率。 S_p 与 W_p 在一定程度上相互制约。

在训练结束后，将样本数据输入到训练好的评估模型中，分析电力系统的暂

态功角稳定和暂态电压稳定，作为后续控制措施启动的依据。若判断故障后系统暂态功角失稳或暂态电压失稳，则需采取切机或切负荷等措施。

2.4 算例分析

2.4.1 测试系统

本文在修改的新英格兰 10 机 39 节点系统上进行仿真分析，原系统代表美国新英格兰地区的一个 345kV 电网，共包含 10 台发电机、39 个节点和 46 条输电线路。将线路 39-9、3-4、27-17 由交流线路修改为直流传输线路，与原始交流电网结合构成交直流混联电网，如图 2-7 所示，图中红线代表直流线路。系统中 39 号母线上的发电机采用等值机模型，发电机基准容量为 500MW。考虑需要暂态电压失稳样本，在节点 15 上采用感应电动机负荷与恒功率负荷组合的形式，电动机占比 50%，将节点 8 的恒功率负荷替换为感应电动机负荷。节点系统基准功率为 100MVA。




图 2-7 修改的新英格兰 39 节点系统结构示意图

本文采用 PSCAD/EMTDC 生成样本数据，所有的程序都使用 Python 语言编写，其中的传统深度学习方法均基于 Pytorch 框架实现，图深度学习方法通过 Pytorch-Geometric 框架实现。为了方便比较不同模型性能，所有方法均在同一台计算机上运行，PC 配置为 Intel(R) Core(TM) i5-10600KF CPU @4.10GHz, 16.0GB RAM 和 NVIDIA GeForce RTX 3070 GPU。

2.4.2 生成样本集

为了获取一个相对完整的样本空间，需要从多个方面设定一系列运行状态，本文设定电力系统的负荷水平在 80%至 120%之间以 5%的步长变化。在实际中可以进一步基于历史运行数据生成样本。预想故障设置为最严重的三相短路故障，故障位置为系统各发电机母线之外的各个母线，故障切除时间为 100ms。数据采样间隔为 0.004s，仿真时间共 8s。

为了考虑拓扑变化的情况，通过改变系统拓扑获取 A、B、C 三类数据集。数据集 A 为无断线的单一拓扑数据集，数据集 B 为随机断一条线的多拓扑数据集，数据集 C 为 A 和 B 的组合。为了防止样本数量过多或过少，对数据集 A 的各档负荷水平进行随机波动，对数据集 B 的样本数进行了适当缩减。按照 2.2.1 节所述方法标注样本的暂态功角稳定性和暂态电压稳定性。各个数据集的具体情况如下：

表 2-3 数据集具体情况

数据集	功角稳定	功角失稳	电压稳定	电压失稳	总数
A	570	475	742	303	1045
B	1079	1531	1720	890	2610
C	1649	2006	2462	1193	3655

每个数据集进行随机打乱后，都按照 6:2:2 的比例划分为训练集、验证集和测试集，以便后续分析。

2.4.3 模型评估性能测试

为了验证 GraphSAGE 模型的评估性能，选择 5 种常见的机器学习模型以及另外 2 种图深度学习模型作为对比：LR、SVM、RF、DNN、CNN、图卷积神经网络（Graph Convolution Network，GCN）、GAT。GraphSAGE 的层数设定为 2 层，特征维度依次为 5-32-32，经过图池化层后形成 32 维特征向量进行分类，两个分类器的全连接层中特征维度依次为 32-16-2。GraphSAGE 的训练批尺寸为 64，初始学习率为 0.01，每过 50 次学习率下降为原本的 90%，训练 200 次。除了 GraphSAGE 外，其余模型均为单任务模型。LR 和 RF 的参数取默认值。SVM 使用径向基核函数，惩罚系数取 1，其余参数取自适应。DNN 的结构为 5 层全连接网络，特征维度依次为 243-128-64-32-16-2。CNN 的层数设定为 3 层，输出特征

维度分别为 16、32、64。GCN 的层数设定为 3 层，特征维度依次为 5-64-32-32，读取函数使用 Set2Set 模型进行实现^[84]。GAT 的层数设定为 3 层，输出特征维度分别为 32、16、8，采用多头注意力机制，头数为 4。

采用 2.3.3 节所述指标作为评估指标，考虑部分评估方法评估性能的随机性，测试时对每个模型都抽样 10 次并取各评估指标的平均值作为测试结果。分别用上述方法进行预测，得到不同模型在不同数据集下的评估结果，如表 2-4 所示。

表 2-4 模型性能测试结果

模型	输入数据集	任务一			任务二		
		$A_p / \%$	$S_p / \%$	$W_p / \%$	$A_p / \%$	$S_p / \%$	$A_p / \%$
LR	数据集 A	88.96	89.74	96.02	87.49	83.38	92.10
	数据集 B	86.03	85.36	95.19	85.18	81.72	94.14
	数据集 C	83.05	82.83	95.77	81.72	74.71	89.23
SVM	数据集 A	88.22	87.91	95.53	87.25	85.81	89.20
	数据集 B	85.84	83.64	92.54	83.70	79.40	89.49
	数据集 C	88.02	82.68	89.86	87.96	81.98	93.44
RF	数据集 A	89.27	87.44	93.30	88.81	87.00	93.13
	数据集 B	89.53	86.36	93.21	89.81	86.27	93.85
	数据集 C	87.08	84.89	95.77	84.79	80.43	89.64
DNN	数据集 A	93.74	91.92	96.81	91.13	86.47	92.54
	数据集 B	95.17	93.36	97.27	90.80	88.09	95.88
	数据集 C	94.35	93.27	97.53	91.66	91.88	93.06
CNN	数据集 A	94.92	92.93	97.57	92.82	89.31	94.07
	数据集 B	95.36	92.70	97.74	93.42	90.52	94.01
	数据集 C	95.03	93.02	96.54	93.16	91.47	95.54
GCN	数据集 A	97.23	95.85	97.79	96.10	94.61	97.34
	数据集 B	97.11	96.26	98.72	95.32	94.33	96.36
	数据集 C	97.20	95.72	98.91	95.39	94.27	96.14
GAT	数据集 A	96.53	95.18	97.56	92.97	91.43	96.03
	数据集 B	95.92	94.68	96.49	93.76	92.22	95.31
	数据集 C	96.98	95.43	97.76	94.03	93.77	95.46
GraphSAGE	数据集 A	97.68	96.39	97.85	95.89	94.42	96.39
	数据集 B	98.19	95.35	98.60	97.08	95.43	98.49
	数据集 C	98.31	97.26	99.19	96.94	94.91	97.32

可以看出,在不同的数据集下,GraphSAGE 的预测性能均高于其他模型,显著高于浅层机器学习模型和传统深度学习模型,其中对于任务一和任务二,数据集 A 的预测准确率比 CNN 分别高出 2.76%、3.07%,数据集 B 的预测准确率比 CNN 分别高出 2.83%、3.66%,数据集 C 的预测准确率比 CNN 分别高出 3.28%、3.78%。比较不同数据集的结果,可以看出,GraphSAGE 模型性能的优势随着数据集中拓扑变化复杂程度的增加而逐渐凸显。与同样是深度图网络模型的 GCN、GAT 相比,GraphSAGE 的性能仍然有小幅提升。此外,相比于其他模型,GraphSAGE 的失稳样本判准率和稳定样本判准率更高,且相对比较均衡,对输入特征具有更强的表达能力。在不同数据集下,所提出的模型对任务一和任务二的预测准确率更加接近,更好地挖掘了暂态功角稳定和暂态电压稳定内在的关系。因此,本文所提出的 GraphSAGE 多任务学习模型能够有效应对电力系统的拓扑变化,具有较高的准确性。




图 2-8 不同模型在训练过程中对验证集的任务二准确率

选取上述性能测试中表现最好的 5 种模型,在数据集 A 下对验证集的任务二的预测准确率如图 2-8 所示。可以看出,GraphSAGE 在训练迭代 25 次以后开始收敛,比除 CNN 之外的其他模型的收敛速度都快,且收敛过程中预测准确率的振荡幅度小。CNN 虽然收敛速度最快,但由于不能有效学习电网拓扑结构信息,预测准确率不高。

表 2-5 在线评估耗时对比

模型	平均单个样本在线评估耗时/ms
DNN	0.0381
CNN	0.0592
GCN	0.1929
GAT	0.1663
GraphSAGE	0.1452

同样选取 DNN、CNN、GCN 等 5 种模型进行在线评估的耗时对比，结果如表 2-5 所示。可以看出，由于本文所提出的 GraphSAGE 多任务学习模型针对节点进行计算，需要训练的参数较多，在线评估耗时明显大于传统深度学习模型，但相较于其他图深度学习模型，其在线评估耗时最短，平均单个样本的评估耗时仅为 0.1452ms，满足在线评估的要求。

2.4.4 不同输入特征下模型性能对比

模型输入特征对模型分类性能具有重要影响，选择 4 种不同的输入节点特征集合作为模型输入，对本文提出的基于 GraphSAGE 的暂态稳定评估模型进行测试。表中的特征集 A 即前文模型评估性能测试所用的节点特征集，其余特征集为该特征的子集。测试时模型只改变最底层的输入维度，其余结构和参数均不改变。

表 2-6 特征集内容

节点特征集	特征内容
A	电压幅值、相角、注入有功功率、注入无功功率、故障信息
B	电压幅值、注入有功功率、注入无功功率、故障信息
C	相角、注入有功功率、注入无功功率、故障信息
D	注入有功功率、注入无功功率、故障信息

图 2-9 为采用不同特征集作为输入时，模型的 3 个性能指标的对比情况。由图可知，仅利用节点注入有功功率和无功功率时，模型评估性能一般。节点电压幅值和相角都对模型的准确预测起正向作用，实际应用时，若节点电压幅值和相角信息都可以得到，应该采用包含信息最多的特征集 A 作为输入模型的节点特征集。




图 2-9 不同特征集下的评估结果

2.4.5 新拓扑下模型泛化能力测试

电力系统的拓扑结构变化频繁，为了模型能够适应未学习到的新拓扑场景，目前已有的方法大多采用模型更新和增加新数据集的方法。提升模型自身对新拓扑结构的泛化能力能够有效减小在线应用时模型更新的计算代价。

通过随机断开两条线路生成新数据集，验证本文所提方法在拓扑变化场景下的泛化能力。由于断开两条线路的拓扑情况太多，仅考虑 20 种拓扑，每种拓扑下的故障设置和负荷水平设置与数据集 B 相同，共生成 5220 个样本。本节模型采用 2.4.3 节通过数据集 C 训练得到的模型，该模型学习的样本所含的拓扑中不包含断开两条线的拓扑，对该模型进行新拓扑数据集下的泛化能力测试并与其他深度学习模型对比，任务一和任务二的评估准确率如图 2-10 所示。




图 2-10 新拓扑下模型性能对比

由图 2-10 可知,本文所提的 GraphSAGE 模型在新拓扑测试集上比其他模型有更好的预测准确率,可以更有效地实现对系统暂态功角稳定和暂态电压稳定的评估,表明 GraphSAGE 模型更适应拓扑变化的新场景,泛化能力更好。因此,本文所提的电力系统暂态稳定评估模型在实际上拓扑多变的电力系统中具有更好的应用前景。

2.5 本章小结

本章提出了一种基于 GraphSAGE 网络的电力系统多任务暂态稳定评估方法,得到能够描述交直流混联系统拓扑变化的暂态稳定评估模型。在修改的新英格兰 10 机 39 节点系统上进行算例验证,结论如下:

(1) 本文方法能够有效学习电力系统拓扑结构特征,在拓扑变化的场景下具有更明显的优势,对未学习的新拓扑场景具有更好的泛化能力。

(2) 多任务学习可以让模型学习电力系统暂态功角稳定与电压稳定之间的内在联系,同时评估功角稳定和电压稳定,平衡模型对不同任务的性能,提升模型精度。

第 3 章 暂态稳定评估模型的可解释性分析

3.1 引言

当前基于机器学习的暂态稳定评估研究中,预测效果好的模型大多是“黑箱”性质的深度学习模型,缺乏透明度、可解释性不足,难以获得使用者的信任,机器学习方法真正应用于电力系统需要能够对机器学习模型进行解释。已有学者针对常规深度学习模型进行可解释性研究,但对于图深度学习模型还缺乏相应的研究。

Grad-CAM 是一种基于梯度计算的模型解释方法,能够由常规深度学习推广到图深度学习中。GNNExplainer 是一种针对图神经网络设计的基于扰动的模型解释方法,能够对从结构和具体特征的不同角度解释影响模型结果的关键因素。

本章对 Grad-CAM 和 GNNExplainer 的原理进行简要介绍,基于 Grad-CAM 和 GNNExplainer 分别提出一种电力系统暂态稳定评估模型的解释方法,获取对模型结果有重要影响的母线、线路和输入特征作为解释结果。

3.2 基于 Grad-CAM 的暂态稳定评估可解释性分析

虽然 LIME 等模型无关的线性代理模型能够对单个样本进行特征重要度排序,提高模型的可信度,但无法保证结果的一致性,缺少严密的数学基础,而 SHAP 方法考虑所有样本的任意特征,计算特征在特征子集中的边际贡献,求取均值来获得特征重要度,虽然能够从全局角度给出特征重要度的排序,但计算复杂度随特征数量呈指数级增加。此外,由于图神经网络的输入数据结构与传统深度学习网络的区别,基于 LIME 发展出的 Graph-LIME 方法虽然适用于图神经网络的可解释性分析,但只能用于节点分类任务,而暂态稳定评估模型属于图分类任务,无法基于 Graph-LIME 进行可解释性分析,SHAP 方法在图神经网络中使用同样存在困难。因此,需要研究适用于基于图神经网络的暂态稳定评估的解释方法。

Grad-CAM 计算量小,速度快,与模型无关,视觉效果强,基于梯度计算,能够扩展到图神经网络模型中使用,适合用于基于 GraphSAGE 的评估模型的可解释性分析。

3.2.1 Grad-CAM 理论

Grad-CAM 方法基于类激活映射(Class Activation Map, CAM)而产生,CAM

最初是为 CNN 设计的，其输入数据为结构化数据，用于输入数据为非结构化数据的图神经网络模型时需要进行一定的修改。

对于 GraphSAGE 网络，用于分类的全连接层和 Softmax 层包含难以理解的信息，并且很难用视觉方式显示。而在全连接层前的最后一个 GraphSAGE 层经过多次采样和聚合之后，包含最丰富而重要的信息。因此，需要充分发挥最后一个 GraphSAGE 层的作用，寻找基于 GraphSAGE 的评估模型的决策依据。

CAM 将全连接层替换为全局平均池化 (Global Average Pooling, GAP)。GAP 层能够包含更多的信息，支持任何尺寸的输入，不含有全连接层的各种参数，鲁棒性更强，泛化能力较好。

由式 (2-5)、(2-6)可知，GraphSAGE 模型中，若采用平均聚合函数，节点 n 在第 k 层的节点表示 h_n^k 的计算如下：

$$h_n^k = \sigma \left(W_1^k h_n^{k-1} + W_2^k \text{mean} \left(\{ h_u^{k-1}, u \in N(n) \} \right) \right) \quad (3-1)$$

$$h_n^k = h_n^k / \|h_n^k\|_2 \quad (3-2)$$

所以，网络第 k 层的所有节点特征表示如下式所示：

$$H^k = \begin{Bmatrix} h_1^k \\ h_2^k \\ \dots \\ h_n^k \end{Bmatrix} = \{ H_1^k \quad H_2^k \quad \dots \quad H_D^k \} \quad (3-3)$$

其中， H_1^k 、 H_2^k 、 H_D^k 为第 k 层中对应不同特征的特征图，每个特征图都由各个节点对应的特征组成，所以，最后一次聚合后的第 d 个特征图 H_d^K 的 GAP 特征表示为：

$$e_d = \frac{1}{N} \sum_{n=1}^N h_{n,d}^K \quad (3-4)$$

其中， K 为总聚合次数， $h_{n,d}^K$ 为节点 n 在第 K 层的第 d 个特征。

由于 GAP 替换掉了全连接层，对每一个分类类别 c ，在 Softmax 层之前，模型输出的类别分数 y^c 与 e_d 有如下的关系：

$$y^c = \sum_d \omega_d^c e_d \quad (3-5)$$

其中， ω_d^c 为特征 d 对类别 c 的权重，可由网络训练得到，反映了该特征在类别 c 的分类任务中的重要性。

解释分类结果时，使用类别 c 对应的所有权重 ω_d^c ，求取他们与自身对应的 GAP 特征的加权即可得到用于解释的热力图，将该热力图与原始输入的图数据

叠加即可了解模型通过哪些节点确定样本的类别。所以，热力图中节点 n 的热力值计算如下式所示：

$$L_{CAM}^c[n] = Relu\left(\sum_d \omega_d^c h_{n,d}^k\right) \tag{3-6}$$

其中，Relu 函数让热力值计算只关注对类别 c 的分类起正影响的节点特征，从而使热力图中只突出对分类起正影响的节点。

CAM 方法虽然能直接使用网络中的参数对模型行为进行解释，且计算量小，但需要修改原本模型的结构，必须重新训练模型。而实际上，若模型已经训练完成，重新训练模型的代价往往非常高，导致该方法的应用范围受到较大限制。

Grad-CAM 与 CAM 计算解释结果的方法相似，都是使用每个特征图的权重对节点特征加权求和得到节点热力值，从而生成特征图。二者不同的是特征图权重的计算方式。CAM 在用 GAP 层代替全连接层后，需要重新训练网络获得特征图权重，而 Grad-CAM 采用梯度求导来计算特征图权重。

定义 Grad-CAM 中第 k 层的特征 d 对类别 c 的权重为 $\alpha_d^{k,c}$ ，可通过以下公式求得：

$$\alpha_d^{k,c} = \frac{1}{N} \sum_{n=1}^N \frac{\partial y^c}{\partial h_{n,d}^k} \tag{3-7}$$

与 CAM 方法类似，求得特征图权重后，通过加权求和即可得到 Grad-CAM 的热力图，其中节点 n 的热力值如下式所示：

$$L_{Grad-CAM}^c[k,n] = Relu\left(\sum_d \alpha_d^{k,c} h_{n,d}^k\right) \tag{3-8}$$




图 3-1 Grad-CAM 方法示意图

Grad-CAM 方法的整个计算流程如图 3-1 所示。Grad-CAM 方法基于梯度计算，不需要修改网络结构，也不需要重新训练模型。而且，Grad-CAM 方法能够

生成网络不同层上的热力图，而 CAM 方法只能得到最后一层的热力图，两种方法在最后一层上的权重是等价的^[85]。因此 Grad-CAM 方法极大地扩展了基于热力图的可解释方法的应用范围，能够给出更细致的解释结果，但由于同样采用全局平均池化和计算时可能产生的梯度消失问题，最终解释结果有时会存在偏差。

3.2.2 基于 Grad-CAM 的暂态稳定评估解释方法

将 Grad-CAM 方法引入本文的暂态稳定评估结果的可解释性分析中，由于本文的暂态稳定评估采用多任务学习方式同时对暂态功角稳定和暂态电压稳定进行分析，所以需要两组不同的全连接层，Grad-CAM 方法计算的权重也分为对应功角稳定和电压稳定的两部分。

由于两部分原理相同，只是具体计算所得数值不同，本节仅针对暂态功角稳定部分进行说明。对于暂态功角稳定分类任务，定义类别 $c = \{0, 1\}$ ，分为两类， $c = 0$ 为功角稳定， $c = 1$ 为功角失稳，式 (3-8) 中 $L_{\text{Grad-CAM}}^c[k, n]$ 的含义为第 k 层中节点 n 的对功角稳定或电压稳定的热力值， $\alpha_d^{k,c}$ 则表示第 k 层的特征 d 对暂态功角稳定或暂态电压稳定的权重，将所有节点的热力值组成的热力图与进行暂态稳定分析的电力系统结构图结合，即可清晰地看出模型主要通过系统的哪些节点确定了稳定类别。本文在暂态稳定评估中使用的 Grad-CAM 在加权求和之后不经过 Relu 函数，保留对分类起负影响的节点特征，从而在热力图中同时表现对分类起正影响和负影响的节点，可以发现多个角度下节点的重要性，进一步明确样本的稳定状态是由哪些节点决定的。

3.3 基于 GNNExplainer 的暂态稳定评估可解释性分析

尽管 Grad-CAM 方法不用修改网络结构就能进行可解释性分析，但基于梯度的计算可能带来梯度消失的问题，导致最终解释结果不同。此外，Grad-CAM 只能针对不同节点对模型评估结果的影响进行解释，难以深入分析不同节点的不同特征对模型结果的影响，且没有考虑到图的结构特征，对暂态稳定分析结果的解释有限。因此，需要研究适用于图神经网络的解释结果更可靠且信息更丰富的解释方法。

基于代理模型的 Graph-LIME 方法和基于特征梯度的 Grad-CAM 方法都源于对传统深度学习的可解释性研究，故而无法考虑图的结构特征。GNNExplainer 是一种基于扰动的模型解释方法，通过输出包含结构特征的原始图的子图和对预测结果影响最大的节点特征的集合来进行解释。该方法不需要修改网络结构，也不需要重新训练原本的网络，适用于任何以图神经网络为基础模型。

3.3.1 GNNExplainer 理论

GNNExplainer 给出的子图最大化了子图与模型输出之间的互信息，这通过学习一个用于筛选图网络输入中的重要子图的结构掩码来实现。同时，GNNExplainer 通过学习一个特征掩码能够屏蔽不重要的节点特征，在另一层面上对模型结果给出解释。

信息论中，基于信息量非负、可加、连续依赖于概率等特点，定义发生事件 x 的信息量为 $-\log P(x)$ ，即该事件发生的概率的负对数。而信息熵考虑事件的所有可能，是平均来看发生某个事件所获得的信息量大小，所以信息熵从数学上看是信息量的期望，如下式所示：

$$H(X) = -\sum_{x \in X} P(x) \log P(x) \quad (3-9)$$

式中， X 为事件的所有可能的集合，数学上属于一个随机变量。信息熵 $H(X)$ 衡量随机变量 X 的不确定性，其大小与随机变量的不确定性大小正相关。

互信息 (Mutual Information, MI) 是衡量随机变量之间相互依赖程度的信息度量，可视为已知一个随机变量时，另一个随机变量的不确定性的变化量。假设有两个随机变量 X 和 Y ，二者的互信息计算方式如下式所示：

$$\begin{aligned} MI(X, Y) &= H(X) - H(X|Y) \\ &= \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \end{aligned} \quad (3-10)$$

其中， $H(X|Y)$ 是 Y 已知的情况下 X 的信息熵，也称为条件熵； $p(x, y)$ 为随机变量 X ， Y 的联合概率分布； $p(x)$ 和 $p(y)$ 为边缘概率分布。

对于一个图分类任务，假设所有样本共分为 C 类，对应标签为 $\{1, \dots, C\}$ ，原始图表示为 $G = (V, E)$ ，原始节点特征为 X_A 。GNNExplainer 需要寻找对图神经网络预测结果重要的子图 G_S 和节点特征 X_S ，其中 X_S 为原始节点特征 X_A 的子集。通过互信息可以衡量子图和节点特征对模型预测结果的重要性，所以所求的是与模型预测之间互信息最大的子图和节点特征，如下式所示：

$$\max MI(Y, (G_S, X_S)) = H(Y) - H(Y|G = G_S, X = X_S) \quad (3-11)$$

式中， Y 是预测结果的随机变量，表示样本属于各个类别的概率。将预测模型表示为 Φ ，则预测结果 $y = \Phi(G(V), X(V))$ ，互信息量化了当用于计算的子图为 G_S 和节点特征为 X_S 时，模型预测出的概率的变化。

对于训练好的模型 Φ ，其输入到输出的映射是确定的，所以 $H(Y)$ 是常数项。因此，最大化预测结果的随机分布 Y 和预测结果的解释 (G_s, X_s) 之间的互信息等价于最小化条件熵 $H(Y|G = G_s, X = X_s)$ ，如下式所示：

$$\min H(Y|G = G_s, X = X_s) = -\mathbb{E}_{Y|G_s, X_s} [\log P_{\Phi}(Y|G = G_s, X = X_s)] \quad (3-12)$$

GNNEExplainer 通过学习结构掩码 M 和节点特征掩码 F 来优化该条件熵，获得解释模型结果的子图和节点特征。结构掩码 $M \in R^{n \times n}$ 与原始图的邻接矩阵进行运算可得到子图 G_s ，如下式所示：

$$G_s = A \odot \sigma(M) \quad (3-13)$$

式中， A 为包含所有节点连接结构信息的邻接矩阵， $\odot$ 表示将矩阵同位置元素相乘， σ 为将掩码元素映射到 0 与 1 之间的激活函数。

节点特征掩码 F 与原始节点特征进行运算可得到作为模型结果解释的部分节点特征 X_s ，如下式所示：

$$X_s = X_A \odot F \quad (3-14)$$

因此，所求的最小化条件熵如下式所示：

$$\begin{aligned} \min H(Y|G = G_s, X = X_s) \\ = -\mathbb{E}_{Y|G_s, X_s} [\log P_{\Phi}(Y|G = A \odot \sigma(M), X = X_A \odot F)] \end{aligned} \quad (3-15)$$

训练中通过使用蒙特卡洛估计从节点特征的经验边缘分布中采样防止解释结果忽略对模型预测结果关键的特征，通过将子图 G_s 与节点特征 X_s 作为输入时模型的输出，与原本训练好的模型的输出比较来计算损失，利用重参数化技巧^[86]反向传播梯度给 F 来学习节点特征掩码。

图神经网络通过节点特征和图结构信息共同进行预测才能在有较高准确率的同时对新拓扑结构下的样本具有较高的泛化能力，图结构信息起着至关重要的作用，而目前基于传统深度学习的解释方法发展而来的方法难以利用图结构信息，对图网络模型结果的解释存在局限性。GNNEExplainer 同时考虑了图结构和节点特征的信息来解释模型预测，且不局限于特定的 GNN 模型，能够适用于图神经网络模型且给出不同层面的解释。

3.3.2 基于 GNNEExplainer 的暂态稳定评估解释方法

将 GNNEExplainer 引入本文的暂态稳定评估结果的可解释性分析中，作为对 Grad-CAM 解释结果的进一步补充。由于本文的暂态稳定评估采用多任务学习方式，模型输出针对功角稳定和电压稳定分为两类结果，而 GNNEExplainer 需要对

比原模型输出和输入扰动后的模型输出来更新掩码，所以 GNNExplainer 在本文模型中也需要分为两部分。

对于暂态功角稳定分类任务中的单一样本，基于 3.2.2 节对分类类别的定义，式 (3-15)可改写为：

$$\min_{M,F} -P_{\Phi}(Y=c|G=A\odot\sigma(M),X=X_A\odot F) \cdot \log P_{\Phi}(Y=c|G=A\odot\sigma(M),X=X_A\odot F) \quad (3-16)$$

式中， P_{Φ} 的含义为只输入部分节点特征和拓扑结构信息时，评估模型对功角稳定类别为 c 的样本的预测概率。该条件熵最小对应着 P_{Φ} 的最大值，以及对模型预测结果最重要的图结构和节点特征信息。结构掩码反映求得的子图结构，将掩码各数值与原始电力系统结构图中的对应线路结合，即可清晰地看出系统中哪些线路对系统的暂态稳定性起关键作用，继而可以在一定程度上表现重要的母线。节点特征掩码反映求得的部分节点特征，将掩码的各个数值以热力图的形式表现可直观地看出系统稳定性主要受哪些节点特征影响。

对于单个任务，基于上述 GNNExplainer 方法的暂态稳定评估结果解释框架如下图 3-2 所示。




图 3-2 暂态稳定评估结果的解释框架

3.4 算例分析

3.4.1 基于 Grad-CAM 的预测结果解释

为了验证所提方法在暂态稳定评估模型中的可解释性，在本文 2.4 节仿真得到的样本数据中，随机选择一个模型预测结果为功角失稳且电压失稳的样本，获

得的失稳样本 1 为：在负荷水平 110%下，系统无断线，母线 6 发生故障。模型采用通过数据集 C 训练得到的模型，图 3-3 展示了如何基于 Grad-CAM 对其预测暂态功角稳定性的结果进行解释。




图 3-3 基于 Grad-CAM 的失稳样本 1 预测结果解释

图中红色表示热力值为正的节点，对预测结果有正面影响；蓝色表示热力值为负的节点，对预测结果有负面影响。颜色越深表示该节点的热力值的绝对值越大，说明对模型预测结果的影响越大。由图 3-3 可以看出，对预测结果影响较大的节点包括节点 6 及其相邻的节点和节点 31 至节点 35 等。从物理意义的角度考虑，节点 6 为故障节点，该节点与周围相邻节点的信息最能反映故障的影响。而节点 31 至节点 35 均为发电机节点，包含用于计算功角稳定指标的发电机节点相角特征。此外，节点 31 至节点 35 为故障后功角摆开最快的几个发电机组，对暂态功角稳定性起重要作用。上述节点对暂态功角稳定性的重要性与 Grad-CAM 的解释结果是一致的，表明 Grad-CAM 一定程度上符合客观规律。

选取相同拓扑和故障情况下的暂态功角稳定样本 2，基于 Grad-CAM 对其预测暂态功角稳定性的结果进行解释，如图 3-4 所示。结合图 3-3 可知，尽管拓扑结构和故障情况相同，不同样本中的重要节点也存在部分区别。图 3-3 中颜色较深的故障节点 6 和发电机节点 34、35 对模型预测的影响方向由负变正，符合样本稳定性的改变，表明在相同拓扑和故障下，这些节点的信息都使模型更倾向于认为结果是功角失稳，对不同样本的预测结果均有重要影响。




图 3-4 基于 Grad-CAM 的失稳样本 2 预测结果解释

选取故障情况相同而拓扑结构不同的暂态功角稳定样本 3，基于 Grad-CAM 进行可解释性分析，结果如图 3-5 所示，该样本中线路 1-2 断开。对比图 3-3 和图 3-5，可以看出，各个节点的热力值大小和正负情况变化很大，如线路 1-2 周边的发电机节点 30 和 37 的对结果的影响程度增大很多，只有节点 3、节点 34 和节点 35 等部分节点在对预测结果的重要性上表现一致。从系统运行特性看，系统拓扑变化对系统潮流分布的影响很大，继而使各个节点对系统暂态稳定性的影响程度变化极大，与 Grad-CAM 的解释结果相一致，表明 Grad-CAM 能够在一定程度上学习到拓扑结构对系统稳定性的影响。




图 3-5 基于 Grad-CAM 的失稳样本 2 预测结果解释

3.4.2 基于 GNNExplainer 的预测结果解释

Grad-CAM 只能从节点对预测结果重要度的角度解释模型结果，为了获得不同角度下模型预测结果的解释，本节采用上一节所用的样本和评估模型，基于 GNNExplainer 对模型预测暂态功角稳定性的结果进行解释。样本 1 的解释结果如图 3-6 所示。图 3-6 a)为 GNNExplainer 求得的最优子图结构，通过设定阈值区分不同线路，线路对应结构掩码大于阈值，则用加粗的黑色线条显示，掩码值越大颜色越深；反之，用不加粗的灰色线条显示，设定阈值为 0.1。图 3-6 b)为节点特征掩码的热力图，每行代表一个节点的各特征的掩码，各列为不同的特征，方格颜色代表节点特征掩码数值，数值越大颜色越深。由图 3-6 可以看出，对预测结果影响较大的线路包括线路 6-31、6-7、5-8、20-34、22-35、14-15 等，影响较大的节点特征主要为节点 6 的故障信息、注入有功和无功，节点 31 的注入有功和无功，节点 34、35 的注入有功。从物理意义的角度看，故障发生在 6 号母线，而 31 号发电机与其直接相连，故而线路 6-31 和节点 6、31 中的特征对暂态功角稳定性起重要作用。34 号和 35 号发电机均为故障后功角摆开较快的发电机，其接入系统的线路 20-34、22-35 以及包含的特征也会对暂态功角稳定性起重要作用。此外，节点 15 和节点 8 由于包括感应电动机，对系统稳定性的影响比恒功率负荷更大，相连线路重要性更大。上述分析结果与 GNNExplainer 给出的结果相一致，表明 GNNExplainer 能在一定程度上解释模型预测结果从何而来。




图 3-6 基于 GNNExplainer 的失稳样本 1 预测结果解释

对样本 2 的解释结果如图 3-7 所示，与图 3-6 对比可知，在稳定样本和失稳

样本中，重要线路和和特征存在一定的差异，但节点 6、34、35 等节点相连的线路仍然是重要线路，节点 6 的注入有功和无功、节点 31、34、35 的注入有功等特征仍然是重要特征，可以看出，在稳定样本中有更多的特征对模型正确预测结果起重要作用。




图 3-7 基于 GNNExplainer 的失稳样本 2 预测结果解释

对样本 3 的解释结果如图 3-8 所示，与图 3-6 相比，大部分线路的重要度变化很大，明显看出所有线路的对应的掩码都超过了阈值，从而图中所有线路都加粗，反映出各个线路的重要性更趋于平衡，但线路 6-31、20-24、22-35 仍然是最重要的几条线路。节点特征的热力值差异减小，分布情况不同，但节点 6 的故障信息和注入有功等特征仍表现为重要特征。拓扑结构的变化对系统运行情况产生极大影响，导致对系统失稳有重要作用的线路和节点特征发生变化，可以看出 GNNExplainer 在一定程度上学习到拓扑结构对系统稳定性的影响。




图 3-8 基于 GNNExplainer 的失稳样本 3 预测结果解释

GNNExplainer 能够用于解释模型对每个样本的评估结果，找出对系统暂态失稳有重要作用的物理量和线路，可以与 Grad-CAM 从节点本身角度给出的解释结果相结合，从多角度说明模型对系统暂态稳定性的相应判断的原因，有助于排除系统稳定的潜在威胁，提高模型评估结果的可信度。

3.5 本章小结

本章从对已有机器学习模型进行解释的思路出发，基于 Grad-CAM 和 GNNExplainer 分别提出了一种暂态稳定评估模型的解释方法，对具体故障的分类进行了解释，对比分析了不同故障情况下解释结果的区别，结论如下：

(1) 基于 Grad-CAM 的解释方法能够解释模型主要通过哪些母线的信息进行稳定预测，不需要重新训练网络，减小实际应用时的计算负担。

(2) 基于 GNNExplainer 的解释方法能够进一步解释模型的预测结果主要受哪些特征和线路信息的影响，提高了模型的透明度和可信性，且不受具体图深度学习模型结构限制，使用场景广阔。

第 4 章 基于深度图强化学习的紧急控制策略

4.1 引言

从物理特性出发的紧急控制方法在复杂电力系统中通常建模困难、对电力系统结构的变化适应性不强，随着现代电力系统发展难以满足实时性、准确性的要求。

深度强化学习结合了深度学习的特征表达能力和强化学习的决策能力，能够根据不同的运行方式和系统运行状态快速进行决策并给出方案，适合用于现代电力系统的控制决策中。

本章简单介绍了深度强化学习的原理，将图神经网络用于提取环境特征，提出了一种基于 DGRL 的紧急控制方法，并在前几章的基础上设计了基于 DGRL 的紧急控制策略框架，实现电力系统故障后的有效紧急控制决策。

4.2 深度强化学习

4.2.1 基本原理

强化学习通过智能体与环境的交互来实现最优决策，属于机器学习的其中一类方法。强化学习基于对环境信息的充分分析采取行动，寻求利益最大化，其智能体通过不断尝试寻找能够产生最大利益的动作，这个过程中执行动作导致环境由上一种状态过渡到下一种状态，通过回报值量化变化的好坏。

实际生活中，很多决策问题的状态空间和动作空间的维数非常大，传统的强化学习方法无法学习到全新的状态下不同动作的好坏，难以解决高维的复杂问题。深度学习提取深层特征信息的能力正好弥补了这一点，深度强化学习（Deep Reinforcement Learning, DRL）的概念由此而来。强化学习的基本框架如图 4-1 所示。强化学习的学习过程包含了环境状态信息、动作信息和回报信息的传递以及策略的不断更新。




图 4-1 强化学习基本框架

在具体决策过程中,智能体获得环境在当前的状态 s_t ,将状态通过深度学习提取特征,根据当前策略 π 选择相应的动作 a ,智能体将动作 a 施加于环境中,使环境状态转变为新状态 s_{t+1} ,同时产生回报 r_t 与新状态一起作为反馈传回至智能体,智能体根据奖励更新策略,以使后续的动作尽可能获得更高的奖励,并进入下一个决策过程。强化学习的目标就是通过不断更新策略,使智能体能针对当前环境生成最优动作。

对于大部分强化学习问题,下一时刻的环境状态与之前时刻的状态、动作无关,故而可以转化为马尔可夫决策过程(Markov Decision Process, MDP)。MDP中观测到的环境状态内容包含所有决策需要的信息。

一个典型的MDP由以下四种元素组成:状态集 S ;动作集 A ;状态转移概率矩阵 P ,即当前状态转移到下一个状态的概率分布;奖励函数 R 。在当前时刻 t 智能体观测到环境状态为 $s_t \in S$,执行动作 $a_t \in A$ 后依据概率 p_t 环境状态转移到新状态 s_{t+1} ,依据 s_{t+1} 和 a_t 通过奖励函数获得奖励值 $r_t \in R$,从而形成马尔可夫链。

由动态特性可得如式(4-1)所示的状态转移概率。若环境中的状态转移概率为1,则该强化学习过程为确定性过程。

$$p_{s',s} = p(s_{t+1} = s' | s_t = s, a_t = a) \quad (4-1)$$

强化学习中,奖励函数的设计和价值函数的计算都极大影响着决策结果。

(1) 奖励函数

智能体收到的奖励是滞后奖励,而环境的响应具有随机性,智能体在某一时刻接收的奖励是不确定的。所以强化学习的目的是最大化累积奖励,通过对未来的奖励添加折扣来避免基于未来状态的决策和当前的决策相互冲突,为智能体寻找累积奖励最快的策略。所以 t 时刻奖励函数为:

$$R_t = E \left\{ \sum_{k=0}^K \gamma^k r_{t+k+1} \right\} \quad (4-2)$$

式中, K 为智能体与环境的交互次数; $\gamma \in (0,1)$ 为折扣因子。 R_t 表示长期奖励期望。

所以,强化学习时即便一个动作获得的奖励很小,如果在后续决策中智能体能够获得较高的奖励,也能让该动作有较高的评价,故而强化学习具有较强的寻找最优策略的能力。

(2) 价值函数

价值函数基于奖励的期望评估智能体在某个状态下的价值或在某个状态下采取特定动作的价值。

状态价值函数 $V_\pi(s)$ 为从状态 s 开始,智能体基于策略 π 连续采取动作获得

的总奖励的期望：

$$\begin{aligned}
 V_{\pi}(s) &= E_{\pi}[R_t | s_t = s] \\
 &= E_{\pi}\left[\sum_{k=0}^K \gamma^k r_{t+k+1} | s_t = s\right] \\
 &= E_{\pi}\left[r(s' | s, a) + \gamma V_{\pi}(s') | s_t = s\right]
 \end{aligned} \tag{4-3}$$

通过蒙特卡洛方法，当智能体依据策略 π 选择动作时，记录每个新状态的奖励均值，该均值随状态增加将收敛至 $V_{\pi}(s)$ 。利用每个状态的价值之间的关系，状态价值函数可表示为：

$$V_{\pi}(s) = \sum_a \pi(a|s) \sum_{s'} p(s' | s, \pi(s)) [r(s' | s, \pi(s)) + \gamma V_{\pi}(s')] \tag{4-4}$$

式中， $\pi(a|s)$ 表示状态 s 下每种可能采取的动作对应的策略； $p(s' | s, \pi(s))$ 表示采用策略 π 使得状态从 s 变为 s' 的概率； $r(s' | s, \pi(s))$ 表示采用策略 π 使状态 s 变为 s' 的回报值。

动作价值函数 $Q_{\pi}(s, a)$ 为从状态 s 开始，依据策略 π 选择动作 a 的价值，即执行动作 a 之后所有可能的决策的总奖励期望：

$$\begin{aligned}
 Q_{\pi}(s, a) &= E_{\pi}\left[\sum_{k=0}^K \gamma^k r_{t+k+1} | s_t = s, a_t = a\right] \\
 &= E_{\pi}\left[r_{t+1} + \gamma Q(s', a) | s_t = s, a_t = a\right]
 \end{aligned} \tag{4-5}$$

通过寻找到的最优策略 π_* ，强化学习可做出最优决策。在该策略下所有状态的状态价值函数或动作价值函数最大，即 $\forall s \in S, a \in A$ ，有 $Q_{\pi_*}(s, a) \geq Q_{\pi}(s, a)$ 。考虑策略 π 下的状态转移概率，可得该策略下的动作价值函数称为最优动作价值函数的贝尔曼方程为：

$$\begin{aligned}
 Q_*(s, a) &= \max_{\pi} Q_{\pi}(s, a) \\
 &= E\left[r_{t+1} + \gamma \max_a Q_*(s', a) | s_t = s, a_t = a\right] \\
 &= \sum_{s', r} p(s' | s, a) [r + \gamma \max_a Q_*(s', a)]
 \end{aligned} \tag{4-6}$$

在求得价值函数之后，为了避免陷入局部最优解，利用 ε -贪心策略 (ε -greedy) 进行寻优，该方法以概率 ε 随机选择动作以探索全局最优策略，理论上强化学习通过 ε -贪心策略可以让训练收敛后的策略 π_* 达到全局最优。

4.2.2 深度 Q 网络

深度强化学习的主要特点是用神经网络的基于梯度下降的优化过程取代价值函数的最优贝尔曼方程的迭代过程，深度 Q 网络 (Deep Q Network, DQN) 是一种基于价值的深度强化学习方法^[87]。DQN 通过构造参数为 θ 动作价值神经网络 $\hat{Q}(s, a; \theta)$ 拟合估计如式 (4-6) 的动作价值函数，为了寻找对应最优策略的动作价值函数，通过最小化损失函数 $L_t(\theta_t)$ 不断调整参数来训练网络：

$$L_t(\theta_t) = E_{s,a} \left[(y_t - Q(s, a; \theta_t))^2 \right] \quad (4-7)$$

$$y_t = r + \gamma \max_a Q(s', a'; \theta'_t) \quad (4-8)$$

式中， i 为迭代次数； θ_i 代表神经网络的参数； y_i 为第 i 次迭代的目标值。

DQN 采用两个 Q 网络和经验回放机制来保证训练过程收敛。

(1) 两个 Q 网络

动作价值网络的参数更新依赖于 Q 值的实际值和预测值，为了网络训练收敛且能寻到全局最优，DQN 设置两个结构一样的神经网络来训练，分别是在线 Q 网络和目标 Q 网络。在线 Q 网络仅用于更新网络参数并输出 Q 值的估计值，而目标 Q 网络用于计算 Q 值的实际值，每隔一段时间基于在线 Q 网络的参数更新自身参数。所以，第 i 次迭代的目标值 y_i 通过目标 Q 网络提供的 $\max_a Q(s', a'; \theta'_i)$ 来计算，区别于在线 Q 网络的参数， θ'_i 为目标 Q 网络的参数。

(2) 经验回放机制

在训练前期，记忆集记忆每次智能体学习时接收的状态 s_i 和 s_{i+1} 、动作 a_i 、奖励 r_i ，训练时随机提取部分样本作为学习样本，该机制能够充分利用样本，提高算法的学习效率和稳定性。

由图 4-2 可以看出，在 DQN 的训练过程中，每一次迭代，将原状态、动作、奖励和新状态构成的序列 $d_i = (s, a, r, s')$ 存入记忆集 $D = \{d_1, d_2, \dots, d_i\}$ ，从中提取样作为训练样本。将状态输入在线 Q 网络，在线 Q 网络输出所有动作的 Q 值并基于贪心算法选择动作反馈给环境。

通过在线 Q 网络和目标 Q 网络的输出 Q 值，可以计算出损失函数，继而基于梯度下降的方法更新在线 Q 网络的参数。每隔 N 次迭代，将在线 Q 网络的参数传递给目标 Q 网络，从而更新目标 Q 网络的参数，即 $\theta'_i = \theta_i$ 。




图 4-2 DQN 训练过程

4.2.3 深度 Q 网络的改进

由前文所述可知，在 DQN 的目标值计算中，Q 值计算和动作选择通过同一目标 Q 网络进行，而由于紧急控制中同个控制点下的控制动作只有控制量的区别，可能使部分控制动作近似，动作空间中具有多个近似动作。这可能导致深度强化学习的决策因过度估计动作的 Q 值而不准确。为了避免这种情况，将动作选择与价值估计分为独立的两部分，形成双重 DQN（Double Deep Q Network，DDQN）。DDQN 不直接通过目标网络生成 Q 值，而是先通过在线网络计算最大 Q 值来选择动作，再从目标网络计算目标 Q 值。所以，这种结构下第 t 次迭代的目标值为：

$$y_t^{\text{DDQN}} = r + \gamma Q\left(s', \arg \max_a Q(s', a; \theta_t); \theta_t'\right) \quad (4-9)$$

动作的选择仍然取决于在线网络参数 θ_t ，但通过目标网络参数 θ_t' 更准确地估计该动作的 Q 值，通过这种方式减少了训练中因目标值和估计值相关性过高导致的冲突，同时在一定程度上保证了 Q 值不被高估。

在 DQN 中，神经网络提取环境状态信息的特征之后会通过全连接层输出该状态下各个动作的价值 $Q(s_t, a_t)$ ，考虑修改网络结构，在特征提取之后将网络分为两部分，一部分用于评估环境本身的价值，另一部分衡量每个动作相对于其他动作的优势，称为竞争 DQN（Dueling DQN），网络结构如图 4-3 所示。由此各个动作的价值为：

$$Q(s_t, a_t) = V(s_t) + A(s_t, a_t) \quad (4-10)$$

在 Dueling DQN 的结构下，Q 值分为状态价值 $V(s_t)$ 和动作优势 $A(s_t, a_t)$ ，使学习的目标更加明确，深度强化学习能够对状态的价值单独进行估计。当动作空间较大时，该方法相较于传统 DQN 的收敛速度快很多。此外，当动作空间中

具有多个近似动作，或一些动作对状态的影响很小时，该方法比传统 DQN 收敛速度更快。




图 4-3 竞争 DQN 结构图

本文将 DDQN 与 Dueling DQN 结合，构成同时具有上述两种改进方法优势的竞争双重 DQN 网络（Dueling Double DQN，D3QN），用于制定电力系统紧急控制策略。

4.3 基于 DGRL 的紧急控制决策方法及流程设计

4.3.1 控制流程

现代电力系统运行状态复杂，稳定性受诸多因素影响，系统的优化控制问题是多维非线性优化问题。深度强化学习能够提取环境状态的特征，做出合适的动作选择，具有较好的优化性能。此外，由于电力系统中电力电子设备的快速响应特性，当系统需要优化控制时，控制决策越快速，系统的稳定性能越能得到保障。深度强化学习将大量仿真和计算过程转移到离线阶段，在线应用时根据提前训练好的模型进行决策，决策时间很短。

紧急控制是电力系统优化控制问题中的一种，目的是通过采取合理的控制策略，保障系统的稳定性。采用深度强化学习方法进行电力系统紧急控制，可基于系统实时响应快速有效地制定控制策略，保证系统的安全运行。

本文提出的紧急控制决策流程如图 4-4 所示，为了适应电力系统的拓扑变化，采用第 2 章所述的 GraphSAGE 网络来提取电力系统环境信息，包括由电气量组成的状态和拓扑结构信息，与 D3QN 结合，构成基于 DGRL 的紧急控制策略模型。在离线阶段，将时域仿真获得的失稳样本数据作为输入，提取节点特征和拓扑结构特征，训练 D3QN 生成紧急控制策略。在线应用时，若需要采用紧急控制策略，利用实时监测获得的系统运行状态，提取需要的系统环境特征，使用训练

好的模型制定最优紧急控制策略。

DGRL 的具体训练过程如图 4-4 的左图所示。首先，设定训练集数、记忆集容量等参数，初始化各参数；然后，循环训练 DGRL，使用 ε -贪心算法选择动作，不断更新网络参数和策略，随着训练次数增加，逐渐降低探索概率，使智能体在训练后期能够以较大概率使用学习到的策略。当训练集数达到设定值时结束训练，并保存模型。




图 4-4 基于 DGRL 的紧急控制决策流程图

4.3.2 状态空间

对于电力系统的基于 DGRL 的紧急控制策略，状态空间的选取既要能够准确描述系统在不同运行方式下真实的环境信息，又不能对神经网络的训练造成太大计算负担。考虑特征提取采用的是图神经网络，本文将电力系统所有节点的电压幅值、电压相角、节点注入有功功率、节点注入无功功率和故障节点信息以及包含拓扑结构信息的邻接矩阵作为输入状态，并对使用的电气量进行归一化处理，如下式所示：

$$s = \{V, \theta, P, Q, F, A\} \tag{4-11}$$

式中， V 、 θ 、 P 、 Q 、 F 分别为所有节点的电压、相角、注入有功功率、注入无功功率和故障信息组成的向量，共同构成输入图神经网络的节点特征矩阵； A 为邻接矩阵。每次训练时，从样本数据中获取对应的状态 s 作为智能体的状态观

测量，为紧急控制决策提供依据。

4.3.3 动作空间

理论上，增大动作空间，可以使其包含的动作选择更完备，智能体更能找到最优控制动作，在大规模系统中动作空间会产生维数灾，导致模型难以找到最优解，所以一般不能简单地将动作空间设置为所有控制点的控制动作集合。

考虑实际系统中具体的发电机和负荷的重要性问题，选择部分发电机和负荷作为备选控制点，并且假设发电机母线连接若干相同的发电机，发电机只有切除或不切除的动作，假设负荷按照若干种比例切除。将切机切负荷动作编号，按选取的控制点由小到大，切机台数或切负荷比例由小到大的顺序将动作编号为从 1 开始递增的正整数。因此，智能体选择的动作 $a \in \Omega$ ，动作空间 $\Omega = \{1, 2, \dots, N_\Omega\}$ ，为离散实数集，其中 N_Ω 为切机切负荷动作总数。

4.3.4 奖励函数

奖励函数是否合适对深度强化学习的训练效率和控制效果都起到至关重要的作用。本文采用的模型中奖励函数需要能够被准确量化，并且必须来自于能够获取的环境信息。为了同时应对故障后系统可能发生的暂态功角失稳和暂态电压失稳的情况，本文设计奖励函数如式 (4-12) 所示：

$$r = \begin{cases} -1, & TSI \leq 0 \text{ 或 } TVSI = 1 \\ c_1 TSI + c_2 \left(1 - \sqrt{\frac{1}{n} \sum_{i=1}^n (V_i - V_{ref})^2} \right), & TSI > 0 \text{ 且 } TVSI = 0 \end{cases} \quad (4-12)$$

式中， n 为系统节点数， V_i 为节点 i 的电压， V_{ref} 为节点电压额定值， c_1 、 c_2 为权重系数； $TVSI \in \{0, 1\}$ 为暂态电压稳定实用判据的判断结果， $TVSI=1$ 表示暂态电压失稳，反之则为稳定。当执行控制动作后系统仍失稳，则奖励值为一个负数，代表该动作带来与期待相反的结果；当执行控制动作后系统稳定，则从两方面综合评估该动作：（1） TSI ，在该式中表示采取控制动作后系统的暂态稳定指数，由发电机功角差计算得到，反映暂态功角稳定性；（2）电压偏移指标

$\sqrt{\frac{1}{n} \sum_{i=1}^n (V_i - V_{ref})^2}$ ，由各节点电压计算得到，反映暂态电压稳定性。

4.4 基于 DGRL 的紧急控制策略框架

基于 DGRL 的电力系统紧急控制策略整体框架如图 4-5 所示。

第一步，离线训练时，基于系统时域仿真数据或历史运行数据，按照 2.3 节的方法进行暂态稳定评估模型的训练，保存训练好的模型。按照 4.3 节的方法训练智能体，根据训练样本更新 DGRL 的网络参数，直至达到设定的最大训练集数，保存模型。

第二步，在线应用时，在系统发生故障后，将实时观测得到的系统运行数据输入至训练好的暂态稳定评估模型中，并按照 3.2 节和 3.3 节的方法解释模型评估结果，供调度人员参考。若判定系统故障清除后保持稳定，则不启动智能体，继续观测运行数据直至下一次系统发生故障；若判定故障清除后系统失稳，则进入第三步。

第三步，启动智能体，利用训练好的 DGRL，提取输入的环境状态特征，快速地选出 Q 值最大的动作，制定出紧急控制策略，保证系统安全稳定运行。




图 4-5 电力系统紧急控制策略整体框架

4.5 算例分析


4.5.1 样本生成

本节同样采用前文使用的修改的 IEEE39 节点系统作为测试系统，系统负荷水平和故障设置相同，故障切除后 0.1s 采取控制措施。选取部分发电机节点和负荷节点作为备选控制点，可切发电厂编号为 33、34、35、36、38，可切负荷编号为 3、4、8、15、20、24、28，并且假设每个发电机节点连接 5 台完全相同的发电机，最多切除 4 台，负荷按比例等分为 5 份以供切除，最多切除 80%。将切机切负荷动作编号，按节点编号由小到大，发电机切机台数由小到大，负荷切除比例由小到大的顺序编号为 1-48、训练时，将动作编号转换为 Onehot 编码形式，以提高模型对该任务的学习能力。


设置图神经网络结构为 2 层，特征维度依次为 5-32-16，记忆集大小为 1000，采样集大小为 64，学习率为 0.001，折扣因子 γ 为 0.95。将贪心策略中的概率 ϵ 设为 0.5，随着训练进行而不断衰减，减少对环境的探索。奖励函数中的权重可结合不同指标的重要程度设置，本文分别设置 c_1 、 c_2 为 5、1.4。

4.5.2 紧急控制决策效果分析


基于上述设置，对基于 DGRL 的紧急控制策略模型进行训练，训练过程如图 4-6 所示。图 4-6 a)、图 4-6 b) 分别为训练过程中暂态功角稳定指标和电压偏移指标的变化，图 4-6 c) 为考虑功角稳定性和电压稳定性的奖励函数值，图中均以滑动平均值显示。



a) 暂态功角稳定指标



b) 电压偏移指标



c)奖励函数

图 4-6 模型训练过程

可以看出，在训练过程中，基于 DGRL 的智能体初始阶段的控制性能很差，随着训练次数、累计样本的增加，奖励值逐渐增大，智能体性能向好的方向发展，最终使奖励函数稳定在一个范围内。

随机抽取具体单个样本验证智能体的训练效果，获取的失稳场景为：线路无断开的拓扑下，负荷水平为 100%，16 号母线发生故障，故障持续 0.1s。考虑故障位置，选取母线 15、16、17 观察母线电压。无紧急控制的情况下，发电机功角曲线和母线电压曲线如图 4-7 所示。系统中的发电机分为三个机群，发电机 31、32、33、34、35、36 组成一群，发电机 30、37、38 组成一群以及发电机 39 为一群，故障后母线电压持续低于 0.75pu 的时间超过 1s，功角和电压处于失稳状态。紧急控制的决策结果为切除母线 34 上的 1 台发电机，紧急控制后的发电机功角曲线和母线电压曲线如图 4-8 所示。可以看出，发电机功角偏差趋于稳定，被抑制在较小范围内，母线电压也在故障后趋于稳定，验证了模型输出的紧急控制策略的有效性。




图 4-7 故障后系统功角、电压曲线




图 4-8 控制后系统功角、电压曲线

4.5.3 拓扑变化适应性分析

系统实际运行时的拓扑结构可能是智能体训练样本中不包含的,为了验证本文方法对拓扑变化的适应性,选择拓扑未被学习到的失稳样本进行测试。失稳场景为线路 4-5 断开的拓扑下,负荷水平为 100%, 22 号母线发生故障,故障持续 0.1s。选取母线 21、22、23 观察母线电压。无紧急控制的情况下,发电机功角曲线和母线电压曲线如图 4-9 所示,系统功角和电压均失稳。模型决策结果为切除 15 节点 40%的负荷。图 4-10 为采用模型决策结果后的系统发电机功角和母线电压。可以看出,按本文方法选择紧急控制策略后,系统恢复稳定,表明了本文方法在拓扑变化场景下具有较好的适应性。




图 4-9 故障后系统功角、电压曲线




图 4-10 控制后系统功角、电压曲线

4.6 本章小结

本章将深度强化学习引入电力系统紧急控制问题,提出了一种基于 DGRL 的紧急控制方法,并基于此构建了紧急控制策略框架,在修改的新英格兰 10 机 39 节点系统上进行验证,结论如下:

- (1) 对于故障后失稳系统,本文方法能够有效根据电力系统运行环境信息进行紧急控制决策,求取的紧急控制策略能够使系统恢复稳定运行,能有效实现在线应用时的快速准确控制。
- (2) 对于电力系统拓扑变化的场景,本文方法在一定程度上能够适应系统拓扑变化,具有一定的泛化能力,且决策结果具有正确性。

第 5 章 总结与展望

5.1 总结

随着间歇性能源的大规模并网、跨区域大电网互联,越来越多特高压交直流线路投运,电力系统拓扑变化频繁,且面临随机性高、动态复杂性高等挑战,其对电力系统的安全稳定运行带来了日益严峻的挑战。在此背景下,电力系统暂态稳定评估和紧急控制在保障电力系统安全性上意义重大,在采取的方法的适用范围和准确度等方面有更高的要求。机器学习方法为解决这些问题提供了方向,但其模型欠缺可解释性已成为此类方法开展工业应用的极大阻碍。本文针对电力系统暂态稳定分析与紧急控制方法进行了深入研究,所做的工作和主要研究成果总结如下:

(1) 提出了一种基于 GraphSAGE 网络的电力系统暂态稳定评估方法。该方法采用了多任务学习模式,能够学习电力系统暂态功角稳定和电压稳定之间隐含的关系,同时对功角稳定和电压稳定进行了评估。该方法考虑了电力系统中的母线特征和拓扑连接关系,得到的模型能够描述系统拓扑变化。算例分析表明,该方法具有较高的评估精度和速度,能有效学习电力系统拓扑结构特征,进而在新拓扑场景下表现出较好的泛化能力。

(2) 提出了基于 Grad-CAM 和 GNNExplainer 的暂态稳定评估模型解释方法。基于 Grad-CAM 的方法采用梯度计算,利用已训练好的模型进行解释,对模型结果主要受哪些母线影响给出解释。算例分析表明,该方法具有一定的可信性。基于 GNNExplainer 的方法利用特征扰动寻找重要线路和节点特征,进一步从线路和节点特征的角度对解释结果进行了拓展。算例分析表明,该方法能够反映拓扑变化对系统暂态稳定性的影响,同时对评估模型给出解释,提高了模型的透明度。

(3) 提出了一种基于 DGRL 的电力系统紧急控制方法。该方法能够分析电力系统运行环境信息,从中提取有效信息进行紧急控制决策,对于不同故障和运行方式的控制决策不需要调整模型,结合暂态稳定分析,构建了紧急控制策略框架。算例分析表明,该方法求取的紧急控制策略能够使系统恢复稳定,实现了系统运行信息到控制策略的直接映射,对于拓扑变化的场景具有较好的适应性。

5.2 展望

在上述工作的基础上，本文的研究仍存在问题，有以下研究工作值得进一步开展：

（1）本文仅在修改的 10 机 39 节点系统上验证方法的有效性，有必要基于实际交直流互联大电网进行测试，并考虑模型对实际系统的量测噪声、信号缺失的鲁棒性。

（2）利用无监督或半监督学习方法，对实际系统存在的大量无标签数据进行学习，充分挖掘电力系统大量数据的价值。面对不断更新的运行数据，可以将深度学习与迁移学习等技术结合，利用少量新数据提升模型在新场景下的性能。

（3）本文仅对样本个体的结果进行解释，有必要从全局角度解释母线、线路或输入特征的重要性，并结合基于物理模型的分析方法，进一步研究如何将解释结果更好地运用于工程实践。

（4）本文提出的紧急控制方法面对极其严重的故障时，可能会因备选控制措施不足找不到最优动作，无法使系统保持稳定。可以考虑控制动作序列或多种控制类型同时动作，深入研究紧急控制策略。

参考文献

- [1] 王华昕, 王杰, 赵永熹, 等. 双碳与新型电力系统背景下半波长可控调谐技术研究 [J/OL]. 电测与仪表: 1-11[2022-03-17]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20220222.1354.002.html>
- [2] 曾辉, 孙峰, 李铁, 等. 澳大利亚“9·28”大停电事故分析及对中国启示[J]. 电力系统自动化, 2017, 41(13): 1-6
- [3] 王平, 王尧. 台湾大停电的“锅”谁来背[J]. 两岸关系, 2017(09): 30
- [4] 易俊, 卜广全, 郭强, 等. 巴西“3·21”大停电事故分析及对中国电网的启示[J]. 电力系统自动化, 2019, 43(02): 1-6
- [5] 张玥, 谢光龙, 张全, 等. 美国得州 2·15 大停电事故分析及对中国电力发展的启示[J]. 中国电力, 2021, 54(04): 192-198+206
- [6] 韦肖燕. 电力系统暂态稳定紧急控制方法研究[D]. 湖南大学, 2018
- [7] Arel I., Rose D. C., Karnowski T. P.. Deep Machine Learning-A New Frontier in Artificial Intelligence Research[J]. IEEE Computational Intelligence Magazine, 2010,5(4):13-18
- [8] Bacciu D., Errica F., Micheli A., et al. A Gentle Introduction to Deep Learning for Graphs[J]. 2019
- [9] 林济铿, 李杨春, 罗萍萍, 等. 波形松弛法的电力系统暂态稳定性并行仿真计算[J]. 电工技术学报, 2006(12): 47-53+65
- [10] Jalili-Marandi V., Dinavahi V.. Instantaneous Relaxation-Based Real-Time Transient Stability Simulation[J]. IEEE Transactions on Power Systems, 2009,24(3):1327-1336
- [11] Zadhast S., Jatskevich J., Vaahedi E.. A Multi-Decomposition Approach for Accelerated Time-Domain Simulation of Transient Stability Problems[J]. IEEE Transactions on Power Systems, 2015,30(5):2301-2311
- [12] 苏福, 杨松浩, 王怀远, 等. 电力系统暂态稳定时域仿真快速终止算法研究[J]. 中国电机工程学报, 2017, 37(15): 4372-4378+4577
- [13] Magnusson, P. C. The Transient-Energy Method of Calculating Stability[J]. American Institute of Electrical Engineers Transactions of the, 1947,66(1):747-755
- [14] Aylett P. D.. The Energy-Integral Criterion of Transient Stability Limits of Power Systems[J]. Proceedings of the IEE-Part C: Monographs, 1958,105(8):527-536
- [15] Gless G. E.. Direct Method of Liapunov Applied to Transient Power System Stability[J]. IEEE Transactions on Power Apparatus and Systems, 2007,PAS-

- 85(2):159-168
- [16]El-Abiad A. H., Nagappan K.. Transient Stability Regions of Multimachine Power Systems[J]. Power Apparatus & Systems IEEE Transactions on, 2007,PAS-85(2):169-179
- [17]Athay, T., Podmore, et al. A Practical Method for the Direct Analysis of Transient Stability[J]. Power Apparatus and Systems, IEEE Transactions on, 1979,PAS-98(2):573-584
- [18]王锡凡. 现代电力系统分析[M]. 北京: 科学出版社, 2003
- [19]Kakimoto N., Ohsawa Y., Hayashi M.. Transient stability analysis of electric power systems via Lure-type Lyapunov function[J]. Parts I and II Trans IEE of Japan, 1978,98(5-6):566-604
- [20]Chiang H. D., Wu F. F., Varaiya P. P.. A BCU method for direct analysis of power system transient stability[J]. IEEE Transactions on Power Systems, 1994,9(3):1194-1208
- [21]Xue Y., Custem T. V., Extended equal area criterion justifications, generalizations, applications[J]. Power Systems IEEE Transactions on, 1989,4(1):44-52
- [22]Xue Y., Cutsem T. V.. A simple direct method for fast transient stability assessment of large power systems[J]. Power Systems IEEE Transactions on, 1988,3(2):400-412
- [23]倪以信, 姚良忠. 直接暂态稳定分析综合法[J]. 中国电机工程学报, 1992, 12(6): 63-68
- [24]Sobajic D. J., Pao Y. H.. Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems[J]. IEEE Power Engineering Review, 1989,9(2):55-55.
- [25]Zhu L., Chao L., Zhao Y. D., et al. Imbalance Learning Machine Based Power System Short-Term Voltage Stability Assessment[J]. IEEE Transactions on Industrial Informatics, 2017,PP(99):1-1
- [26]叶圣永, 王晓茹, 刘志刚, 等. 基于随机森林算法的电力系统暂态稳定性评估[J]. 西南交通大学学报, 2008, 43(5): 573-577.
- [27]王亚俊, 王波, 唐飞, 等. 基于响应轨迹和核心向量机的电力系统在线暂态稳定评估[J].中国电机工程学报,2014,34(19):3178-3186
- [28]田芳, 周孝信, 于之虹. 基于支持向量机综合分类模型和关键样本集的电力系统暂态稳定评估[J]. 电力系统保护与控制, 2017, 45(22): 1-8
- [29]周艳真, 吴俊勇, 冀鲁豫, 等. 基于两阶段支持向量机的电力系统暂态稳定预测及预防控制[J]. 中国电机工程学报, 2018, 38(01): 137-147+350
- [30]Xu Y., Dong Z. Y., Meng K., et al. Real-time transient stability assessment model using extreme learning machine[J]. IET Generation, Transmission & Distribution,

2011,5(3):314-322

- [31]陈振, 肖先勇, 李长松, 等. 基于代价敏感极端学习机的电力系统暂态稳定评估方法[J]. 电力自动化设备, 2016, 36(02): 118-123
- [32]戴仁昶, 张伯明. 基于人工神经网络的暂态稳定性分析[J]. 电力系统自动化, 2000, 24(12): 1-3
- [33]姚德全, 贾宏杰, 赵帅. 基于复合神经网络的电力系统暂态稳定评估和裕度预测[J]. 电力系统自动化, 2013, 37(20): 41-46
- [34]Hinton G. E., Osindero S., Teh Y. W.. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 2006,18(7):1527-1554
- [35]Hinton, G., E., et al. Reducing the Dimensionality of Data with Neural Networks[J]. Science, 2006,313(5786):504-507
- [36]汤奕, 崔晗, 李峰, 等. 人工智能在电力系统暂态问题中的应用综述[J]. 中国电机工程学报, 2019, 39(01): 2-13+315
- [37]杨维全, 朱元振, 刘玉田. 基于卷积神经网络的暂态电压稳定快速评估[J]. 电力系统自动化, 2019, 43(22): 46-51, 136
- [38]孙黎霞, 白景涛, 周照宇, 等. 基于双向长短期记忆网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2020, 44(13): 64-72
- [39]胡伟, 郑乐, 闵勇, 等. 基于深度学习的电力系统故障后暂态稳定评估研究[J]. 电网技术, 2017, 41(10): 3140-3146
- [40]尹雪燕, 闫炯程, 刘玉田, 等. 基于深度学习的暂态稳定评估与严重度分级[J]. 电力自动化设备, 2018, 38(5): 64-69
- [41]王铮澄, 周艳真, 郭庆来, 等. 考虑电力系统拓扑变化的消息传递图神经网络暂态稳定评估[J]. 中国电机工程学报, 2021, 41(07): 2341-2350
- [42]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(06): 2122-2130
- [43]孙黎霞, 彭嘉杰, 白景涛, 等. 结合图嵌入算法的电力系统多任务暂态稳定评估[J]. 电力系统自动化, 2022, 46(02): 83-91
- [44]陈明华, 刘群英, 张家枢, 等. 基于 XGBoost 的电力系统暂态稳定预测方法[J]. 电网技术, 2020, 44(03): 1026-1034
- [45]韩天森, 陈金富, 李银红, 等. 电力系统稳定评估机器学习可解释代理模型研究[J]. 中国电机工程学报, 2020, 40(13): 4122-4131
- [46]周挺, 杨军, 詹祥澎, 等. 一种数据驱动的暂态电压稳定评估方法及其可解释性研究[J]. 电网技术, 2021, 45(11): 4416-4425
- [47]Begovic M., Novosel D., Karlsson D., et al. Wide-Area Protection and Emergency Control[C]// IEEE. IEEE, 2005:876-891

- [48]Fang D. Z., Xiaodong Y., Jingqiang S., et al. An Optimal Generation Rescheduling Approach for Transient Stability Enhancement[J]. IEEE Transactions on Power Systems, 2007,22:386-394.
- [49]王彪, 方万良, 罗煦之. 紧急控制下最优切机切负荷方案的快速算法[J]. 电网技术, 2011, 35(06): 82-87
- [50]王云, 江全元. 基于 OpenMP 并行简约空间内点法的暂态稳定紧急控制[J]. 电力自动化设备, 2014, 34(12): 83-88
- [51]甘国晓, 耿光超, 仲悟之, 等. 电力系统暂态稳定紧急控制并行序贯优化算法[J]. 电力自动化设备, 2018, 38(08): 68-73
- [52]Tong J., Chiang H. D.. A sensitivity-based BCU method for fast derivation of stability limits in electric power systems[J]. IEEE Transactions on Power Systems, 1993, 8(4):1418-1428
- [53]Song H., Kezunovic M.. Stability control using PEBS method and analytical sensitivity of the transient energy margin[C]// Power Systems Conference & Exposition. IEEE, 2004
- [54]Shi Z., Xu Y, Wu X, et al. Coordinated Emergency Control Strategy for Transient Stability Enhancement of AC/DC Hybrid Power Systems Based on EEAC Theory[C]// 2018 IEEE 2nd International Electrical and Energy Conference (CIEEC). IEEE, 2018
- [55]吴为, 汤涌, 孙华东. 基于系统加速能量的切机控制措施量化研究[J]. 中国电机工程学报, 2014, 34(34): 6134-6140
- [56]任伟, 房大中, 陈家荣, 等. 大电网暂态稳定紧急控制下切机量快速估计算法[J]. 电网技术, 2008, 32(19): 10-15
- [57]彭疆南, 孙元章, 程林. 基于受扰轨迹的紧急控制新方法[J]. 电力系统自动化, 2002(21): 17-22
- [58]顾卓远, 汤涌, 张健, 等. 基于相对动能的电力系统暂态稳定实时紧急控制方案[J]. 中国电机工程学报, 2014, 34(07): 1095-1102
- [59]胡伟, 张玮灵, 闵勇, 等. 基于支持向量机的电力系统紧急控制实时决策方法[J]. 中国电机工程学报, 2017, 37(16): 4567-4576+4881
- [60]王彤, 刘九良, 朱劭璇, 等. 基于随机森林的电力系统暂态稳定评估与紧急控制策略[J]. 电网技术, 2020, 44(12): 4694-4701
- [61]杨少波, 刘道伟, 安军, 等. 基于长短期记忆网络的电网动态轨迹趋势预测方法[J]. 中国电机工程学报, 2020, 40(09): 2854-2866
- [62]刘威, 张东霞, 王新迎, 等. 基于深度强化学习的电网紧急控制策略研究[J]. 中国电机工程学报, 2018, 38(01): 109-119+347

- [63]强子玥. 基于深度学习的电力系统暂态失稳紧急控制策略[D]. 北京交通大学, 2021
- [64]Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks. In: Proc. of the 5th Int'l Conf. on Learning Representations. Toulon: OpenReview.net, 2017
- [65]Li RY, Wang S, Zhu FY, Huang JZ. Adaptive graph convolutional neural networks. In: Proc. 32nd AAAI Conf. on Artificial Intelligence, the 30th Innovative Applications of Artificial Intelligence, the 8th AAAI Symp. on Educational Advances in Artificial Intelligence. New Orleans: AAAI, 2018. 3546–3553
- [66]Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering. Proc. of the 30th Int'l Conf. on Neural Information Processing Systems. Barcelona: NIPS, 2016. 3844–3852
- [67]Levie R, Monti F, Bresson X, Bronstein MM. Cayleynets: Graph convolutional neural networks with complex rational spectral filters. IEEE Trans. on Signal Processing, 2019, 67(1): 97–109
- [68]Gilmer J, Schoenholz SS, Riley PF, Vinyals O, Dahl GE. Neural message passing for quantum chemistry. In: Proc. of the 34th Int'l Conf. on Machine Learning. Sydney: PMLR, 2017. 1263–1272.
- [69]Hamilton WL, Ying R, Leskovec J. Inductive representation learning on large graphs. In: Proc. of the 31st Int'l Conf. on Neural Information Processing Systems. Long Beach: NIPS, 2017. 1025–1035
- [70]Velickovic P, Cucurull G, Casanova A, Romero A, Liò P, Bengio Y. Graph attention networks. arXiv: 1710.10903, 2017
- [71]Li YJ, Vinyals O, Dyer C, Pascanu R, Battaglia P. Learning deep generative models of graphs. arXiv: 1803.03324, 2018
- [72]F. Scarselli, M. Gori, A. C. Tsoi, M. Hagenbuchner, and G. Monfardini, "The graph neural network model," IEEE Trans. Neural Netw., vol. 20, no. 1, pp. 61–80, Jan. 2009
- [73]Y. Li, D. Tarlow, M. Brockschmidt, and R. Zemel, "Gated graph sequence neural networks," in Proc. ICLR, 2015, pp. 1–20
- [74]S. Cao, W. Lu, and Q. Xu, "Deep neural networks for learning graph representations," in Proc. AAAI, 2016, pp. 1145–1152
- [75]S. Pan, R. Hu, G. Long, J. Jiang, L. Yao, and C. Zhang, "Adversarially regularized graph autoencoder for graph embedding," in Proc. IJCAI, Jul. 2018, pp. 2609–2615
- [76]J. You, R. Ying, X. Ren, W. L. Hamilton, and J. Leskovec, "GraphRNN: A deep generative model for graphs," in Proc. ICML, 2018, pp. 1–12
- [77]M. Simonovsky and N. Komodakis, "Graphvae: Towards generation of small

- graphs using variational autoencoders,” in Proc. ICANN. C h a m , Switzerland: Springer, 2018, pp. 412–422
- [78]Y . Seo, M. Defferrard, P. V andergheynst, and X. Bresson, “Structured sequence modeling with graph convolutional recurrent networks,” in Proc. NeurIPS. Springer, 2018, pp. 362–373
- [79]Z. Wu, S. Pan, G. Long, J. Jiang, and C. Zhang, “Graph WaveNet for deep spatial-temporal graph modeling,” in Proc. IJCAI, Aug. 2019, pp. 1–7
- [80]S. Guo, Y . Lin, N. Feng, C. Song, and H. Wan, “Attention based spatial-temporal graph convolutional networks for traffic flow forecasting,” in Proc. AAAI, 2019, pp. 922–929
- [81]Hamilton W L , Ying R , Leskovec J . Inductive Representation Learning on Large Graphs[J]. 2017
- [82]黎晓, 刘崇茹, 辛蜀骏, 等. 暂态功角稳定与暂态电压稳定的耦合机理分析与耦合强度评估指标[J]. 中国电机工程学报, 2021, 41(15): 5091-5107
- [83]国家能源局. 电力系统安全稳定计算技术规范: DL/T 1234—2013[S]. 北京: 中国电力出版社, 2013
- [84]Vinyals O, Bengio S, Kudlur M. Order matters: Sequence to sequence for sets[J]. Computer Science, 2015
- [85]R. R. Selvaraju, M. Cogswell, A. Das, R. V edantam, D. Parikh, and D. Batra. Grad-cam: Visual explanations from deep networks via gradient-based localization. In ICCV, pages 618–626, 2017. 1, 2, 5
- [86]Diederik P Kingma and Max Welling. Auto-encoding variational bayes. In NeurIPS, 2013
- [87]李茹杨, 彭慧民, 李仁刚, 等. 强化学习算法与应用综述[J]. 计算机系统应用, 2020, 29(12): 13-25

攻读硕士学位期间发表的论文及其它成果

（一）发表的学术论文

- [1] Qunqiao Wang, Chongru Liu, Hanxing Lin. AC Side Impedance Modeling Method of Multi-level Converter Considering Complete Control Structure. 2022 IEEE 5th International Electrical and Energy Conference (CIEEC), Nanjing, 2022, pp. 1-7. (EI 待检索)

（二）参与的项目

- [1] 国家电网有限公司科技项目：高比例新能源电力系统网架形态与演化技术研究。项目主研人。项目编号：SGXJJY00GHJS2000091

致 谢

时光荏苒，白驹过隙，转眼三年研究生生涯即将结束，回想起来，一路上虽遇到许多困难，走得磕磕绊绊，所幸坚持了下来，心里满是感慨。值此学位论文完成之际，衷心感谢三年来给予我支持与鼓励的老师、父母、同学和朋友们。

衷心感谢我的导师刘崇茹教授。刘老师思维敏捷、学识渊博，无论是在学术上还是生活中都给予了我极大的帮助和鼓励，从选题、开题、中期直至成稿的各个环节都离不开老师的指导。刘老师严谨的治学态度、豁达的胸怀是我一生学习的榜样，三年时光里的言传身教将继续指引我在未来的人生路上前进。衷心感谢郑乐老师对我的耐心指导。郑老师对我的学位论文研究内容进行了详细的指导，及时指出我的不足之处，帮助我开启新的思路，科研素养令我钦佩。老师认真的处事风格、亲善的为人态度值得我学习。谆谆教诲，涓涓师恩，铭记于心。愿二位老师身体健康，工作顺利。

感谢我的父母对我的支持和鼓励。二十余载，父母在生活、学习等各方面给予我最大限度的支持。当我压力很大时，你们都能表现出理解，给予我安慰。如今求学生涯将要结束，深感寸心难报三春晖，唯有长进以待父母，愿你们头发白得慢一些，天天开心，身体健康。

感谢帮助过我的所有同学和朋友们。感谢黎晓师兄帮助我确定了论文研究思路，进行了细心的指导，我论文的顺利完成离不开师兄的帮助。感谢杜容天、姚丛霄、全义三位室友一直以来的陪伴，我不会忘记我们一起谈理想、聊未来的时光，和你们一起生活是我的幸运。感谢王群乔、牛纪伟、姜苑、蒋思雯、李竹青五位同门，三年同窗，苦乐与共，互帮互助，感谢你们对我的关怀，和你们一起锻炼身体、放松心情的日子十分珍贵。此去经年，前途似海，来日方长，愿我们都能保持热爱，万事顺意。

最后，感谢华北电力大学为我提供了优秀的学习环境和科研平台。七年的华电求学时光刻苦铭心。祝愿华北电力大学越来越好。