

分类号_____

密级_____

U D C_____

编号_____

清 华 大 学

博 士 后 研 究 工 作 报 告

基于人工智能的新型电力系统状态评估与运行优化

郭 盛

工作完成日期 2020年9月—2022年9月

报告提交日期 2022年9月

清 华 大 学 （北京）

2022年9月

基于人工智能的新型电力系统状态评估与运行优化

STATE ASSESSMENT AND OPERATION OPTIMIZATION FOR NEW POWER SYSTEM BASED ON ARTIFICIAL INTELLIGENCE

博 士 后 姓 名： 郭 盛

流动站（一级学科）名称： 控制科学与工程

专 业（二级学科）名称： 控制理论与控制工程

合 作 导 师： 吉吟东 教授

研究工作起始时间 2020年9月30日

研究工作期满时间 2022年9月30日

清华大学自动化系（北京）

2022年9月

内 容 摘 要

新型电力系统以其对分布式发电的良好消纳能力成为了能源电力系统的发展方向，同时，新型电力系统的信息化和智能化为其运行优化提供了基础。本文基于人工智能算法，对新型电力系统的状态评估、故障诊断及优化控制开展研究，主要内容如下：

(1) 综合利用新型电力系统中的 SCADA 系统和 PMU 系统采集到的多源异构监测数据，考虑电力系统拓扑结构等领域知识，提出了一种基于图卷积神经网络和异构数据融合的新型电力系统状态估计方法。该方法利用相邻矩阵表示的电力系统拓扑，通过 GCN 中的图卷积运算提取并融合每个电力系统节点及其相邻节点的多源异构监测数据，并构造多任务输出获得所有节点的实时状态，实现了在故障和扰动情况下，新型电力系统高精度的暂态状态估计。

(2) 基于 PMU 监测数据和新型电力系统拓扑，将 GCN 引入电力系统故障诊断领域，并考虑新型电力系统的领域知识对其进行了改进，提出了一种基于改进 GCN 的新型电力系统故障诊断方法。该方法构造卷积神经网络模块提取各节点 PMU 的暂态监测数据，并结合 GCN 对电力系统拓扑的表示，对每个节点及其相邻节点的 PMU 数据中的故障特征进行提取。进而通过构造以电力系统线路特征为输入的多任务分类模块，实现了新型电力系统准确的故障线路的检测、识别和定位。同时，针对新型电力系统中的发电设备故障，提出了一种基于卷积神经网络和异构信息融合的风电机组故障诊断方法。该方法结合故障机理知识，构造了风电传动链系统领域知识图，并结合改进的多任务卷积神经网络，实现了部件级的风电机组传动链系统的准确故障诊断和定位。

(3) 在状态评估和故障诊断的基础上，为保持新型电力系统故障及扰动情况下的系统问题，基于多主体深度强化学习方法，提出了一种分布式协同控制的无功补偿优化框架。该方法引入图注意力网络，利用动态邻接矩阵表示故障后的新型电力系统拓扑，并根据现场实际的数据采集情况，基于异构的 SCADA 和 PMU 数据，融合并提取每个电力系统节点及其相邻节点的监测数据中的特征。最终使用深度强化学习方法使每个无功补偿节点的控制协同得到了最优的无功补偿控制效果。

(4) 为实现新型电力系统运行过程中的能效最优，开发了一套电力系统潮

流仿真系统，并在此基础上进行电力系统能效优化研究。首先，为优化新型电力系统中的能量传输过程，提出了一种基于图神经网络和深度强化学习的能量路由器能量传输路径优化算法，实现了考虑碳排放因素的情况下，新型电力系统中最优供电节点和能量传输路径的选择。其次，针对包含再生制动装置的轨道交通系统场景，提出了一种基于序优化和果蝇算法的轨道交通交直流供电系统的能效优化算法，通过对储能和逆变回馈装置开启电压的优选，实现了列车全天运行过程中的轨道交通系统能效最优。

关键词：新型电力系统，人工智能，图神经网络，异构数据，强化学习

Abstract

New power system has become the development direction of energy power system because of its good ability to absorb distributed power generations. Meanwhile, the informatization and intelligence of the new power system provide the basis for its operation optimization. Based on artificial intelligence algorithms, this paper studies the state evaluation, fault diagnosis and optimal control of the new power system. The main contents are as follows:

(1) Based on graph convolution neural network and heterogeneous data fusion, a new power system state estimation method is proposed by comprehensively utilizing the multi-source monitoring data collected by supervisory control and data acquisition (SCADA) system and phasor measurement unit (PMU). Considering the domain knowledge of power system topology, the proposed method uses the adjacent matrix to represent the power system topology. The multi-source heterogeneous monitoring data of each power system node and its adjacent nodes are extracted and fused by the graph convolution operation in graph convolutional networks (GCN). Finally, a multi-task output is constructed to obtain the real-time state of all nodes and realizes the high-precision transient state estimation of the new power system in the case of faults and disturbances.

(2) Based on the PMU data and the new power system topology, GCN is introduced into the field of power system fault diagnosis. Considering the domain knowledge of the new power system, a fault diagnosis method based on the improved GCN is proposed. A convolutional neural network module is constructed to extract PMU data of each node during the transient process. Then GCN is used to combine the power system topology and the PMU data of adjacent nodes to extract the fault features. Finally, by constructing a multi-task classification module based on the characteristics of power system lines, the accurate fault detection, identification and location of the new power system lines are realized. Moreover, a novel fault diagnosis method based on convolutional neural network and heterogeneous information fusion is proposed for wind turbine in the new power system. This method uses the knowledge of fault mechanism to construct the domain knowledge map of the wind turbine drive chain system. Then, combined with the improved multitask convolutional neural network, the accurate fault diagnosis and location of wind turbine drive chain system in the component level are realized.

(3) On the basis of state evaluation and fault diagnosis, to maintain the safety and

stability of the new power system under faults and disturbances, a distributed cooperative reactive power compensation optimization framework is proposed based on multi-agent deep reinforcement learning (DRL) method. This method introduces graph attention networks to represent the dynamic adjacency matrix of the new power system topology after faults. Then according to the actual data collection situation on the site, based on the heterogeneous SCADA and PMU data, the features in the monitoring data of each power system node and its adjacent nodes are fused and extracted. Finally, the multi-agent DRL method is used to make the controllers of each reactive power compensation nodes cooperate to obtain the optimal reactive power compensation control effect.

(4) Finally, to realize the energy efficiency optimization in the operation of new power system, a power system power flow simulation system is developed. On this basis, the energy efficiency optimization method of new power system is studied. Firstly, in order to optimize the energy transmission process in the new power system, an energy router energy routing optimization algorithm based on GCN and DRL is proposed, which realizes the selection of the optimal power supply node and energy transmission path in the new power system considering the carbon emission. Secondly, for the subway system scenario including regenerative braking devices, an energy efficiency optimization algorithm for the subway AC/DC power supply system is proposed based on sequence optimization and fruit fly optimization algorithm. By optimizing the opening voltages of energy storage and inverter energy feeding devices, the energy efficiency optimization of the subway system during the whole day operation of trains is realized.

Keywords: New power system, Artificial intelligence, Graph convolutional networks, Heterogeneous data, Reinforcement learning.

目 录

1. 绪论.....	1
1.1 研究背景及意义	1
1.2 人工智能算法在电力系统中的应用.....	2
1.3.1 电力系统状态评估及诊断	2
1.3.2 电力系统稳定性控制	3
1.3.3 电力系统能量管理及传输优化	4
1.3 本文内容概述	5
2. 基于图卷积神经网络的新型电力系统暂态状态估计	7
2.1 引言.....	7
2.2 图卷积神经网络	8
2.3 基于图卷积神经网络的新型电力系统状态估计方法	9
2.3.1 状态估计方法流程	9
2.3.2 用于新型电力系统状态估计的 GCN.....	11
2.4 仿真实验及结果分析	12
2.4.1 新型电力系统暂态仿真	12
2.4.2 参数设置及离线训练	13
2.4.3 结果分析	14
2.5 本章小结	15
3. 基于深度学习的新型电力系统诊断.....	16
3.1 引言.....	16
3.2 基于改进图卷积神经网络的电力传输线路故障诊断方法	16
3.2.1 改进的图卷积神经网络	18
3.2.2 新型电力系统故障检测、识别及定位方法	19
3.2.3 超参选择及训练策略	21
3.2.4 仿真实验及结果分析	23
3.3 基于卷积神经网络和异构信息融合的风电机组故障诊断方法.....	30
3.3.1 齿轮箱耦合故障诊断方法	31
3.3.2 齿轮箱综合状态信息矩阵构造	32
3.3.3 基于强化输入的多任务平行卷积神经网络	36
3.3.4 诊断实验及结果分析	38

3.4 本章小结	40
4. 基于强化学习的新型电力系统电压稳定控制	41
4.1 引言	41
4.2 基于多主体强化学习的无功补偿协同控制方法	42
4.3 无功协调优化的多主体深度强化学习框架	44
4.3.1 基于 GRU 和 GAT 的新型电力系统状态感知	45
4.3.2 多主体深度强化学习框架	48
4.3.3 无功补偿框架训练策略	49
4.4 仿真实验及结果分析	50
4.4.1 新型电力系统仿真	50
4.4.2 参数设置及离线训练	51
4.4.3 实验结果分析	53
4.4.4 消融实验	54
4.5 本章小结	55
5. 新型电力系统综合能效优化	56
5.1 引言	56
5.2 新型电力系统能效仿真	56
5.2.1 交流供电系统建模	56
5.2.2 三相潮流仿真建模	57
5.2.3 交流模型的建立及计算流程	59
5.2.4 交流系统稳态计算程序验证	60
5.3 新型电力系统能量传输优化	61
5.3.1 能量传输优化问题描述	62
5.3.2 基于图卷积神经网络的多任务强化学习算法	64
5.3.3 仿真实验及结果分析	69
5.4 新型轨道交通供电系统综合能效优化	75
5.4.1 储能及逆变能馈协同优化控制	76
5.4.2 优化问题描述	77
5.4.3 基于序优化和果蝇算法的储能及能馈装置协同优化方法	77
5.4.4 仿真优化实验及结果分析	79
5.5 本章小结	82
6. 总结与展望	83

6.1 论文工作总结	83
6.2 研究工作展望	84
参考文献.....	85
致 谢.....	96
项目及研究成果	97

1. 绪论

1.1 研究背景及意义

近些年来，全球范围内气候变暖日益加速，极端天气频发。为面对气候危机，许多国家提出了碳减排的目标，我国也承诺碳排放 2030 年前达到峰值，2060 年前实现碳中和。在此背景下，智能电网、能源互联网、分布式发电等关注新能源发电及消纳的技术发展迅速，并逐步形成了新型电力系统。新型电力系统以智能电网技术为基础，高比例新能源接入是其基本特征。同时，源网荷储在新型电力系统中实现互动与多能互补，具有清洁低碳、安全可控、灵活高效、智能友好、开放互动等，是实现碳达峰碳中和的必经之路^[1]。在新型电力系统架构中，随着可再生能源渗透率的不断提升、电力电子设备的广泛应用，未来电力系统容纳的电源与负荷种类将不断攀升，火电等高惯性发电设备比例逐步减少，这使得运行与控制的复杂度也将急剧升高^[2]。

与此同时，信息化和智能化是新型电力系统最主要的特征，也是实现新能源消纳、能源安全的重要途径。在新型电力系统中，丰富的信息采集及监测手段被广泛应用，如：同步相量测量装置、SCADA 系统、视频图像和振动温度等，也为现场积累了大量的数据。但目前对新型电力系统大量监测数据的应用已经在逐步开展，在用户负载及发电量预测、基于图像的异常物体检测等领域已经取得了一定成效^[4]^[5]。

然而，在新型电力系统的在线运行过程的监测诊断及运行优化方面，人工智能算法的应用还十分有限^[6]，其原因主要有以下几点：首先，人工智能算法的训练需要大量的历史数据，而现场更多获取到的是正常运行的数据，对算法训练的帮助有限。其次，由于缺少结合场景领域知识点特殊设计，现有人工智能方法训练获得的大多是黑箱模型，鲁棒性不强，而且其输出有一定的不确定性，所以考虑到电力系统的安全稳定性的要求，很少有算法能够真正在现场部署。再次，人工智能算法的现场部署存在着数据采集困难、算法分布式部署的问题，在现有的人工智能算法的设计中没有充分考虑。

由此可见，为了扩展人工智能算法在新型电力系统中的有效应用，急需考虑更多电力系统领域知识和专家经验，来指导人工智能算法的构建与部署，提升人工智能算法的通用性及鲁棒性，进而保障新型电力系统稳定和高效的运行。

1.2 人工智能算法在电力系统中的应用

近些年来，人工智能技术发展迅速，获得了能源电力领域许多专家学者的关注。凭借着人工智能算法对数据的强大特征提取能力，减轻了工业领域监测及控制方法对领域专家的依赖，有助于端对端的任务目标的实现。本节将对人工智能算法在电力系统状态评估及诊断、电能质量优化控制和综合能量管理等方面的现有研究进行介绍。

1.3.1 电力系统状态评估及诊断

新型电力系统中，分布式能源的广泛接入会影响新型电力系统电能质量及稳定性，这使得准确的实时状态估计成为确保新型电力系统安全稳定运行的一个重要问题。在实际电力系统中，实时监测数据通常来自监控数据采集（Supervisory Control And Data Acquisition, SCADA）系统，包括有功功率、无功功率、电压幅值等。近年来，同步相量测量装置（Phasor Measurement Unit, PMU）的发展提供了更准确实时的电力系统监测。基于人工智能算法和监测数据，学者提出了一些数据驱动的新型电力系统状态评估方法^[7]。文献[8]提出了一种基于人工神经网络的电力系统动态状态估计技术，基于 PMU 的电压和电流相量数据的，实现了发电厂中转子角度的动态估计。文献[9]提出了一种基于广义最大似然库普曼算子的卡尔曼滤波器来估计同步发电机的转子角和转速，进而获得了暂态过程中发电机终端的有功和无功功率。臧海洋等^[10]提出了一种基于深度迁移学习的电力系统状态估计方法，用以解决电力系统拓扑实时变化后的状态估计模型产生偏差的问题。穆强^[11]提出了一种基于迁移学习卷积神经网络的主动配电网分布式状态估计方法，解决了光伏、风电等新能源发电出力的高度不确定性对状态评估结果的影响。王泽等^[12]针对电力系统状态估计中量测数据存在的噪声、估计精度和时效性问题，提出了一种基于卷积神经网络（Convolutional Neural Networks, CNN）、长短期记忆神经与内核岭回归的电力系统鲁棒状态评估方法。刘晓莉等^[13]融合 PMU 和远程终端单元的监测数据，基于粒子滤波和卷积神经网络，提出了包括离线学习和在线状态估计的电网状态估计方法。

新型电力系统由于分布式发电的大量接入，线路及设备故障时有发生，同时由于新型电力系统拓扑结构的复杂多变，局部故障如果没有得到及时准确的处理，可能会引起大规模的停电事故。基于人工智能算法，学者们已经提出了一些基于机器学习的智能方法。如极值梯度提升（eXtreme Gradient Boosting, XGBoost）^[14]、人工神经网络^[15]等。深度学习作为机器学习的一种高级形式，由于具有强大的特征提取能力，已成功应用于电力系统故障诊断领域。黄梓晴^[16]使用 SCADA 系统监控

信息，建立了基于多种群遗传算法电网故障诊断模型，实现了单一性故障、保护断路器不正确动作及多重继发性故障等不同的故障状态的识别。肖玮^[17]利用深度学习在特征提取和非线性表达方面的优势，构建了基于卷积神经网络的故障诊断模型同时实现了对电力线路故障特征的提取和故障的诊断。Chen 等^[18]将卷积层和堆叠式自动编码器结合起来，用于线路的故障检测和分类。James 等^[19]融合了离散小波变换提取的特征和选通递归单元，用于微电网的智能故障识别和定位。在分布式发电及储能设备的诊断方面，徐先峰^[20]等基于半监督学习和极端随机树，实现了少量故障数据标签情况下光伏阵列故障诊断及定位。田佳强^[21]结合电池退化知识，建立了基于粒子滤波和模糊聚类的储能电池系统健康度评估和故障诊断模型。文献[22]考虑到风电机组齿轮箱振动信号的多尺度特性，提出了一种基于多尺度卷积神经网络的风电机组传动链故障诊断方法。

1.3.2 电力系统稳定性控制

在新型电力系统中，设备的种类越来越复杂多样，非线性荷载比重逐步增大，这使得供电的连贯性和稳定性愈发重要。同时可再生能源的随机性与波动性对其大规模并入电网并将其高效利用达到供需平衡带来很大困难，这使得稳定性问题成为了新型电力系统研究的重要方面。

基于人工智能中，学者们进行了电力系统稳定性控制方面的研究。文献[23]使用粒子群优化算法进行电压/无功协调优化，以确保具有分布式发电的配电系统的稳定性和能效最优。李凯强^[24]基于蜂拥算法和多智能体模型，设计了分布式控制器，保障了智能电网的稳定运行。朱泓宇^[25]提出了一种基于卷积神经网络的电力系统扰动后频率稳定紧急控制策略，该方法以电力系统遭受扰动前后的运行状态数据作为卷积神经网络的输入，可以快速而准确地预测出扰动后电网所需的直流紧急功率支援量和切负荷量。田芳等^[26]提出了一种基于卷积神经网络的电力系统暂态稳定预防控制方法，该方法通过卷积神经网络输出变量灵敏度选择控制发电机并确定控制量，然后结合时域仿真进行控制方案的暂态稳定性评估。

近年来，强化学习算法成为了各工业领域的研究热点，其可将对环境的观测数据作为网络输入，并以获得最优的控制效果为目标，通过在环境中尝试不同的策略进行学习和更新^[27]。基于强化学习方法，Cao 等^[28]提出了一种基于深度 Q 学习的新型电力系统无功补偿优化方法，该方法将能源互联网全网络中各节点的数据、不同 SVG 无功补偿量分别作为状态与动作，将稳定性判断与补偿量作为奖励值函数设置的依据，训练获得最高奖励值的无功补偿策略。李柏埝等^[29]提出一种基于柔性 Actor-Critic 深度强化学习算法的双智能体发电机调整方法，通过同时进行有功

功率和电压的调整,保证了电力系统的静态安全性。莫逆垒^[30]建立了考虑不确定性的微电网频率动态系统的连续时间动力学方程,并基于在线强化学习算法实现了微电网动力学系统的最优二次频率控制。夏岩^[31]基于 Q 学习算法实现了次级控制器的设计及训练,以保证孤岛微电网系统的电压和频率稳定在额定值。

1.3.3 电力系统能量管理及传输优化

由于可再生能源和包含电动汽车、分布式储能设备在内的大量柔性负载的接入,新型电力系统中多类发电及用能方式之间的耦合关系给新型电力系统的综合能量管理带来了挑战,同时,电力交易的逐步开展也为园区及企业的用能优化提供了机遇。新型电力系统不确定性和强耦合性也使传统优化算法的构造及求解十分困难,因此,基于人工智能中强化学习算法的综合能量管理成为了研究热点^[32]。

在新型电力系统中,储能设备可以实现削峰填谷的供能,进而降低电网负荷和用电成本^[33]。针对储能设备的管理控制,文献[34]使用强化学习中的 DDPG 算法实现了储能管理系统的充放电状态的控制,并考虑了对电网的频率响应。文献[35]基于 Double Q Learning 算法,考虑实时电价和煤炭价格的实时波动,获得了并网情况下微电网中的储能系统的最优价格策略。文献[36]提出了一种基于 DQN 的微电网集群能源和储备调度方法,通过共享能源和储能设备来提高微电网集群的整体经济效益。

电动汽车、变频空调、太阳能光伏板等家庭智能用电设备的普及,使得家庭能源管理的需求不断增加^{[37][38]}。文献[39]将负载分为常开负载、可开关负载和可灵活调节负载,并用双向长短期记忆网络预测电力和能源价格,在此基础上用 Q 学习算法进行优化,实现了能耗减少和成本降低。文献[40]提出了一种基于置信域策略梯度的家用电器高效需求响应算法,该方法不依赖模型,并且通过同一个策略网络输出不同概率分布的参数,基于不同的概率分布进一步采样得到不同类型设备优化后的离散动作或连续动作。文献[41]基于确定性策略梯度法,根据实时电价在线优化用电设备的动作,实现了家庭用电总花费最小,同时不影响用户的舒适度。

在典型的新型电力系统场景中,能量路由器被提出并逐步投入使用^[42]。能量路由器连接各种发电设备、负载和储能设备,并管理这些设备之间的能量流和信息流,从而获得更好的能量转换和传输效率^[43]。由于电能可以在区域新型电力系统中从端到端双向灵活流动^[44],复杂的系统网络拓扑直接导致不同能量传输路径的不确定性。如果能合理优化能量传输路径,则能以较少的线路损耗传输能量,进而有助于节能减排。目前,已有大量与能量路由器相关的理论研究成果和工程示范项目。例如,在文献[45]中,能量路由器与电动汽车一起部署在新型电力系统中; Miao

等^[46]建立了能量路由嵌入式系统网络的稳态潮流模型和相应的潮流优化；在文献[47]中，通过适当的控制策略和能量路由协议，实现了通过互连能量路由器的集中式最优能量调度。

综上所述，人工智能算法已经在新型电力系统的多种场景下得到了应用。但是目前这些应用普遍存在着对领域知识考虑不足的问题，这导致了人工智能方法在实际新型电力系统中的落地引用十分有限^[48]，主要原因总结如下：

首先，在基于人工智能方法进行新型电力系统故障诊断时，设备故障机理和故障特征等专家知识遭到了弃用，数据训练得到的人工智能模型成为了完全的黑箱模型，导致了模型的可解释性不强。

然后，由于模型训练数据和现场测量数据存在着特征分布上的差异，使得人工智能模型的鲁棒性和泛化能力不足^[49]。同时，新型电力系统的拓扑结构、设备参数和运行机理很难被用于人工智能模型结构和输入的构建，难以给出强解释性的控制策略，这也使得人工智能在实际控制系统中的应用比较有限^[50]。

另一方面，大多数算法基于历史数据，而现场部署存在着数据采集困难、算法分布式部署的问题，在现有的人工智能算法的设计中没有充分考虑。在这些因素的影响下，虽然有大量文章和方法被提出，但除了计算机视觉方面，很少有其他人智能算法在新型电力系统中得到真正的在线应用，这也是目前人工智能在大部分工业领域所面临的困境。

因此，如何将人工智能算法更好地和新型电力系统领域知识相结合，利用电力领域多年积累专家经验，实现“知识-数据”双驱动的新型电力系统状态评估及运行优化，是目前该领域的研究热点和发展趋势。

1.3 本文内容概述

为了解决人工智能算法在新型电力系统应用中存在的问题，提高人工智能算法在实际应用过程中的准确性及鲁棒性，进而保障具有广泛分布式发电储能设备接入的新型电力系统运行过程中的稳定和高效，本文充分考虑了能源电力系统的领域知识，提出了一系列的新型电力系统状态评估、诊断、稳定控制及能量管理方法。本文的研究路线及主要内容如下所示。

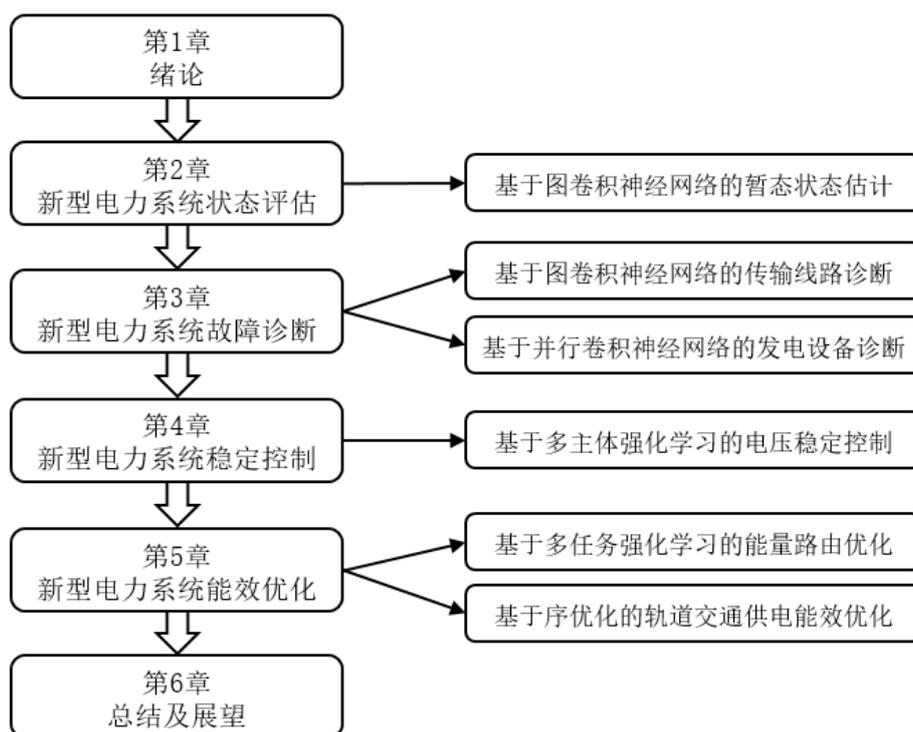


图 1-1 本文研究路线

第 1 章首先阐述了本文的研究背景及意义，随后对现有的人工智能算法在新型电力系统中的应用进行了综述。

第 2 章介绍了现有新型电力系统中的数据采集情况，并结合异构的 SCADA 和 PMU 数据，提出了一种基于图卷积神经网络的新型电力系统暂态状态评估方法。

第 3 章在新型电力系统状态评估的基础上，使用各电力系统节点的 PMU 数据，提出了一种基于改进图卷积神经网络的电力系统传输线路故障检测、识别及定位方法；进而对分布式发电设备风电机组的主传动链系统，提出了一种多部件耦合故障的诊断方法，以及时发现新型电力系统中各类设备的运行故障。

第 4 章针对新型电力系统中故障或扰动引发的电压暂降情况，考虑现场数据采集及控制器的布置，提出了一种基于异构数据融合和多主体强化学习的新颖电力系统电压稳定性控制方法，以保障新型电力系统的稳定运行。

第 5 章在前面章节新型电力系统状态评估及安全保障的基础上，进行了新型电力系统综合能效仿真，并提出了新型电力系统能量传输和系统运行过程中的能效优化方法，实现了在可再生能源最优利用的情况下，新型电力系统的运行能效最优。

第 6 章对全文主要研究内容进行了总结，并对下一步研究进行了展望。

2. 基于图卷积神经网络的新型电力系统暂态状态估计

2.1 引言

近年来,得益于对分布式能源的吸收和实现有效的能源管理,新型电力系统的研究发展迅速。但分布式能源的增加会影响新型电力系统电能质量及稳定性,这使得准确的实时状态估计成为确保新型电力系统安全稳定运行的一个重要问题。在实际电力系统中,实时监测数据通常来自 SCADA 系统,包括有功功率、无功功率、电压幅值等,数据采集间隔为秒级,其数据的实时性较差,无法准确地反映故障和干扰期间电力系统的暂态变化过程。

随着 PMU 的出现和发展,电力系统中的实时波形基于利用 GPS 同步实现实时准确地测量。PMU 传输数据速度快,并配有相位角测量装置,以确保数据采集的实时同步^[51],辅助实现快速的电力系统事件检测^[52]和故障诊断^[53]。然而,与 SCADA 相比,PMU 成本高且维护困难,虽然 micro-PMU 等技术也发展迅速,但仍难以保证在每条母线上安装 PMU 测量装置^[54]。因此,将来自有限节点的 PMU 数据和 SCADA 数据融合以进行电力系统状态评估是近年来一个主要研究热点。

近年来,随着人工智能技术的快速发展,人工智能算法已被应用于电力系统的状态评估领域。然而,现有方法仅将监测数据作为人工智能输入的方法完全是数据驱动的,并没有考虑到作为关键电力领域知识的电网拓扑结构,这导致人工智能方法的鲁棒性较差,尤其是在新型电力系统具有大量的可再生能源接入的情况下。电网拓扑结构可以指示母线、发电设备及负载之间的连接关系,决定了电网中功率的流向,有助于更准确的电力系统状态估计。

考虑到电网拓扑结构,新型电力系统的监测数据可以视为具有图结构的数据。受到卷积神经网络(CNN)应用于具有图结构的数据的启发,通过定义图^[55]上具有邻接矩阵的卷积运算,学者们提出了图卷积网络(Graph Convolutional Networks, GCN),并已将其成功地应用于许多领域,如互联网流量预测^[56]和虚拟网络嵌入^[57]等。因此,为了充分利用新型电力系统的多源监测数据和领域知识,本文将 GCN 引入到新型电力系统瞬态过程的状态估计中,并提出了一种基于 GCN 的 SCADA 和 PMU 数据融合的新型电力系统状态估计方法。该方法利用相邻矩阵表示的电力系统拓扑,通过 GCN 中的图卷积运算提取并融合每个电力系统节点及其相邻节点的多源监测数据,进而通过 GCN 的多任务输出获得所有节点的实时状态,实现了新型电力系统发生故障和扰动情况下快速和高精度的暂态状态估计。

2.2 图卷积神经网络

近年来, CNN 已成功应用于许多领域, 因为它对矩阵形式的数据具有强大的特征提取能力^{[58][59]}。然而, 具有图结构的系统在我们的日常生活中更为常见, 如互联网、社交网络和电网, 其拓扑结构对这些系统的特征提取和状态估计具有重要意义。为了对具有图结构的数据应用卷积运算, 文献^[60]提出了图卷积神经网络 (GCN), 并基于图的邻接矩阵推导处理图卷积运算。考虑一个具有 N 个节点 $v_i \in \mathcal{V}$ 、 K 个边 $(v_i, v_j) \in \mathcal{E}$ 的无向图 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$, 构造邻接矩阵 $A \in \mathbb{R}^{N \times N}$ 来表示图的拓扑结构, 构造度矩阵 $D_{ii} = \sum_j A_{i,j}$ 来表示节点的度。然后通过组合 A 和 D 得到图的归一化普拉斯矩阵 L :

$$L = D^{-\frac{1}{2}}(D - A)D^{-\frac{1}{2}} = U \Lambda U^T \quad (2-1)$$

其中, Λ 是 L 的特征值组成的矩阵, U 是特征向量的矩阵, T 是矩阵转置。图卷积操作定义为:

$$y = \sigma(U g_{\theta}(\Lambda) U^T x) \quad (2-2)$$

其中, y 是节点的输出特征, g_{θ} 是图卷积核。 $g_{\theta}(\Lambda)$ 表示 g_{θ} 在 Λ 上的卷积运算。 x 是输入节点特征, $\sigma(\cdot)$ 是激活函数。如图 1 所示, 图卷积层将图节点的特征与邻接矩阵融合, 以获得提取的节点特征。 x_i 和 y_i 分别是第 i 个节点的输入和输出特征。

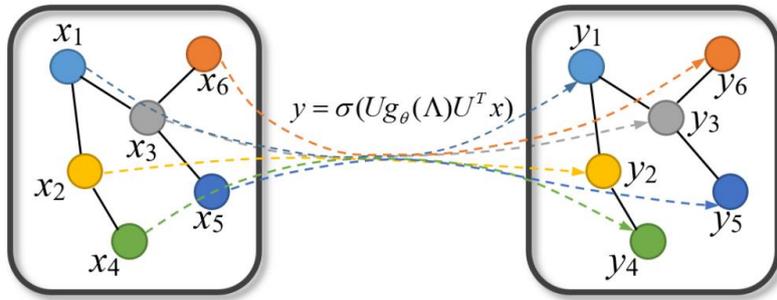


图 2.1 图卷积层结构

进一步地, 由于 L 仅代表直接相连节点之间的关系, 为了提取距离较远的节点间的特征关系, 将切比雪夫多项式应用于:

$$g_{\theta}(\Lambda) = \sum_{k=0}^{K-1} \beta_k T_k(\tilde{\Lambda}) \quad (2-3)$$

其中, K 为总的阶数, $T_k(\cdot)$ 是第 k 阶切比雪夫多项式, β_k 是第 k 阶特征的卷积核, $\tilde{\Lambda} = \frac{2\Lambda}{\lambda_{max}} - I$, I 是重新缩放的 Λ , 是为了 $T_k(\cdot)$ 需要在 $[-1,1]$ 输入范围内, λ_{max} 是 Λ 的最大值, I 是单位矩阵。因此, 我们可以通过以下方式推导出图卷积层的最终公式:

$$y = \sigma(U \sum_{k=0}^{K-1} \beta_k T_k(\tilde{L}) U^T x) = \sigma(\sum_{k=0}^{K-1} \beta_k T_k(\tilde{L}) x) \quad (2-4)$$

其中 $\tilde{L} = \frac{2L}{\lambda_{max}} - I$ 是归一化后的 L 。

基于上面的公式，图卷积层提取节点不同距离的特征并求和，以获得每个节点的输出特征。一个完整的 GCN 通过多个堆叠的图卷积层来获得节点的最终特征。如图 2-2 所示， x_i 、 y_i 和 o_i 分别是第 i 个节点的输入、隐藏和输出特征。在每个图卷积层之后，通过结合相邻节点的信息来更新每个节点的特征。最后，可以构建全连接层以完成分类和回归等目标任务。

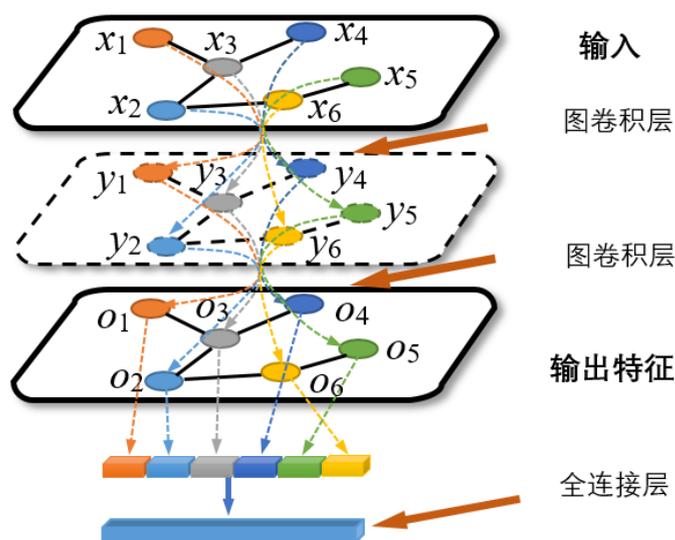


图 2-2 图卷积神经网络基本结构

2.3 基于图卷积神经网络的新型电力系统状态估计方法

2.3.1 状态估计方法流程

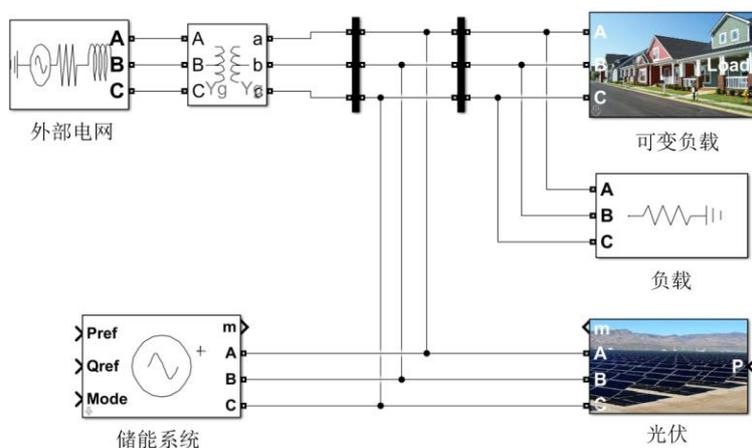


图 2-3 典型新型电力系统模型

随着接入的分布式能源增加，新型电力系统惯性下降，暂态电压波动会更加频繁的发生，从而影响电能质量，因此需要实时监测电力系统中各母线节点的暂态过程。然而，由于 PMU 的安装不足，在电力系统实际运行过程中很难获得所有节点的暂态数据信息。

一个典型的新型电力系统模型如图 2-3 所示，包含有光伏发电、储能和可变负载。考虑节点间的连接关系，该电力系统为典型的图结构，其拓扑指示了馈线上的潮流，并影响新型电力系统的运行状态。因此，考虑节点状态之间的关系对于新型电力系统的状态估计非常重要。在有限的 PMU 安装的情况下，可以挖掘节点数据之间潜在联系的 GCN 是进行新型电力系统状态估计的最优选择。因此本文提出了一种基于 GCN 的综合利用 SCADA 和 PMU 数据的新电力系统状态估计方法。

图 2-4 显示了所提出方法的流程图，其详细步骤描述如下：

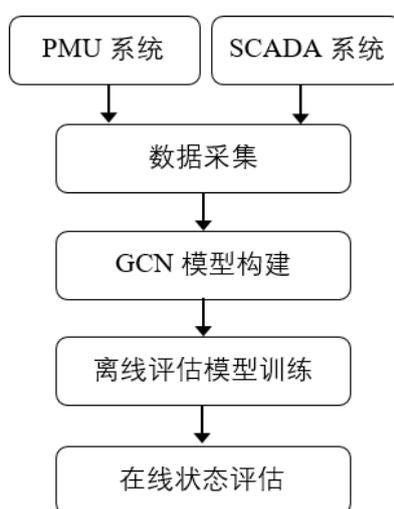


图 2-4 新型电力系统状态评估方法流程图

1) 新型电力系统实时状态监测数据获取

获取未安装 PMU 节点的 SCADA 监测数据和具有 PMU 测量的节点的高采样频率的实时 PMU 数据，包括有功功率、无功功率、频率和三相电压。然后结合 SCADA 和 PMU 数据构建新型电力系统的状态矩阵 $S \in \mathbb{R}^{N \times 6}$ 。其中 N 是新型电力系统节点数量。在电力系统发生的暂态过程中，PMU 数据实时变化，SCADA 数据保持不变。

2) 用于新型电力系统状态估计的 GCN 构建

根据新型电力系统的拓扑结构，构造用于状态估计的 GCN 模型。基于电力系统节点之间的连接关系，建立了相应拓扑结构的邻接矩阵。然后，考虑电力系统的参数，设置 GCN 的结构参数，并根据 PMU 节点的位置定义输入和输出形式，网络具体结构将在下一小节中介绍。

3) 状态估计模型离线训练

建立新型电力系统暂态仿真模型，模拟系统中可能发生的故障及扰动情况，获取暂态过程中所有节点的监测数据。进一步地，选择以获取的新型电力系统的状态矩阵为输入，未 PMU 的节点暂态数据为输出，训练已构建的用于新型电力系统状态估计 GCN 模型。

4) 实时状态估计的在线实现

在线部署基于 GCN 的新型电力系统节点状态估计模型。输入实时采集的所有节点的 SCADA 数据和部分节点的实时 PMU 数据，根据网络输出获得所有新型电力系统节点的实时状态估计结果。

2.3.2 用于新型电力系统状态估计的 GCN

为了充分利用 SCADA 数据和有限的 PMU 数据，提出了一种用于新型电力系统状态估计的 GCN 模型，如图 2-5 所示。该模型将多源数据合并为 GCN 的输入，其中 SCADA 数据用作未安装 PMU 节点的输入，实时 PMU 数据用作安装有 PMU 节点的输入。然后，以 SCADA 数据为初始值，通过 GCN 中的图卷积运算与相邻节点的数据融合，更新未安装 PMU 节点的状态。

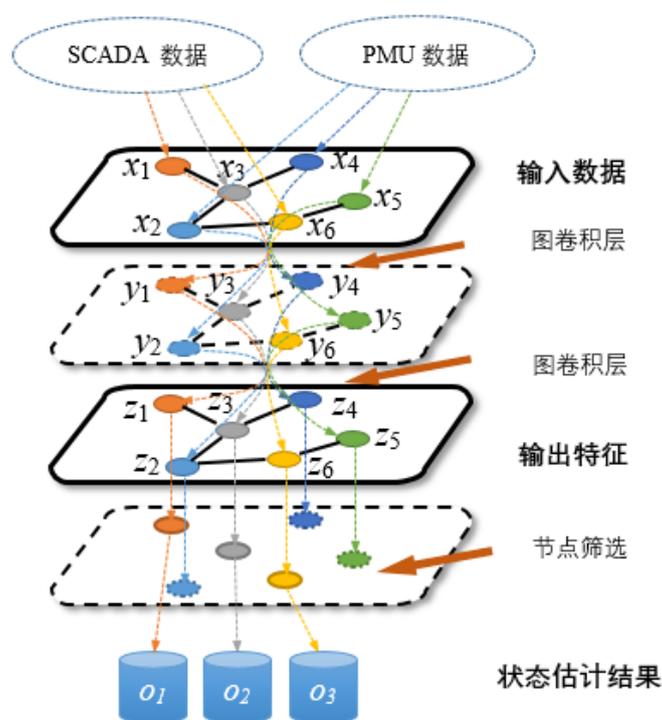


图 2-5 新型电力系统状态估计的 GCN 结构

同时，为了获得未安装 PMU 测量的节点状态，在网络输出部分构造了多个回归任务以生成多个输出。如图 2-5 所示，在最后一个图卷积层之后添加掩码层，以

指示出未安装 PMU 的节点，然后构造多任务回归输出，训练过程中的损失函数定义如下：

$$L = \sum_i^S \sum_j^C (l_{i,j} - o_{i,j})^2 \quad (2-5)$$

其中 S 是未安装 PMU 测量的节点数， C 是数据通道数， $l_{i,j}$ 和 $o_{i,j}$ 分别是第 i 个节点的第 j 个数据通道的真实标签值和输出值。在网络训练过程中，以仿真获得的未安装 PMU 节点的实际暂态数据为标签。

2.4 仿真实验及结果分析

为了验证所提出方法的有效性，本节进行了基于 IEEE 9 节点电力系统^[61]进行了仿真实验，并进行了结果分析。

2.4.1 新型电力系统暂态仿真

基于图 2-6 所示的 IEEE 9 节点电力系统的拓扑结构，首先使用 PSD/BPA 软件构建新型电力系统的仿真模型。该系统在 230 kV、50 Hz 下运行，其中发电机 1、2 和 3 为三台发电机，其中发电机 2 为光伏发电。母线 A、母线 B、母线 C 和发电机 2 是具有不同功率因数的可变负载的母线，母线 A、母线 B、母线 C 和发电机 2 安装有 PMU 数据采集设备。

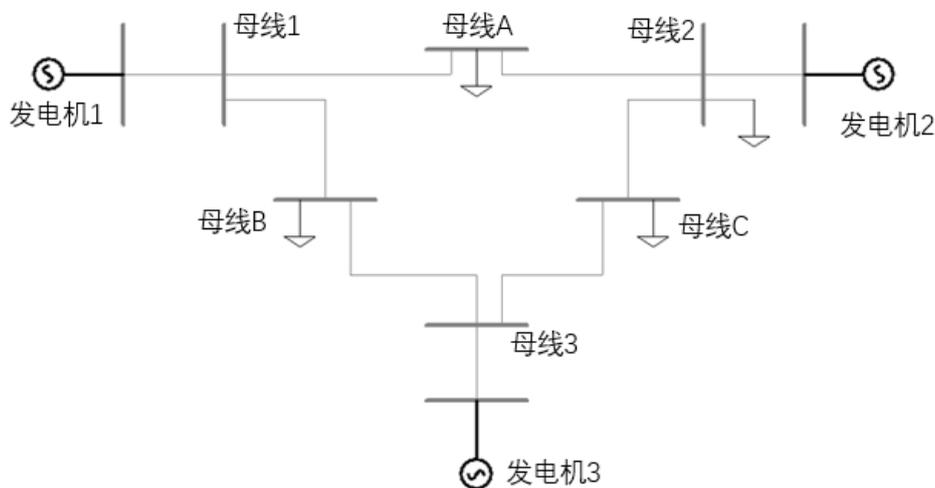


图 2-6 IEEE9 节点电力系统模型

使用 PSD/BPA 软件注入干扰和故障，以模拟新型电力系统中的瞬态过程。干扰包括节点上负载的突然增加，故障包括母线之间电力线路上的单相接地、两相短路、两相接地和三相短路，共模拟了故障和干扰条件下的 180 个暂态过程。图 2-7 显示了当母线 A 和母线 2 之间的电力线路 B 相和 C 相上发生两相接地时，新型电力系统的节点电压曲线。故障发生在 0.01 秒，保护装置动作在 0.02 秒。

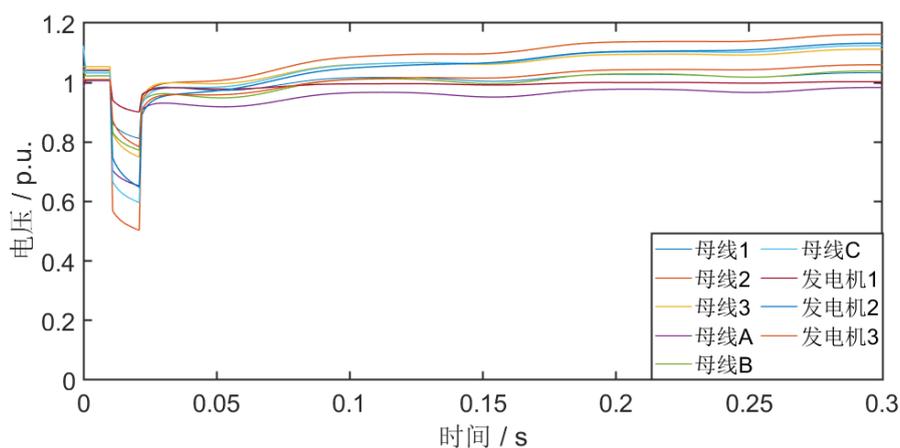


图 2-7 两相接地故障期间的母线电压曲线

2.4.2 参数设置及离线训练

为了构建针对特定新型电力系统的 GCN 模型，首先，将电力系统母线作为图节点，将传输线路作为图的边，构建电力系统系统的图结构。然后，建立一个 6×6 的邻接矩阵来描述电力系统拓扑。GCN 模型由三个图卷积层构成，并进而使用两个全连接层来提取每个节点的特征。表 2-1 列出了 GCN 模型的详细参数，最后一个图卷积层的特征被筛选为 5 个未安装 PMU 节点的输出，包括电压、频率和有功功率等 3 个待估计的数据。

表 2-1 GCN 模型参数

编号	层类型	输入大小	参数大小	输出大小
1	图卷积层	9×6	$6 \times 10 \times 3$	9×10
2	图卷积层	9×10	$10 \times 10 \times 3$	9×10
3	图卷积层	9×10	$10 \times 5 \times 3$	9×5
4	掩码层	9×5	9×1	5×5
5	全连接层	5×5	$5 \times 10 / 5$	5×10
6	全连接层	5×10	$10 \times 3 / 5$	5×3

在采样频率为 1000Hz 的情况下，选择 0.3 秒的 PMU 数据（包含 300 个采样点）作为网络输入进行训练。离线训练总共使用了 42000 个样本，其中 12000 个样本用于评估训练后的 GCN 状态估计模型。模型训练在具有 GTX 1070 GPU 和 16GB 内存的计算机上进行，使用 Python 环境中 Tensorflow 深度学习框架，学习速率设置为 0.001。经过大约 290 分钟，GCN 模型的训练在 5000 个周期后实现收敛。训

练过程中 3 个预测量的损失曲线如图 2-8 所示, 相对稳定。GCN 的训练速度比 CNN 慢, 因为它是考虑了图的拓扑结构, 具有很强的鲁棒性。

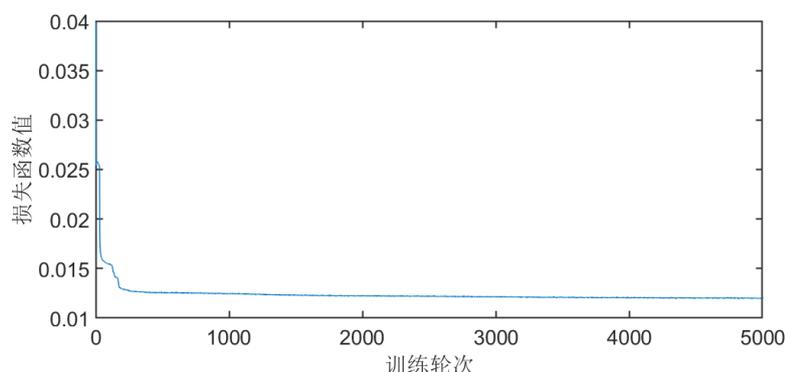


图 2-8 训练过程中损失函数收敛曲线

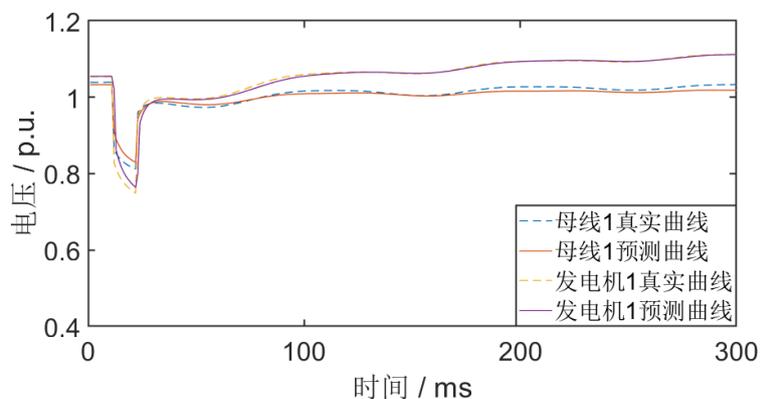
2.4.3 结果分析

表 2-2 列出了 3 个估计指标的训练和测试集的平均均方根误差 (Root Square Mean Error, RSME)。可以看出, 与真实值相比, 电压、频率和有功功率的所有 RSME 都很小, 这表明了该方法在状态估计中的有效性。

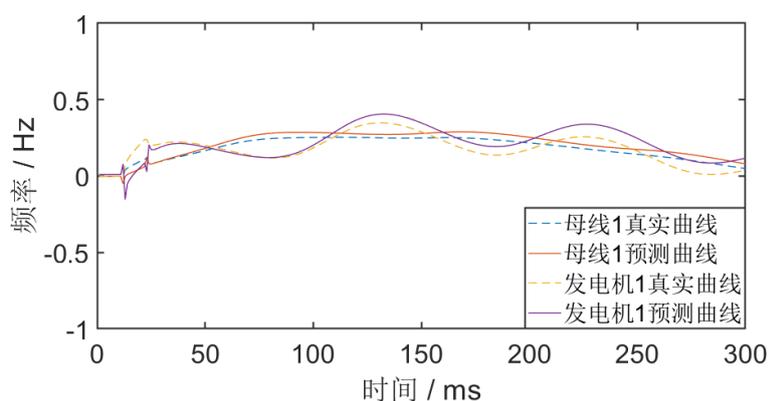
表 2-2 3 个估计指标的训练和测试集误差

数据集	电压 (p.u.) RSME	频率 (Hz) RSME	有功功率 (MW) RSME
训练集	0.058	0.273	1.954
测试集	0.073	0.439	2.495

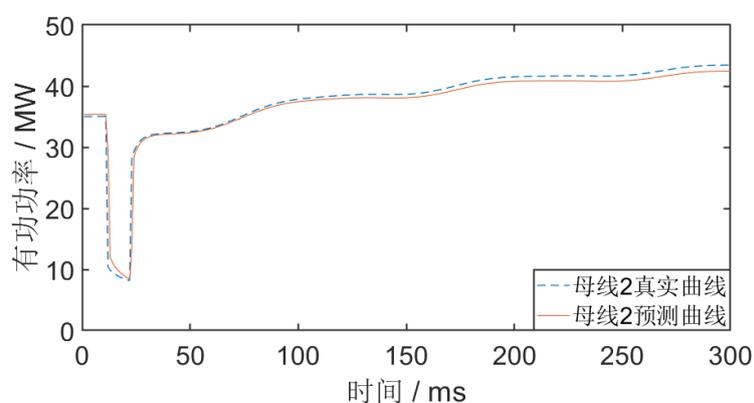
图 2-9 显示了图 2-5 中瞬态过程中母线 1 和发电机 1 的状态估计结果。可以看出, 提出的方法可以获得母线 1 和发电机 1 的电压、频率和有功功率的准确估计, 而且保护动作后曲线中的波动拟合良好。当线路阻抗发生剧烈变化时, 估计误差主要来自故障注入过程, 阻抗变化对 GCN 模型的影响值得进一步研究。



(a) 电压估计结果



(b) 频率估计结果



(c) 有功功率估计结果

图 2-9 状态评估结果

2.5 本章小结

本章提出了一种利用 SCADA 和 PMU 数据的基于 GCN 的新型电力系统状态估计方法。考虑到新型电力系统的拓扑结构，GCN 基于邻接矩阵融合电力系统节点的多源数据。然后构造多个任务批，通过部分安装 PMU 节点的实时测量数据来估计所有电力系统节点的暂态状态。对新型电力系统的仿真实验研究表明，该方法可以实现故障和扰动期间电力系统的实时状态估计。

3. 基于深度学习的新型电力系统诊断

3.1 引言

分布式发电的增加使新型电力系统更容易随着发电量的变化、负载的随机波动及电力电子设备的谐波干扰而发生故障，这导致故障检测、识别和定位成为电力系统保护的重要方面^[62]。同时分布可再生发电系统由于需要对自然资源进行充分利用，往往布置在偏僻、较为恶劣的环境中，这些发电系统的有效诊断对整个新型电力系统的稳定高效运行意义重大。

近年来，PMU 因其可以提供大量实时数据和丰富的数据类型优势，广泛应用于电力系统的监测和控制，为状态估计^[63]、电压稳定性^[64]等许多应用提供了支持。此外，微型 PMU^{[65][66]}近年来发展迅速，使大范围的电力系统实时监测成为可能。同时在新系统中，设备级的健康监测也逐渐普及，在电信号之外，振动、图像等多种信息的采集，也为更精确的设备级故障诊断提供了数据支撑。大量数据的接入为高效快速的基于人工智能的诊断方法提供了基础，但目前，现有的基于人工智能的系统、设备级的故障诊断方法大多数只使用数据进行模型训练，为充分考虑电力系统的领域知识，导致这些方法的鲁棒性和实用性较差。

为了充分利用丰富的监测数据和新型电力的领域知识，本章根据电力系统拓扑和故障机理知识对深度学习算法进行改进，提出了对新型电力系统传输线路及发电设备的智能诊断算法，以保障电力系统的安全稳定运行。

3.2 基于改进图卷积神经网络的电力传输线路故障诊断方法

电力系统故障诊断的常用方法使用远距继电器的信号^[67]，然而，由于缺乏丰富的实时数据，基于继电器的故障诊断方法对于具有可变发电量和拓扑结构的新系统保护的效率和准确性并不令人满意^[68]。当使用 PMU 数据进行故障诊断时，一些传统方法开发了特征提取算法^{[69][70]}或建立诊断规则^[71]，这些方法未能充分利用 PMU 的大量监测数据。特别是在用于新系统故障诊断时，如果不充分考虑其状态的变化，这些方法的准确性将大大降低。为了利用 PMU 数据实现新系统的实时故障检测，并方便快速保护，然而现有方法大多需要录波数据和复杂的数据预处理过程，无法实现毫秒级的故障诊断和快速的故障响应。

此外，上述基于深度学习的方法仅将所有测量数据直接合并为统一的输入，没有考虑测量数据背后的电力系统拓扑信息，因此，上述方法很难检测故障发生在哪

条线路上。拓扑反映了电力系统节点之间的连接关系,对相邻节点数据的联合特征提取可以揭示节点之间的潮流,从而有助于电力系统的故障检测。同时,不考虑电力系统拓扑等领域知识的全数据驱动方法的鲁棒性较差,尤其是在多变的发电量和负载下。

因此,本文首次将 GCN 引入电力系统故障诊断领域,并考虑了电力系统的领域知识对其进行了改进,提出了一种基于改进 GCN 的新型电力系统故障诊断方法,实现了准确的在线故障检测、识别和定位。该方法利用 GCN 中邻接矩阵表示的电力系统拓扑,提取每个节点及其相邻节点的 PMU 数据中的故障特征,并通过图卷积运算进行融合。最后,构造了多任务的以电力系统线路特征为输入的全连接层和分类器,同时实现了电力系统的故障检测、识别和定位。

以一个基于电气可靠性技术解决方案联盟 (Electric Reliability Technology Solutions, CERTS) [72] 的简化新型电力系统为例,本节讨论了应用和改进 GCN 进行新型电力系统故障诊断的动机,该方法也适用于其他放射形的或环形结构的电力系统。如图 3-1 所示,该电力系统中包含两个分布式发电机 (Distributed Generator, DG), 即 DG 1 和 DG 2, 以及三个可变负载, 即负载 1、负载 2 和负载 3, 线路 1 至 7 为 7 条潜在的故障线路。PMU 测量系统安装在母线、DG 和负载上, 以获取节点的实时操作信息。

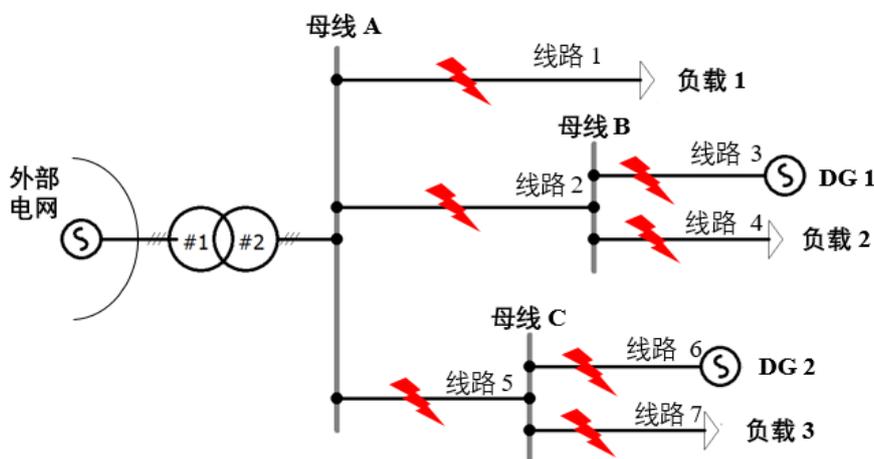


图 3-1 基于 CERTS 的简化的电力系统模型

考虑到电力系统中多个节点相互连接的结构,电力系统的动态故障过程中采集到的多节点的 PMU 数据是非欧几里德结构的图,如上一章节所述,其拓扑结构对电力系统的状态感知具有重要意义。此外,由于 GCN 和电力系统的结构相似,GCN 节点的输出可以对应于电力系统节点,这提高了深度学习模型的可解释性。因此,在本节中,GCN 被引入电力系统故障诊断领域并结合领域知识进行了改进,

最终实现了对电力系统故障数据的准确特征提取。

3.2.1 改进的图卷积神经网络

在上一章中，GCN 的基本结构得到了详细的介绍。新型电力系统的拓扑是一种典型的图结构，电力系统的节点和线路可以分别用图的顶点和边来表示，这使得 GCN 易于应用于电力系统的结构化数据。然而，考虑到电力系统的领域知识，仍然存在一些有待解决的问题：

(1) 在 GCN^[73]的一些基本应用中，每个节点中的数据维度很小，通常最多只有几十个数据点。而在新型电力系统故障诊断中，GCN 需要从高采样频率的多通道的 PMU 数据中提取并融合多个节点的特征，这对 GCN 的特征提取能力提出了挑战。

(2) 新型电力系统中的不同节点具有不同的类型，代表具有不同特性的具体设备，如母线、负载和分布式发电等，因此不同节点的功率特性曲线和故障响应也不同。GCN 平等地对待所有节点，无法考虑不同新型电力系统节点运行规律的差异。

为了解决上述问题，结合卷积神经网络（CNN）并考虑电力系统节点特性差异，本章提出了一种全新的改进的图卷积神经网络（improved GCN, IGCN）用于新型电力系统数据的特征提取，其主要结构如图 3-2 所示。

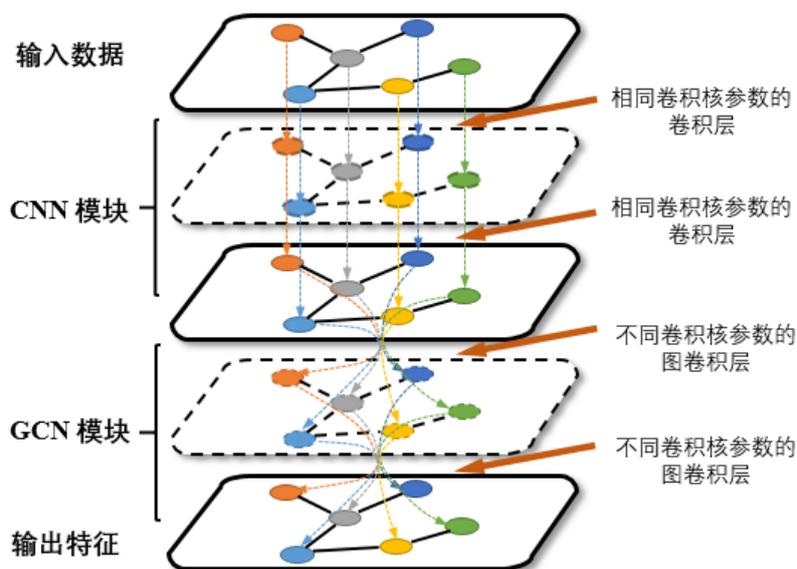


图 3-2 改进的图卷积神经网络结构图

如图 3-2 所示，为了提高 GCN 的特征提取能力，IGCN 在图卷积层之前添加了基于 CNN 的公共卷积层块。由于每个节点的 PMU 测量数据采用欧几里得结构的统一格式，卷积层通过以下方式分别应用于每个节点的数据：

$$X_i^j = \sigma(M_i * H^j + b^j) \quad (3-1)$$

其中, $M_i \in \mathbb{R}^{T \times C}$ 是第 i 个节点的 PMU 测量数据, 是具有 C 个采样通道和 T 个时刻的样本, H^j 和 b^j 分别是第 j 个卷积层的卷积核和偏差。 X_i^j 是第 j 卷积层之后第 i 个节点提取到的特征。值得注意的是, 电力系统中的所有节点在同一卷积层中共享相同的卷积核, 因为这些节点的 PMU 数据具有相同的数据结构。

同时, 在普通的图卷积层中, 不同节点的图卷积核 β_k 在相同的阶次下保持不变, 如公式 (2-4) 所示。该设计采用了 CNN 中的权重共享思想, 有助于减少参数数量, 因为每个节点或图片部分的数据形式大致相同^[74]。然而, 如上所述, 电力系统节点可能具有不同的数据特征和运行规律。在天气较好时, 光伏功率曲线会呈现山峰形状, 发电功率在靠近正午时较大, 而风力发电更接近于一个与天气有关的随机过程^[75]。因此, 有必要在图卷积层中以不同的方式提取不同电力节点的数据特征。

在本章提出的改进的 GCN 中, 通过为每个节点构造不同的单独的图卷积核来优化图卷积层, 其公式定义为:

$$y' = \sigma(\sum_{k=0}^{K-1} \sum_{i=0}^N \beta_k^i T_k(\tilde{L})x_i) \quad (3-2)$$

其中, y' 是优化图卷积层的输出, β_k^i 是第 k 阶针对第 i 个节点的图卷积核, K 为总的阶数。按这种方式, β_k^i 仅由与第 i 个节点相关的特征进行训练, 从而实现了与每个节点的运行规律相对应的单独训练。在通过改进的 GCN 获得所有节点的输出特征后, 可以对提取的特征应用多个任务, 例如, 将所有节点的特征与新型电力通态势感知的回归模型相结合, 或者为每个节点构建分类器来判断该节点的状态。

3.2.2 新型电力系统故障检测、识别及定位方法

图 3-3 显示了提出的新型电力系统故障诊断方法的流程图, 该方法同时实现了新型电力系统的实时故障检测、识别和定位, 其详细步骤描述如下:

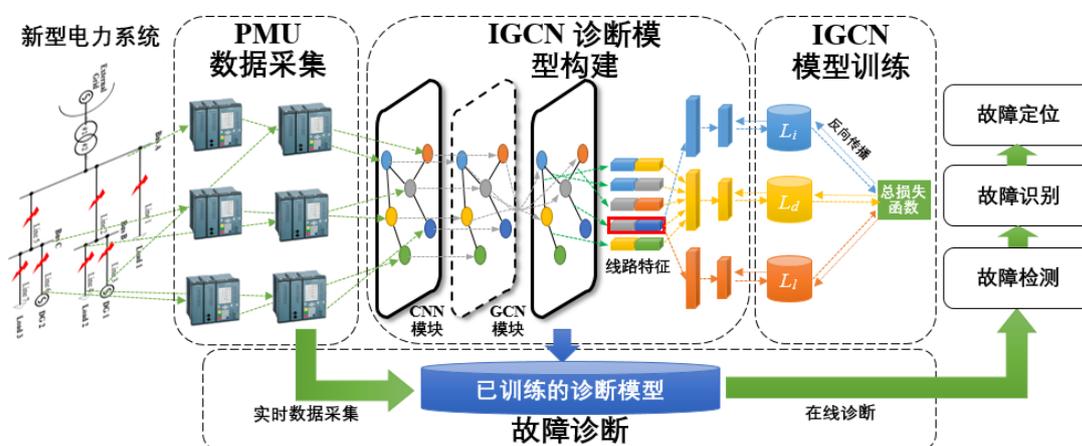


图 3-3 新型电力系统故障诊断方法流程图

(1) PMU 数据采集

实时采集所有新型电力系统节点的 PMU 暂态数据，包括每个节点在一定时期内的有功功率、无功功率、频率和三相电压，共 T 个时刻的样本。因此，每个节点的测量数据 $M_i \in \mathbb{R}^{T \times 6}$ 。

$$M_i = \begin{bmatrix} P_{1,i} & P_{2,i} & \dots & P_{j,i} & \dots & P_{T,i} \\ Q_{1,i} & Q_{2,i} & \dots & Q_{j,i} & \dots & Q_{T,i} \\ f_{1,i} & f_{2,i} & \dots & f_{j,i} & \dots & f_{T,i} \\ U_{1,i}^a & U_{2,i}^a & \dots & U_{j,i}^a & \dots & U_{T,i}^a \\ U_{1,i}^b & U_{2,i}^b & \dots & U_{j,i}^b & \dots & U_{T,i}^b \\ U_{1,i}^c & U_{2,i}^c & \dots & U_{j,i}^c & \dots & U_{T,i}^c \end{bmatrix} \quad (3-3)$$

其中， $P_{j,i}$ 、 $Q_{j,i}$ 、 $f_{j,i}$ 、 $U_{j,i}^a$ 、 $U_{j,i}^b$ 、 $U_{j,i}^c$ 分别为第 j 个时刻的采样点的有功功率、无功功率、频率和 A、B、C 三相电压。

在本节中， T 设置为 50，采样率为 100Hz，其中包括半秒内的 PMU 测量数据。值得注意的是， T 决定了输入大小，只影响一步诊断所需的计算时间。诊断算法的触发间隔可设置为远小于 0.5 秒，以确保实时诊断，故障诊断过程可以在故障发生后不到一秒钟内完成。

(2) 基于改进 GCN 的故障诊断模型构建

基于新型电力系统拓扑结构，构建一个由卷积层、图卷积层和全连接层组成的改进 GCN 模型，其中全连接层具有三个子任务，分别完成 MG 线路的故障检测、识别和定位。

如图 3-4 所示，首先，基于电力系统拓扑，第 k 条线路的两个节点的特征融合构成了第 k 条线路 Y_k 的特征，这有助于直接基于线路特征的进一步提取。然后，故障检测任务使用所有 Y_k 作为输入来检测故障线路。最后，将红色框中故障线路 Y_f 的特征用作其他两个任务的输入，用于故障识别和定位。

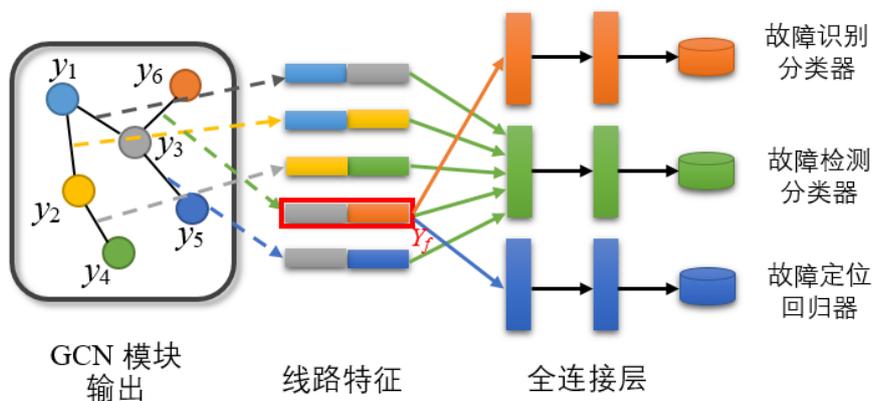


图 3-4 改进 GCN 的多诊断任务处理模块

每个任务的子网络包括两个全连接层,用于进一步的特征提取,如图 3-4 所示。不同之处在于, softmax 分类器用于故障检测和识别的任务,而回归输出用于故障定位任务。通过这种方式,改进的 GCN 模型可以同时完成三个故障诊断任务。

(3) 改进 GCN 的故障诊断模型训练

在训练之前,用电力系统实际状态对 PMU 监测数据进行标记,包括故障线路、故障类型和故障位置。标签 L_d 具有 $K+1$ 类,用于判断是否发生故障以及哪条线路是故障线路。标签 L_t 有 10 类,包括四种故障类型即(单相接地、两相短路、两相接地和三相短路接地)的不同的故障相位。标签 L_l 是故障线路上的具体故障位置,被归一化至 $[0, 1]$ 范围内,以线路的其中一个节点作为起始端。然后,使用采集到的 PMU 监测数据作为输入,以三种类型的标签作为输出,使用特殊的训练策略(将在下一小节中描述)对构建的改进的 GCN 模型进行训练,以获得准确且鲁棒性强的模型。

(4) 基于改进 GCN 模型的在线诊断

将训练好的改进的 GCN 模型应用于新型电力系统的在线故障诊断。改进的 GCN 模型以实时 PMU 采集数据为输入,可以实现实时的故障检测。如果检测到故障,故障线路的特征将进一步用于实现线路的故障识别和定位。

3.2.3 超参选择及训练策略

由于分布式发电系统和负荷在 MG 中的波动受到时间、天气等因素的影响, MG 节点的微观 PMU 数据受到强随机波动的影响,这对基于深度学习的故障诊断方法的鲁棒性提出了挑战。因此,需要优化 MG-IGCN 的参数选择和训练策略,以获得鲁棒的故障诊断模型。

(1) 卷积层参数选择

电力系统故障诊断主要是捕捉故障发生后节点电压、频率和功率的变化。因此,不需要太多卷积层,否则将增加网络参数且会降低训练速度。同时,实现准确的故障定位需要在毫秒级捕捉故障突变过程数据中的细节信息。因此,卷积核不应太大,否则将无法提取 PMU 数据中的微小变化。

(2) 图卷积层参数选择

在电力系统中,节点和远距离节点之间的关系很弱。例如,负荷和发电侧之间的距离通常不超过 3。因此,在改进的 GCN 中,切比雪夫多项式的阶数设置为不超过 3。本文将图卷积层数设置为 2。如果使用更多的图卷积层,故障诊断的准确性不会提高很多,反而会显著增加网络的参数数量。

(3) 考虑功率波动的训练策略

为了确保经过训练得到的深度学习模型的鲁棒性，训练数据的丰富性和完整性至关重要。因此，本文将具有功率波动的多个全天的电力系统数据用作改进 GCN 的训练数据。算法 3-1 显示了训练策略的主要步骤。

算法 3-1 考虑功率波动的改进的故障诊断 GCN 训练策略

- 1: 获取新型电力系统中 s 天以 m 分钟为间隔的分布式发电机、可变负载的有功和无功功率;
 - 2: 构建新型电力系统模型，基于不同时刻的功率信息，计算每个样本的潮流，获得 $1440s/m$ 个电力系统初始状态;
 - 3: 以不同的 $1440s/m$ 个电力系统初始状态为基础，进行不同线路上不同故障类型、位置的仿真;
 - 4: 获取故障过程中的监测数据，并对数据进行标注得到: L_d 、 L_t 和 L_l ，并初始化改进的 GCN 模型;
 - 5: 重复:
 - 6: 以监测数据为输入，对改进的 GCN 模型进行正向传播，从最后一个图卷积层获得电力系统节点的输出特征。
 - 7: 对于 $k \in 1, 2, \dots, K$:
 - 8: 组合第 k 条线的两个节点的输出特征，以获得第 k 条线路 Y_k 的特征;
 - 9: 将所有 Y_k 集中作为故障检测任务的输入，用 L_d 计算故障检测的 softmax 损失:

$$loss_d = -\log(e^{s_{L_d}^d} / \sum_{j=1}^{K+1} e^{s_j^d});$$
 - 10: 使用故障线路 Y_f 的特征作为故障识别任务的输入，并使用 L_t 计算故障识别的 softmax 损失: $loss_t = -\log(e^{s_{L_t}^d} / \sum_{j=1}^{K+1} e^{s_j^d});$
 - 11: 使用故障线路 Y_f 的特征作为故障定位任务的输入，并使用 L_l 计算故障识别的损失: $loss_l = (s^l - L_l)^2;$
 - 12: 计算三个任务的总损失: $Loss_{total} = \frac{1}{\sigma_d^2} loss_d + \frac{1}{\sigma_t^2} loss_t + \frac{1}{\sigma_l^2} loss_l + 2\log\sigma_d + 2\log\sigma_t + 2\log\sigma_l;$
 - 13: 使用 Adam 优化器执行网络反向传播，以更新改进的 GCN 模型参数。
 - 14: 直到 $Loss_{total} < Loss_{end}$
-

在所提出的训练策略中， s_j^d 是故障检任务的第 j 个输出， s_j^t 是故障识别任务的第 j 个输出， s^l 是故障定位任务的输出， $Loss_{end}$ 是收敛损失限制。新型电力系统在一天中所有时间的状态都用于训练，其中尽可能包括分布式发电和负载的所有波动。同时，改进的 GCN 中的多任务学习需要从共享特征表示中完成三个任务，这要求模型在不同的任务之间进行权衡。否则，其中一个任务可能发生梯度爆炸，造

成训练无法收敛。因此，为了平衡三个任务的训练，采用了一种考虑不确定性的损失加权方法^[76]，该方法使用观察到的噪声参数来衡量多个任务的损失。在所提出的训练策略中， σ_d 、 σ_t 和 σ_l 分别是三个任务的观测噪声参数，并随着训练过程进行更新。

3.2.4 仿真实验及结果分析

本节中在 CERTS 系统上对所提出的新型电力系统故障诊断方法进行了评估，以证明其有效性。此外，还与现有方法进行了比较，充分证明了该方法的优越性。

(1) 故障仿真

基于图 3-1 所示的结构，模拟中的新型电力系统在 10 kV、50 Hz 下运行。母线 2、母线 3 和母线 5 的长度为 2 km，而母线 1、母线 4、母线 6 和母线 7 的长为 1 km。DG 1 为 1.5 MW 的光伏发电，DG 2 为 1.5MW 的风力发电机。负荷 1 和负荷 2 是具有不同功率曲线和功率因数的可变负荷，负荷 3 是一个电机。图 3-5 显示了故障仿真中第 5 天的分布式发电和负载的功率曲线，具有强烈的动态变化。

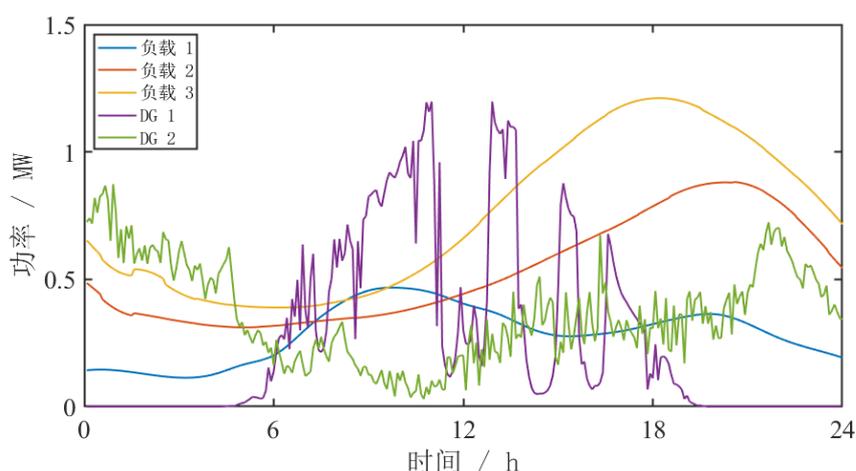


图 3-5 分布式发电和负载的功率曲线

本节的故障模拟在 PSD-BPA 软件上进行，包括不同的故障线路、类型和位置的组合，其详细参数如表 3-1 所示，共有 630 个故障标签组合。从 5 天的功率曲线中采样 240 个负载和分布式发电的功率组合。采样率为 100 Hz，采集了 6 个通道的 PMU 数据，包括三相电压、频率、有功和无功功率。选择的 PMU 数据长度为 50，包括故障注入前的 30 个数据点和故障注入后的 20 个数据点。

表 3-1 故障模拟情况

参数	可选的配置	数量
故障线路	线路 1 至 7	7

故障类型	(A/B/C) G、AB、BC、AC、 (AB/BC/AC) G、ABCG	10
故障位置	线路从一段开始的 10%、20%、...、90%	9
负载/分布式发电	负载 1: 0 - 1.11 MW 负载 2: 0.23 - 0.97 MW 负载 3: 0.27 - 1.21 MW 分布式发电 1: 0 - 1.49 MW 分布式发电 2: 0.06 - 1.50 MW	240

图 3-6 显示了当线路 1 的 B 相和 C 相发生两相短路故障，且在距离母线 A 侧 20%的位置时，线路 1 的暂态电压曲线。故障在 0.3 秒时注入，在故障发生后 0.2 秒可以检测到。

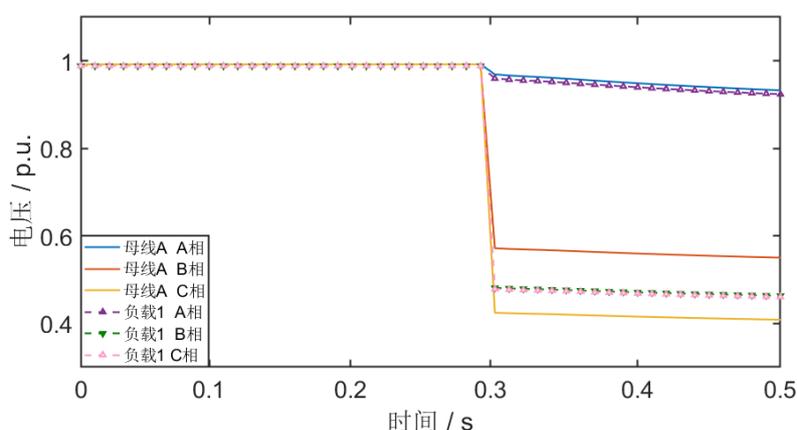


图 3-6 两相短路过程中线路 1 暂态电压曲线

故障模拟中新型电力系统的运行间隔为 30 分钟，持续 5 天。将每一天的故障模拟数据作为包含 30240 个故障样本的数据集，其中包括 432 个非故障样本，以及在一个负载中注入 10%、20%和 30%的新增负荷。共获得 5 个数据集，编号为 1 到 5，用于交叉验证。

(2) 模型参数设置

在改进的 GCN 的构建中，首先构造了 9×9 邻接矩阵，表示新型电力系统的拓扑结构，如图 3-7 所示，其中 1 表示两个节点之间有一条线路。然后构造了具有两个卷积层、两个图卷积层和三个全连接任务的改进 GCN 模型，其详细参数如表 3-2 所示。卷积层的参数是卷积核的大小和数量，图卷积层的参数包括图卷积核大小和切比雪夫多项式的阶，全连接层的参数表示隐藏层中的神经元数量。

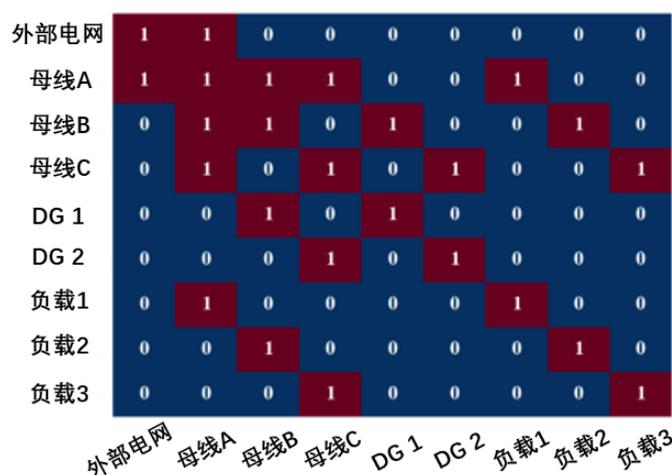


图 3-7 邻接矩阵

表 3-2 改进 GCN 的结构和参数

编号	层类型	输入大小	参数大小	输出大小
1	卷积层	9×50×6	1×4×6 / 20	9×50×20
2	卷积层	9×50×20	1×4×20 / 6	9×50×6
3	池化层	9×50×6	2×1	9×25×6
4	图卷积层	9×150	9×150×50 / 3	9×50
5	图卷积层	9×50	9×50×10 / 3	9×10
6	全连接层	14×10	10×8	8
		2×10	10×10	10
		2×10	10×1	1

基于改进 GCN 的故障诊断模型的训练在 Python 环境中进行，计算机配置为 intel i7-4790K CPU、GTX 1080Ti GPU 和 32 GB 内存。在训练阶段，学习速率设置为 0.001。大约 700 步后，改进 IGCN 的训练在大约 150 分钟内实现收敛。

(3) 实验结果及分析

表 3-3 列出了所提出方法在新型电力系统的故障检测、识别和定位中交叉验证的结果。通过预测故障位置与实际故障位置之间的距离的平均绝对误差 (MAE) 和均方根误差 (RMSE) 来评估故障定位的准确性。可以看出，所有数据集的组合都实现了准确的故障检测、识别和定位。故障检测准确率平均为 99.59%，表明该方法能够准确地检测出故障线路，并为电力系统的保护动作提供指导。使用数据集 1 作为测试集的组合具有最高的故障检测和识别精度，但在故障定位方面存在较大的误差，这展示了多个目标任务之间的权衡。

表 3-3 交叉验证下改进 GCN 模型的诊断准确率

训练 / 测试数据集	故障检测准确率	故障识别准确率	故障定位 MAE / RMSE
1 2 3 4 / 5	99.47%	99.97%	3.89% / 7.09%
1 2 3 5 / 4	99.67%	99.98%	3.89% / 7.17%
1 2 4 5 / 3	99.37%	99.99%	3.88% / 7.20%
1 3 4 5 / 2	99.60%	99.27%	4.05% / 8.59%
2 3 4 5 / 1	99.82%	100%	6.15% / 9.42%
平均	99.59%	99.82%	4.37% / 7.89%

图 3-8 中的混淆矩阵进一步显示了使用数据集 5 作为测试集的故障检测和识别结果，其中 LLLG、LL、LLG 和 LG 分别代表三相短路、两相短路、两相接地和单相接地故障。从图中可以看出，没有故障样本被分类为非故障，故障检测中的误分类主要发生在相似线路中，故障识别中的误分类主要分布在故障类型正确的错误相位上。

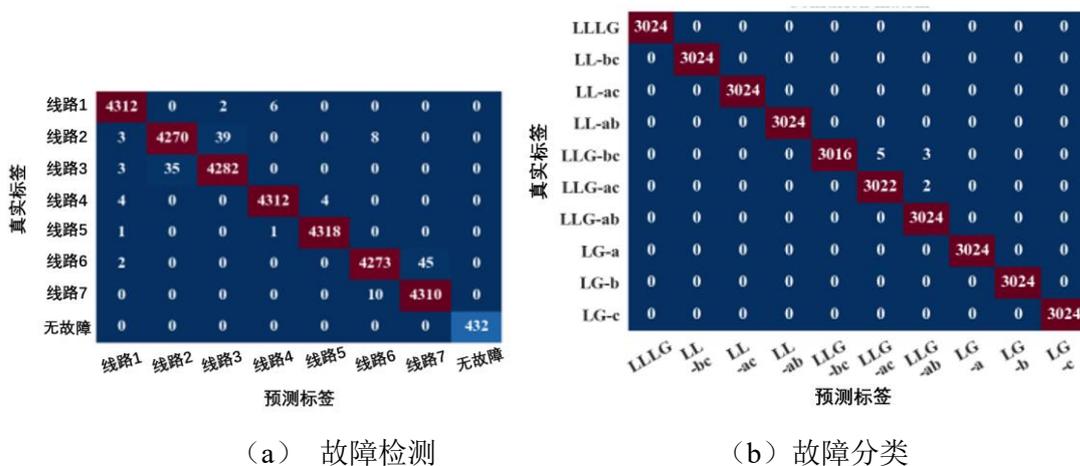


图 3-8 故障检测和分类任务的混淆矩阵

图 3-9 显示了使用箱线图直观地进行故障定位的结果。可以看出，所有定位结果都集中在较小的真值范围内，很少到达相邻的位置段。在线路 10%和 90%位置注入的故障的定位结果误差较大。这是因为当故障发生在节点附近时，故障波的传播距离较短，这需要更高的采样频率来提高故障定位的灵敏度。

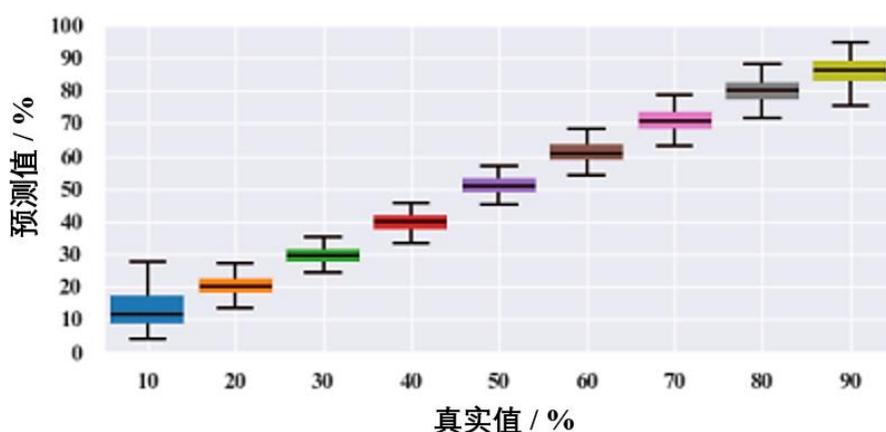


图 3-9 故障定位结果的箱线图

(4) 对比分析

为了证明该方法的优越性,将改进的 GCN 与文献中的方法进行了进一步比较,其中包括卷积稀疏自动编码器 (CSAE) [18]和基于小波的深度神经网络[19] (WDNN)。表 3-4 展示了数据集 1-4 用作训练集,数据集 5 用作测试集时的比较结果。

表 3-4 与文献中方法的对比结果

方法	故障检测 准确率	故障识别 准确率	故障定位 MAE / RMSE
CASE	\	98.07%	\
WDNN	\	86.30%	27.87% / 32.65%
改进 GCN	99.47%	99.97%	3.89% / 7.09%

比较结果表明,该方法的故障识别精度分别比 CSAE 和 WDNN 高 2%和 13%,而故障定位误差比其他方法低 80%以上。CSAE 和 WDNN 无法检测故障线路,这需要基于拓扑结构的电力系统综合特征提取。WDNN 将故障类型和相位视为两个独立的任务,这增加了故障识别的不确定性。同时,需要高采样率数据的 WDNN 无法利用实时 PMU 监测数据实现准确的故障定位。与最先进的方法相比,改进的 GCN 具有更好的相邻电力系统节点的特征融合能力,从而大大改善了需要精确节点特征的故障定位效果。此外,该方法是唯一能够同时完成三个故障诊断任务的方法。

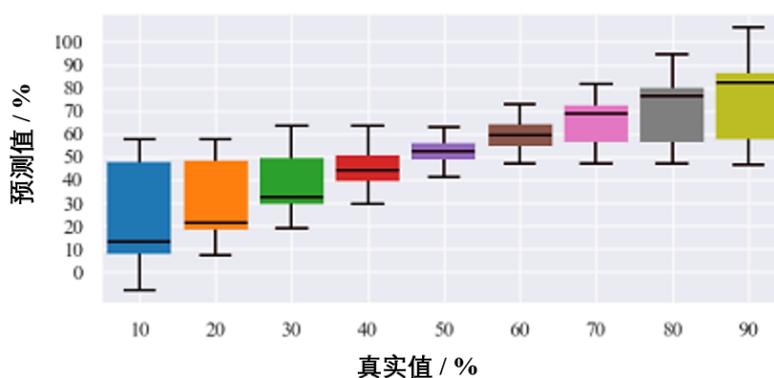
(5) 消融实验

为了分析所提出改进 GCN 各部分对整体性能的影响,进行了消融实验研究。每次去掉改进的 GCN 的一部分,并评估其故障检测、识别和定位的性能。从表 3-

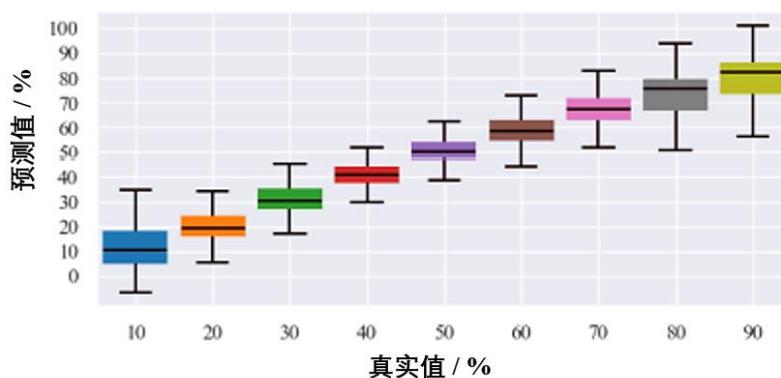
5 所示的结果可以看出，缺少改进的 GCN 的任何部分都会降低其故障诊断性能，虽然故障识别的准确性保持在较高水平。独立的图卷积核可以大大提高故障检测的准确性，这表明其可以提高对电力系统图结构数据的提取能力。对比图 3-9 和图 3-10，CNN 模块对故障定位的改进贡献很大，这表明 CNN 块可以准确地提取电力系统暂态过程数据中的细节。

表 3-5 消融实验诊断结果

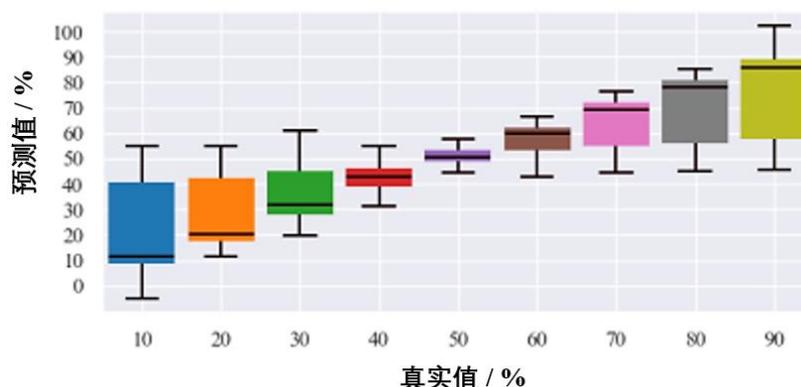
GCN	CNN 模块	独立图卷积核	故障检测准确率	故障识别准确率	故障定位 MAE / RMSE
✓			95.78%	99.97%	8.99% / 14.22%
✓	✓		97.10%	99.96%	6.29% / 10.15%
✓		✓	97.44%	99.96%	7.95% / 13.40%
✓	✓	✓	99.47%	99.97%	3.89% / 7.09%



(a) 只使用 GCN



(b) 普通 GCN+CNN 模块



(c) 具有独立卷积核的 GCN

图 3-10 消融实验中故障定位结果的箱线图

(6) 鲁棒性分析

为了评估该方法的鲁棒性，本小节在 PMU 监测数据中加入不同比例的高斯噪声，其故障诊断结果如表 3-6 所示。可以看出，改进的 GCN 在不同噪声比下保持了 PMU 数据的高故障识别精度。虽然故障线路的检测精度随着噪声的增加而缓慢下降，但故障识别的精度仍然高于 99%。故障定位的准确性降低较为明显，在 30dB 时最大误差约为 11%，这表明准确的故障定位需要准确的数据采样。总体来说，该方法在高斯噪声下具有很高的鲁棒性。

表 3-6 高斯噪声下的诊断结果

信噪比	故障检测 准确率	故障识别 准确率	故障定位 MAE / RMSE
40dB	97.44%	99.96%	4.36% / 7.61%
35dB	95.09%	99.96%	6.73% / 10.05%
30dB	91.13%	99.91%	11.07% / 15.55%

综上所述，本节提出的基于改进的 GCN 的新型电力系统故障诊断新方法可以实现电力系统的准确故障检测、识别和定位。对比研究表明，该方法比最先进的方法更准确且鲁棒性较强。在进一步的研究中，GCN 可以实现与新型电力系统状态监测、保护和预测相关的更多应用。除了本文主要研究的线路故障外，母线故障和高阻抗故障是下一步的研究方向，这有助于建立一个完整的电力系统实时诊断系统。

3.3 基于卷积神经网络和异构信息融合的风电机组故障诊断方法

随着智能电网的兴起,风能、光伏和其他可再生能源的充分利用导致电力生产变得智能化和分布式^[77]。风力发电作为智能电网中不可或缺的角色,其稳定运行对智能电网的控制至关重要。变速箱是风电机组的关键机械传动部件,其故障严重影响风电机组的正常运行,可能导致长期停机。因此,需要进行实时在线监测和智能诊断,以掌握变速箱的运行状态和健康程度。

在智能管理和诊断的推动下,许多基于机器学习的方法被提出用于风电机组齿轮箱的故障诊断^[78]。然而,由于使用简单的机器学习算法,例如极端学习机^[79]、支持向量机^[80]等,大多数基于机器学习的方法仍然需要复杂的特征提取过程。作为机器学习的高级形式,深度学习能够识别高维复杂输入,摆脱了对人工特征提取算法的依赖,是处理风电机组齿轮箱复杂非平稳振动数据的有力工具。因此,近年来,一些深度学习算法已应用于风电机组齿轮箱的故障诊断,例如,自动编码器^[81]、生成对抗网络^[82]和 CNN^[83]等。通常,在设计基于深度学习的齿轮箱故障诊断方法时,需要研究两个方面,即深度学习网络结构的设计和深度学习输入的构造^[84]。深度学习网络的设计应考虑故障信号的特征和待诊断的潜在故障,比如考虑到齿轮箱振动信号的多尺度特性,文献^[85]提出了 MSCNN 架构。现有工作集中在如何改变网络结构以更好地提取特征。然而,齿轮箱故障诊断中网络任务的变化并没有引起足够的重视,尤其是在耦合故障的情况下。

实际上,风电机组齿轮箱由多个部件组成包括轴、轴承和齿轮等,每个部件都可能出现故障^[86]。多部件耦合故障诊断是一个具有多标签的分类问题,现有技术方法尚未很好地解决这一问题。在文献^[87]中,所有耦合故障组合均通过 one-hot 方式进行编码,即每个组合被视为一个新类别。然而,one-hot 编码不能反映类别之间的关系,因为具有相同特征的同类型齿轮故障将属于不同类别。此外,在耦合故障的情况下,存在许多组件和故障类别,这导致具有过多类别的深度学习模型难以训练。这也导致现有方法只能判断整个齿轮箱的故障类型,但无法识别具体的故障部件^[88]。每个组件的故障识别可以实现精确的故障定位,这对风电机组维护有很大帮助^[89]。

为了将振动信息转换为深度学习输入,大多数文献中使用了简单重组的原始信号,无需应用信号分析算法。与仅提供时域信息的原始信号相比,时频分析如小波包分解^[90]、连续小波变换^[91]等是更好的选择,因为它可以提供更多有用的信息,也有结合不同信号分析算法结果的方法。然而,包括齿轮箱结构和部件故障机制在内的运行条件和领域知识在深度学习输入中没有充分使用。在耦合故障的情况下,

不同部件的故障特征频率和边频带可能相互重叠，这使得振动信号非常复杂。特别是，由于深度学习通常在可变条件下运行，故障特征的分布将发生显著变化。同时，高速部件的振动能量大，会掩盖低速部件的故障特征，这使得在没有运行条件和领域知识指导的情况下，使用现有方法难以准确提取所有部件的故障特征。

为了解决上述问题，本文提出了一种新的风电机组齿轮箱多部件耦合故障诊断方法。该方法将多个振动信号的领域知识和小波包分解矩阵融作为深度学习输入，提出了一种具有并行子 CNN 和多分类器的齿轮箱诊断模型，以实现耦合故障的同步诊断。

3.3.1 齿轮箱耦合故障诊断方法

作为一个复杂系统，风电机组齿轮箱由多个部件组成，通常通过使用多个传感器对齿轮箱进行状态监测，获得组合信号 \mathbf{S} 来表示监测到的齿轮箱系统状态。齿轮箱的故障诊断是基于观察到的系统状态 \mathbf{S} 获得其故障状态，单标签常见故障诊断方法假设整个系统只有一个故障状态 F ，并尝试训练诊断模型 g 来表示 \mathbf{S} 和 F 之间的关系。事实上，为了准确获得特定的故障部件和位置，具有 n 个部件的齿轮箱的故障诊断应表示为具有故障状态 F_1, F_2, \dots, F_n 的多标签问题，这需要多个故障诊断分支 g_i 来获得所有待诊断部件的故障状态：

$$F_i = g_i(\mathbf{S}) \quad (i = 1, 2, \dots, n) \quad (3-4)$$

为了解决具有多标签的故障诊断问题，需要解决以下挑战：1) 如何利用领域从多个部件的复杂振动信号中全面获取齿轮箱整体信息和运行状态；2) 如何构造深度学习网络实现变速箱不同部件的特征提取和故障分类。

本章提出了一种基于综合信息矩阵和并行多任务卷积神经网络的齿轮箱耦合故障诊断方法。该方法将更多的故障相关信息集成到输入中，并合理使用深度学习算法的灵活网络结构。图 3-11 说明了该方法的过程，主要步骤描述如下：

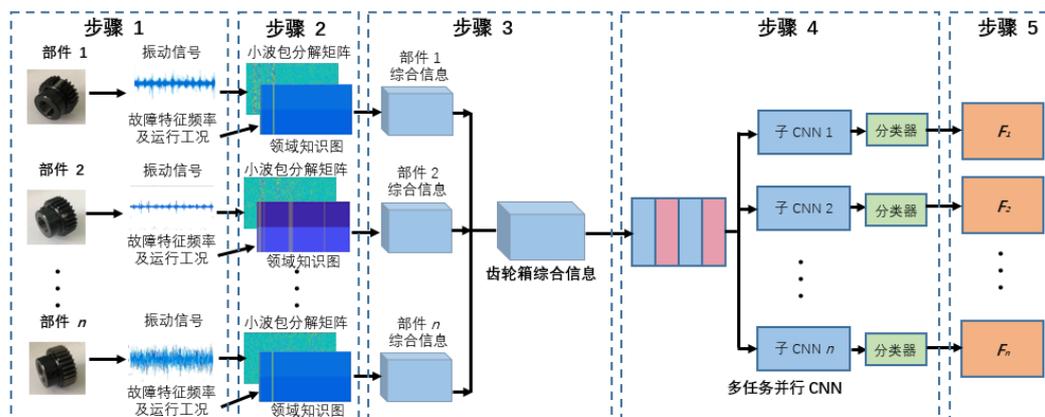


图 3-11 齿轮箱耦合故障诊断方法流程图

步骤 1: 在风电机组齿轮箱的不同位置安装多个加速度传感器, 以采集多个齿轮箱部件的振动信号。记录操作条件, 包括输入轴的负载和转速。

步骤 2: 使用小波包分解获得来自不同加速度计的振动信号的小波包分解矩阵。根据齿轮箱结构和部件故障机制, 建立每个部件的信息图。然后将操作条件添加到信息图, 以形成领域知识图。

步骤 3: 将每个部件的领域知识图与相关加速计的小波包分解矩阵组合, 以形成组件的综合信息矩阵。然后, 组合不同部件的综合信息矩阵, 以获得齿轮箱的综合信息矩阵。

步骤 4: 构建用于耦合故障诊断的多任务并行 CNN 模型。根据输入大小和组件数量设置多任务并行 CNN 模型, 使用训练样本的对模型进行训练。

步骤 5: 将训练后的模型部署到风电机组的在线监测系统。使用相同的方法处理数据, 并对风电机组齿轮箱进行故障诊断。

3.3.2 齿轮箱综合状态信息矩阵构造

为了表示齿轮箱的整体状态信息, 本方法将振动信息、领域知识和不同部件的运行工况组合起来, 形成齿轮箱综合信息矩阵。由于多个加速度传感器安装在齿轮箱的不同位置, 对不同部件具有不同的灵敏度。因此, 如图 3-11 所示, 首先将每个部件的领域知识图与相应加速度传感器的信号的小波包分解组合, 以获得部件的综合信息矩阵。然后, 通过组合不同部件的综合信息矩阵, 获得齿轮箱的综合状态信息矩阵。

(1) 振动信息表示

由于齿轮箱采用多级传动, 齿轮和轴承的旋转频率、啮合频率和故障特征频率分布范围很广。此外, 由于齿轮箱的故障信号总是作为非平稳信号, 因此时频域分析方法更适合将齿轮箱的振动数据转换为深度学习输入。本文选择小波包分解作为齿轮箱振动数据信息表示的基本分析方法。与其他时频域分析方法, 如连续小波变换和短时傅里叶变换相比, 小波包分解具有统一的时频域分辨率, 小波包分解中的小波基函数能够分析齿轮箱中通常以冲击信号或边频带形式出现的故障信号。

在小波包分解的计算中, 输入信号被一组高通和低通滤波器分解为高频部分和低频部分。在每次分解后, 小波包分解基于小波函数再次将振动信号分解为高频和低频, 从而可以提取局部信号中的高频信息。

$$\begin{aligned} c_j^{2^m}(k) &= \sum_n a_n c_{j-1}^m(2k-n) \\ c_j^{2^{m+1}}(k) &= \sum_n b_n c_{j-1}^m(2k-n) \end{aligned} \quad (3-5)$$

式中, $c_j^{2^m}(k)$ 第 j 个小波包分解层后第 m 个频带的第 k 个系数, a_n 是第 n 个高通滤波器, b_n 是第 n 个低通滤波器。每个小波包分解操作将信号长度减半。在具有 l 个点的信号的 N 层小波包分解后, 获得 $2N$ 个频带。记采样频率为 f , 则每个频带的宽度为 $f/2^{N+1}$ Hz。对应于第 i 频带 c_N^i 的系数的频率范围 R_i 为:

$$f/(2^{N+1}(i-1)) \leq R_i \leq f/(2^{N+1}i) \quad (3-6)$$

从所有小波包分解树节点获得的小波包系数根据频率排列并组合成矩阵, 称为小波包分解矩阵, 表示为 \mathbf{M} :

$$\mathbf{M} = [c_N^{1T}, c_N^{2T}, \dots, c_N^{2^N T}] \quad (3-7)$$

式中, T 为矩阵转置, 因此, \mathbf{M} 在时间维度上的长度为 $p = \frac{j}{2^N}$, 在频率维度上的长度为 $q = 2^N$ 。

综上, 小波包分解矩阵作为振动信息的表示输入深度学习算法。根据与齿轮箱故障相关的频率范围, 我们可以保留小波包分解矩的前几列。图 3-12 是安装在齿轮箱上的加速传感器信号的小波包分解矩阵, 该加速传感器在太阳齿轮裂纹和平行轴齿轮根部裂纹的耦合故障下。Dmey 小波被用作小波基, 进行了 9 层的小波包分解, 要分析的齿轮箱的最大频率低于 2 kHz, 因此选择小波包分解矩阵的前 256 列。

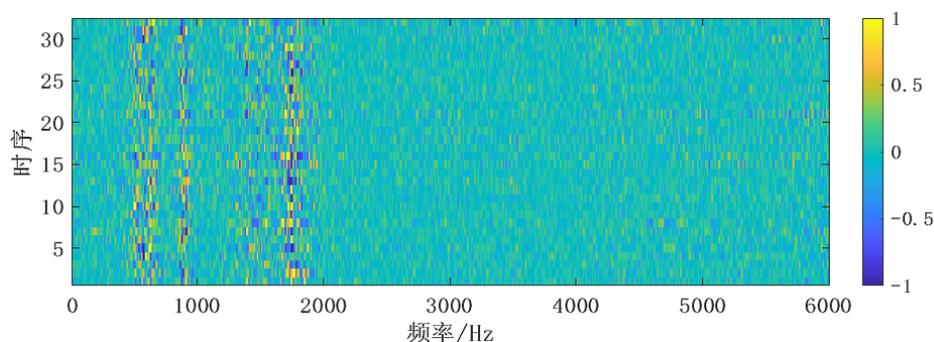


图 3-12 小波包分解矩阵

(2) 考虑运行工况的领域知识图

当将深度学习算法应用于新领域时, 作为目标领域的知识, 领域知识表示了数据的特征分布和内部关系。在不考虑领域知识的情况下建立的深度学习模型完全是数据驱动的, 鲁棒性较差。一旦数据分布发生变化, 模型的准确性将显著降低^[92]。因此, 对于齿轮箱中的常见部件, 如行星齿轮系、平行轴齿轮系和轴承, 本节提出了一种领域知识图构造方法, 以帮助诊断齿轮箱故障, 主要步骤如下所述。

故障特征频率是部件故障时振动信号中出现的频率, 可通过动态分析和数值模拟获得。当将信号分析应用于齿轮箱故障诊断时, 大多数现有方法通过从振动信

号中提取对应于故障特征频率的幅值来识别故障类型[93][94]，有必要以故障特征频率作为领域知识来指导深度学习算法的特征提取过程。因此，通过分析行星齿轮系、平行轴齿轮系和轴承的故障机理，以获得基于传动关系的齿轮箱故障特征频率。

首先，对于行星齿轮系，由于齿轮上的局部故障一旦啮合到故障位置就会发出脉冲信号，因此参考文献^[95]获得了齿轮的旋转频率、啮合频率和故障特征频率：

$$\begin{aligned}
 f_p &= f_s(Z_p - Z_r)Z_s / ((Z_r + Z_s)Z_p) \\
 f_H &= f_s Z_s / (Z_r + Z_s) \\
 f_{m0} &= Z_p(f_H - f_p) = Z_s(f_s - f_H) \\
 f_{sf} &= K f_{m0} / Z_s \\
 f_{pf} &= f_{m0} / Z_p \\
 f_{rf} &= K f_{m0} / Z_r
 \end{aligned} \tag{3-8}$$

式中， Z_s 、 Z_p 、 Z_r 分别为太阳轮、行星轮和齿圈的齿数， K 是行星轮个数。 f_H 、 f_s 、 f_p 、 f_r 分别为行星架、太阳轮、行星轮和齿圈转频， f_{sf} 、 f_{pf} 、 f_{rf} 分别为行星架、太阳轮、行星轮和齿圈的故障特征频率， f_{m0} 为行星轮系的啮合频率。

然后，对于平行轮系，齿轮的转频、啮合频率和故障特征频率可由下式计算：

$$\begin{aligned}
 f_{m1} &= f_{in} Z_1 = f_{out} Z_2 \\
 f_{1f} &= f_{in} \\
 f_{2f} &= f_{in} Z_1 / Z_2
 \end{aligned} \tag{3-9}$$

式中， Z_1 、 Z_2 分别为主动轮和从动轮的齿数， f_{in} 、 f_{out} 分别为主动轮和从动轮的转频， f_{1f} 、 f_{2f} 分别为主动轮和从动轮的故障特征频率， f_{m1} 为平行轮系的啮合频率。

最后，轴承的故障特征频率可由下式计算：

$$\begin{aligned}
 f_{IR} &= f_r \times \frac{Z(1 - \frac{d}{D} \cos \alpha)}{2} \\
 f_{OR} &= f_r \times \frac{Z(1 + \frac{d}{D} \cos \alpha)}{2} \\
 f_{BA} &= f_r \times \frac{D(1 - (\frac{d}{D} \cos \alpha)^2)}{2d}
 \end{aligned} \tag{3-10}$$

其中， f_{IR} 、 f_{OR} 和 f_{BA} 分别为轴承内圈、外圈和滚动体的故障特征频率， f_r 为轴承旋转频率， Z 为滚动体个数， d 为滚动体直径， D 为节圆直径， α 为接触角。

在获得齿轮箱部件的故障特征频率后，通过构造与小波包分解矩阵大小相同的矩阵，并在其中表明故障特征频率和运行工况信息来构建领域知识图。对于轴承的故障，需要标记出 f_{BA} 、 f_{IR} 、 f_{OR} ，及其以转频为间隔的边频带，将其统一标记为 f_{BCF} 。当齿轮发生故障时，振动信号中会出现与转频 f_r 相同的故障特征频率 f_{gf} ，同时引起转频及其倍频幅值增大，故障严重时还会在啮合频率 f_m 附近出现以转频为间隔的边频带。因此，在齿轮信息图的构造中，应首先标出故障特征频率和啮合频率，并在啮合频率两侧标出边频带的位置，对轮系中单个齿的故障，所有需要标注的频率有： f_{gf} 、 f_m 、 $f_m + f_r$ 、 $f_m - f_r$ ，将其统一标记为 f_{GCF} 。

由于在小波包分解矩阵中，每一列对应的值表示了在一定频段内的振动能量，我们在领域知识图中标识出对应到故障特征频率 f_{BCF} 和 f_{GCF} 的列：

$$v_{i,j} = 1 \quad (1 \leq i \leq p, j = j_{BCF} \text{ or } j_{GCF}) \quad (3-11)$$

其中 $v_{i,j}$ 是领域知识图在坐标 (i, j) 处的值， j_{BCF} 和 j_{GCF} 分别是对应频率 f_{BCF} 和 f_{GCF} 的列，分别用来构造轴承和齿轮的领域知识图。

由于风电机组具有复杂多变的运行条件，向领域知识图映射添加运行工况信息可以指示系统状态，并增强可变功率运行条件下故障诊断模型的鲁棒性。为了标记运行条件信息，对速度和负荷进行分级和归一化，然后分别用领域知识图上半部分和下半部分的背景值表示：

$$g_{i,j} = -\frac{u}{l_{Load}} \quad (1 \leq i \leq \frac{p}{2}, 1 \leq j \leq q)$$

$$g_{i,j} = -\frac{w^2}{l_{Load}} \quad (\frac{p}{2} \leq i \leq p, 1 \leq j \leq q) \quad (3-12)$$

式中， $g_{i,j}$ 为领域知识图在坐标 (i, j) 处的背景值， u 为负载等级， w 为转速等级， l_{Load} 和 l_{speed} 分别为负载和转速的总级数。

图 3-13 显示了由图 3-12 中的加速度振动传感器监测的太阳齿轮的领域知识图，其尺寸为 32×256 。图中的黄线为标记的 f_{GCF} ，图下部和上部的背景值分别为 0.75 和 1，分别表示了负载和转速水平。

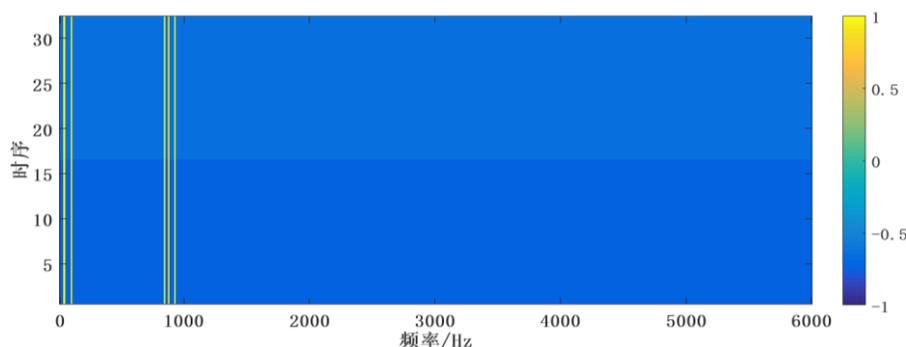


图 3-13 领域知识图

在深度学习网络输入构造时，每个传感器的振动信号首先与对应部件的部件信息图相结合，得到该部件的综合信息矩阵。再将不同部件的综合信息矩阵进行组合，得到多部件的多维异构信息。

3.3.3 基于强化输入的多任务平行卷积神经网络

如上所述，多个组件的耦合故障诊断是具有多标签的分类问题。同时，大多数提出的故障诊断深度学习模型只能执行单个分类任务，多个组件的各种故障特征必须共享相同的特征提取过程，因此难以同时充分提取到所有部件的故障特征。为了解决这个问题，本文提出了一种新的基于强化输入的多任务平行 CNN 进行齿轮箱耦合故障的诊断。

(1) 网络结构

基于强化输入的多任务并行 CNN 的结构如图 3-14 所示，主要包括综合信息提取模块、并行特征提取模块和多任务分类模块， F_i 表示第 i 个部件的故障情况。

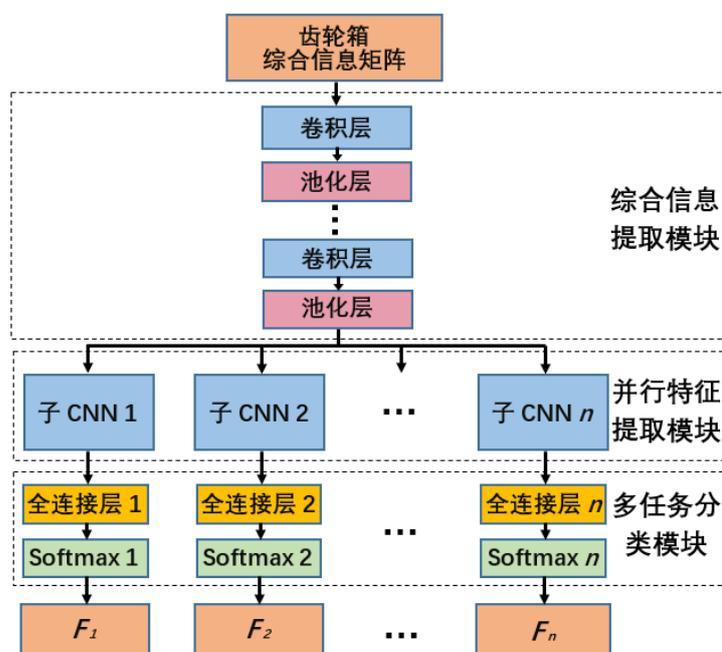


图 3-14 基于强化输入的多任务并行 CNN 的结构图

综合信息提取模块以多维异构多部件信息矩阵作为输入，使用多阶卷积层和池化层的组合对输入矩阵中通用特征信息进行提取和约简，其中卷积层的公式为：

$$x_j^t = \theta(x^{t-1} * k_j^t + b_j^t) \quad (3-13)$$

式中， x_j^t 是第 t 个卷积层后获得的第 j 个特征图， x^{t-1} 是第 $t-1$ 个卷积层后获得的特征图， k_j^t 为卷积核， b_j^t 为偏置。

并行特征提取模块由多个并行的 CNN 子网络构成，使用多个并行的卷积池化

层对综合信息提取模块得到的通用特征图进行分别的特征提取，以得到不同部件的故障特征信息，便于进行多分类。为了增强综合信息提取模块中可能遗漏的部件信息，相应部件的综合信息矩阵被用作子 CNN 的增强输入，如图 3-15 所示。

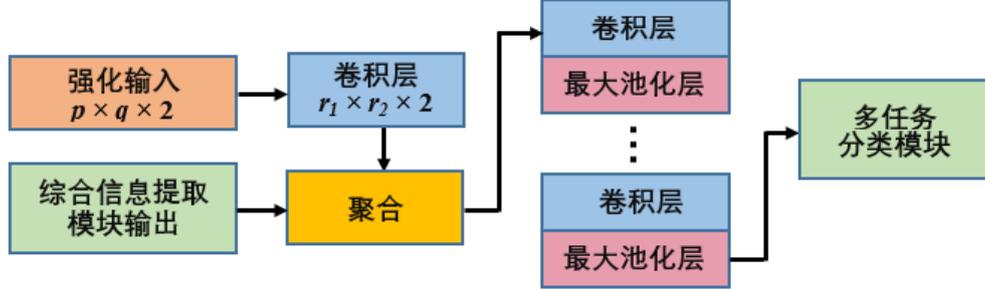


图 3-15 子 CNN 模块结构

为了使综合信息矩阵具有与先前提取的特征相同的大小，在综合信息矩阵上执行卷积操作，第 i 个子 CNN 的输入通过以下方式获得：

$$R_j^i = \theta(C_i * W_j^i + b_j^i)$$

$$X^i = \text{cat}(H, R^i) \quad (3-14)$$

其中， C_i 是第 i 个部件的信息矩阵，大小为 $p \times q \times 2$ ， W_j^i 是卷积核，大小为 $r_1 \times r_2 \times 2$ ， X^i 是第 i 个子 CNN 的输入， H 是由综合信息提取模块获得的特征， $\text{cat}(\cdot)$ 是第三维矩阵合并的操作。为了保证卷积层后的特征图 R^i 与 H 大小相同，步长 o_1 、 o_2 与 r_1 、 r_2 相同，可通过下式获得：

$$o_1 = r_1 = \prod_{k=1}^m p_1^k, o_2 = r_2 = \prod_{k=1}^m p_2^k \quad (3-15)$$

其中， m 是综合信息提取模块中的卷积层个数， p_1^k 、 p_2^k 分别是第 k 个池化层的两个方向上的池化参数。

多任务分类模块利用并行特征提取模块得到的故障特征，分别对每个部件的故障进行分类，获得其故障状态。该方法使用 Softmax 分类器，其公式如下：

$$P_k^i = \frac{e^{s_k^i}}{\sum_{j=1}^{J^i} e^{s_j^i}} \quad (3-16)$$

其中， P_k^i 是部件 i 故障状态 k 的概率， s_k^i 是第 i 个全连接层的第 k 个输出， J^i 是部件 i 的故障状态数。

(2) 网络训练

在多任务 CNN 的训练过程中，前向传播过程中的卷积和池层计算与普通 CNN 相同，分类结果由多个 softmax 分类器获得。在反向传播过程中，总损失函数应为多个分类任务的分类损失之和。然而，由于不同的任务可能具有不同的收敛速度，

因此经常使用相同的损失率可能会导致某些任务的过拟合和其他任务的欠拟合。为了使所有分类任务具有相同的收敛率，提出了一种自适应损失算法。每个分类器的权重根据每个子 CNN 的训练进度在每个训练步骤中变化。在这个意义上，具有较大损失函数值的分类器将接收较大梯度以获得更快的收敛。

3.3.4 诊断实验及结果分析

为了评估所提出方法的性能，本节基于带有耦合故障的齿轮箱案例进行了实验。在案例研究中，所有深度学习模型的训练都由 tensorflow 在 Python 环境中在一台具有两个 E5-2667 v3 CPU、一个 GTX1080Ti GPU 和 64 GB 内存的计算机上进行。

PHM 2009 数据集^[96]注重于通用齿轮箱的故障检测任务，数据集中的装置示意图如图 3-16 所示，故障注入的部件为红色，即输入轴、中间轴承、输入轴轴承和 24T 齿轮。两个加速度振动传感器用于同步采集振动数据。齿轮箱数据在 6 种故障条件下进行采集，采样频率为 66.7 kHz。

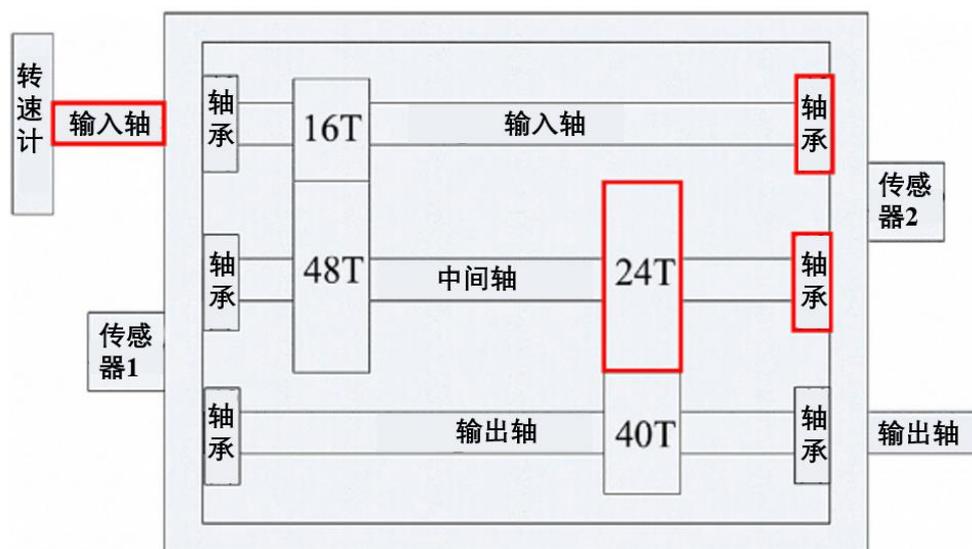


图 3-16 齿轮箱结构图

表 3-6 列出了所有故障条件下 4 个部件的详细故障状态。在每种故障条件下，有 10 种工况，它们是 2 个负载级别（即低和高）和 5 个速度级别（即 30Hz、35Hz、40Hz、45Hz、50Hz）的组合。从每个故障条件下每个工况的采集数据中，提取了各 16384 个采样点的 52 个样本。因此，每个故障条件下获得 520 个样本。对于所有故障条件，共有 3120 个样本。数据样本被分成 5 个数据集 1 至 5，用于交叉验证。在数据集的每个组合中，有 2496 个训练样本和 624 个测试样本。

表 3-6 耦合故障情况

故障状态	24T 齿轮	输入轴轴承	中间轴轴承	输入轴
1	正常	正常	正常	正常
2	齿根裂纹	正常	正常	正常
3	断齿	组合故障	内圈	轴弯曲
4	正常	组合故障	滚动体	不平衡
5	断齿	正常	内圈	正常
6	正常	正常	正常	轴弯曲

在综合信息矩阵的构建中，将振动样本进行 9 层小波包分解，以获得尺寸为 32×256 的小波包分解矩阵。齿轮和轴承的领域知识图标记了齿轮和轴承的故障特征频率，并与加速度传感器 1 的小波包分解矩阵融合。轴的领域知识图标记了转速的倍频，并与加速度传感器 2 的小波包分解矩阵进行融合。因此，获得大小为 $32 \times 256 \times 8$ 的综合信息矩阵，作为多任务并行 CNN 的输入，综合特征提取模块具有 3 个卷积层和池化层，并行特征提取模块由 4 个子 CNN 组成，带有 4 个 softmax 分类器的多任务分类模块可同时获得 4 个部件的故障状态。

在训练过程中，学习率设置为 0.0001。多提出多任务诊断模型在大约 100 个训练步骤后实现收敛。对于每个数据集组合进行 10 次重复训练，交叉验证中所有组件的诊断结果如表 3-7 所示。

表 3-7 所有部件的故障诊断准确率

测试集	24T 齿轮	输入轴轴承	中间轴轴承	输入轴
1	$100 \pm 0\%$	$99.46 \pm 0.08\%$	$100 \pm 0\%$	$99.26 \pm 0.12\%$
2	$99.87 \pm 0.08\%$	$99.52 \pm 0\%$	$100 \pm 0\%$	$99.01 \pm 0.10\%$
3	$100 \pm 0\%$	$99.26 \pm 0.10\%$	$100 \pm 0\%$	$99.26 \pm 0.16\%$
4	$99.97 \pm 0\%$	$99.52 \pm 0\%$	$100 \pm 0\%$	$99.30 \pm 0.08\%$
5	$100 \pm 0.06\%$	$99.20 \pm 0.16\%$	$100 \pm 0\%$	$99.60 \pm 0.08\%$

可以看出，在交叉验证中所有数据集组合对所有齿轮箱部件都具有较高且稳定的精确度，这意味着模型没有过拟合。与文献^[97]中使用相同数据集的结果相比，即 MLCNN 的 $94.02 \pm 0.75\%$ 和随机森林的 $96.79 \pm 1.45\%$ ，提出的方法具有更高的精度。

3.4 本章小结

本章提出了基于深度学习的新型电力系统传输线路及发电设备的故障诊断方法。基于改进的 GCN 的新型电力系统故障诊断新方法通过考虑分布式发电系统的拓扑结构和波动性, 改进了被首次引入电力系统故障诊断领域的 GCN。在 GCN 中邻接矩阵的指导下, 从在 PMU 监测数据中提取和融合电力系统节点的特征。利用基于电力线路特征, 分别构造了三个任务输出, 实现电力系统的准确故障检测、识别和定位。对于发电设备的故障诊断, 提出了一种基于多任务并行 CNN 的齿轮箱耦合故障诊断方法, 通过构造及融合设备领域知识图和振动监测数据, 实现了齿轮箱多部件的同步故障诊断。

4. 基于强化学习的新型电力系统电压稳定控制

4.1 引言

分布式能源的增加使新型电力系统更容易出现各种发电和随机负载的电压稳定性问题，电压不稳定可能导致大规模电力系统停电和巨大的经济损失。为了解决这个问题，前面章节中提出了新型电力系统的状态评估和故障诊断方法，进一步地，本章结合强化学习算法，开展了故障及扰动情况下电压稳定控制方面的研究。

在实际电力系统系统中，通常使用静态无功补偿器和静态无功发生器（Static Var Compensator / Static Var Generator, SVC/SVG）等无功补偿装置来优化无功功率控制。这些装置通常采用反馈控制方法，根据母线电压偏差确定要投入的无功补偿。它可以有效地处理轻微的电压不稳定性，但在出现会导致电压骤降的故障条件时无法及时响应^[98]。同时，由于 SVC/SVG 仅从最近的总线接收收集的信息，因此无法实现整个电力系统的无功优化^[99]。

由于新型电力系统的信息化和智能化，使得我们可以充分利用收集到的丰富数据来保证其的安全运行。基于收集的实时数据，电力系统中的电压稳定性优化可以转化为最优控制问题^[100]。最优控制值可以通过求解方程^{[101][102]}或使用启发式算法^{[103][104]}获得。文献^[105]提出了一种非线性控制方法，通过协调风力发电机和静态同步补偿器来确保电力系统的电压暂态稳定性。然而，面对新型电力系统中发电量和负载的动态变化，这些方法的计算速度不够快，无法支持在线优化，并且可能会陷入局部极值，从而导致无法获得最优解。同时，简化方程不能真正反映电力系统的准确状态，尤其是在干扰引起的电压暂降期间。

近年来，随着人工智能方法的快速发展，深度强化学习（Deep Reinforcement Learning, DRL）已应用于电力系统的许多控制问题，如可再生能源存储^[106]、能源管理^[107]和能源交易^[108]。然而，上述 DRL 方法仅将监测数据作为深度学习输入，完全是数据驱动的。作为新型电力系统领域知识的拓扑信息没有得到适当考虑，这导致深度学习方法的鲁棒性较差，尤其是在多变的负载可变发电量下。电力系统拓扑表示节点之间的互连，还可以帮助精确确定所需的无功功率补偿。

在前面章节中，基于 GCN 已经实现了新型电力系统的状态评估和故障诊断，且取得了不错的效果。然而，GCN 只能处理连接权重恒定的常数的邻接矩阵，而邻接矩阵随系统状态而变化。图形注意力网络（Graph Attention Networks, GAT）^[109]可以基于实时数据重新计算连接权重，计算机视觉^[110]、遥感^[111]、甚至机械故障诊断^[112]等领域的应用表明了 GAT 处理动态图形的能力。动态图这也与功率流随

能量互联网动态平衡而变化的情况相对应。

因此，为了充分利用新型电力系统的信息化和领域知识，本文将 GAT 引入到故障状态下的无功优化中。提出了一种基于 GAT 和深度强化学习的电压稳定无功优化新方法。该方法利用邻接矩阵表示的电力系统拓扑和 GAT 中的图卷积运算，并根据现场实际的数据采集情况，结合第二章中的异构数据融合方法，基于异构的 SCADA 和 PMU 数据，融合并提取每个电力系统节点及其相邻节点的监测数据中的特征。最终使用深度强化学习方法使每个 SVG 节点的控制协同得到了最优的无功补偿控制效果。

4.2 基于多主体强化学习的无功补偿协同控制方法

基于电网架构，新型电力系统集成了信息和电力电子技术，将多种分布式发电和储能设备连接到电网。然而，分布式发电的可变性给可再生能源的有效利用和供需平衡带来了很大困难。图 4-1 显示了一个基于 IEEE30 节点模型的新型电力系统，该系统包括可变发电设备，例如火力发电厂、光伏发电和风力发电机等，也连接着多种变化的负载，如工厂、学校等。所有母线、负载和发电机都视为电力系统节点，数据采集设备放在每个节点上，以收集实时数据，从而形成新型电力系统的信息流。当新型电力系统中发生大扰动或故障时，母线中可能会出现暂态电压不稳定的问题，因此，如何合理配置电压暂降后的无功补偿是本章要解决的主要问题。同时，由于无功功率的远距离传输会带来较大的功率损失，因此有必要在多个关键节点配置无功功率设备。例如，在图 4-1 中，无功功率设备安装在母线 6、母线 12 和母线 10 上。因此，如何协同控制多个无功功率补偿装置以确保新型电力系统中所有节点的稳定性是本章的研究重点。

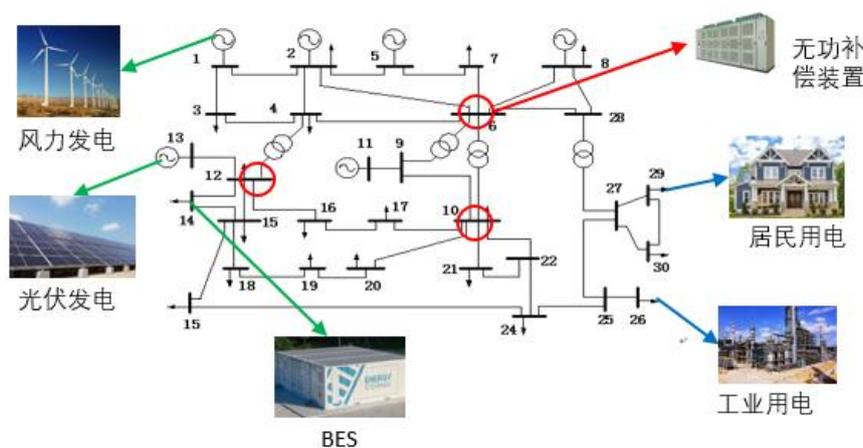


图 4-1 新型电力系统结构图

然而，为了实现准确的全区域无功补偿，需要对电网所有节点的瞬态数据进行

高频实时采集。在真实场景中，无法将所有节点即使是安装有 SVG 节点的实时采样数据集中到中央控制器中，做出统一的无功补偿决策。这是因为暂态电压失稳发生在几秒钟内，但由于通信速率和距离的限制，在数据收集、形成策略和策略下发后，电网可能已经因电压不稳定而引发严重事故。因此，需要提供一个分布式的，在每个边缘设备上可以独立决策的无功补偿协同机制。

为了解决上述问题，基于多智能体深度强化学习和图注意力网络，本章提出了一种新的无功补偿协调优化方法，用于新型电力系统在电压骤降期间的电压稳定性。图 4-2 显示了所提出方法的流程图，其详细步骤描述如下：

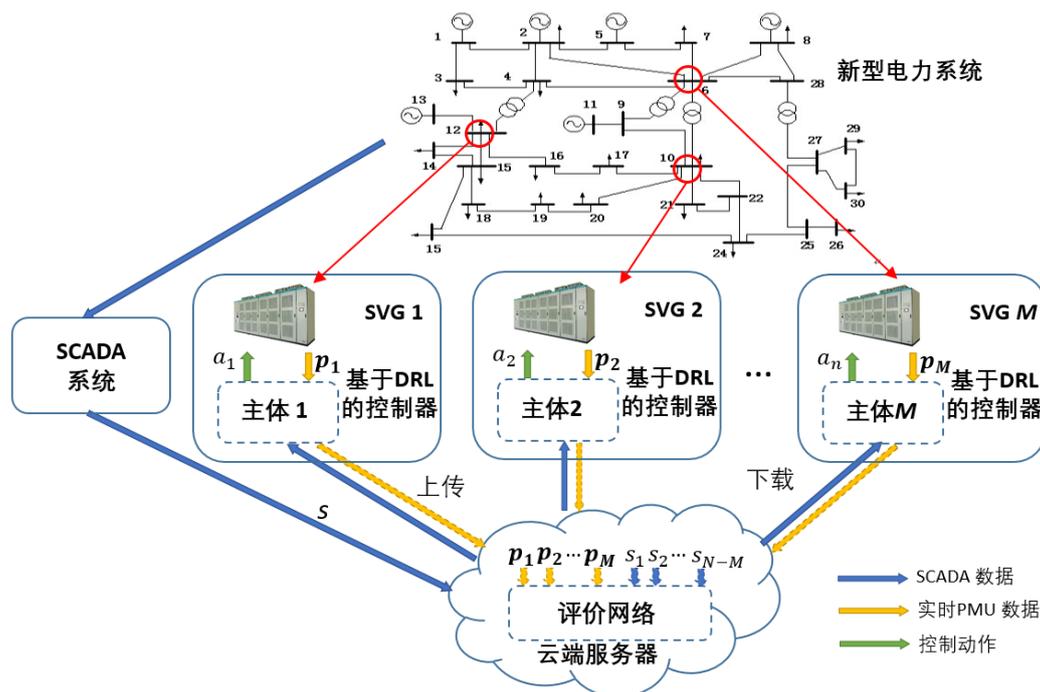


图 4-2 无功补偿系统优化流程图

(1) 新型电力系统模型的构建

由于深度强化学习的训练采用试错策略，很难在实际系统上进行完全的在线训练。因此，除了在实际电力系统中收集的数据外，还需要进行数值模拟，以获得更多的无功补偿装置和电力系统之间交互数据。将采集的新型电力系统节点现场数据作为初始潮流数据，将扰动和故障注入电力系统模型，以模拟系统中的暂态电压过程。

(2) 新型电力系统状态获取

为了实现无功优化，需要获取电力系统电压暂降期间完整的状态信息。然而，PMU 等设备采集的高频监测数据受限于数据量和网络传输效率，节点之间很难共享高频 PMU 数据。同时，为了使安装有 SVG 的控制器节点可以结合其他电力系

统节点的状态做出更准确的无功补偿决策，SVG 控制器节点会获取其他所有节点的低频 SCADA 数据，并尽可能及时的进行更新。PMU 的实时监测数据包括一段时间内的有功功率、无功功率、频率和三相电压， T 个时间点的数据将组合成矩阵 $S \in \mathbb{R}^{T \times 6}$ 作为 SVG 控制器节点的状态。非 SVG 控制节点 SCADA 采集状态数据包括有功功率、无功功率、频率和三相电压的某一时刻的有效值。

(3) 基于门控循环单元和 GAT 的特征提取

每个 SVG 控制器以电压暂降期间的电力系统状态为输入，状态数据包括本地节点采集的 PMU 数据和其他所有节点的 SCADA 数据，如图 4-2 所示。首先，门控循环单元（Gated Recurrent Unit, GRU）用于从 PMU 监测时间序列数据中提取时序特征。然后，考虑电力系统拓扑，构建 GAT 网络，以电力系统节点为图顶点，以电力系统中的电力线为图的边，结合 GRU 的输出和其他节点的 SCADA 数据中提取电力系统的总体特征。

(4) 多主体深度强化学习模型的构建

构建了基于深度强化学习 Advantage Actor-Critic (A2C) 方法的多主体强化学习模型，以获得无功补偿协同优化策略。基于 GAT 提取的特征，多主体强化学习模型中的多个 SVG 控制器分别构建 Actor 网络，以生成多个无功功率补偿装置的最优输出。然后，结合所有节点的 SCADA 数据和所有 SVG 控制器节点的 PMU 数据，输入 GRU 和 GAT 网络，构建 Critic 网络，用于评估无功补偿的效果。

(5) 多主体深度强化学习模型的离线训练

在多主体深度强化学习模型的离线训练期间，每个 SVG 控制器的本地网络将可以获得的状态数据作为输入，并给出无功补偿动作。然后，基于新型电力系统模型，将多个 SVG 控制器给出的无功功率补偿策略施加到电力系统模型，并进行状态转换以获得控制后的电力系统新状态，并对新状态进行评价，给出控制动作的奖励。最后根据奖励值，对 Actor、Critic、GAT 和 GRU 网络进行反向传播，训练多主体深度强化学习模型。

(6) 多主体控制模型的在线部署运行

将经过训练的多主体深度强化学习模型在每个 SVG 控制器处进行在线部署，将监测数据中的电力系统状态作为输入。如果检测到电压骤降，多主体深度强化学习模型将给出无功补偿装置的优化输出，以确保新型电力系统的电压稳定性。

4.3 无功协调优化的多主体深度强化学习框架

为了使所有无功补偿控制器都能准确感知新型电力系统的运行状态，并给出合理的无功补偿策略，本文提出了一种基于 GRU 和 GAT 的多主体深度强化学习

框架。在该框架中，使用 GRU 感知高频 PMU 采样节点的实时状态，GAT 根据电力系统拓扑结构进行信息提取和融合，得以准确评估整个新型电力系统的综合安全状态。最后，提供完整的培训训练和实施计划，以获得准确的评估模型和控制策略。

4.3.1 基于 GRU 和 GAT 的新型电力系统状态感知

(1) 门控循环单元 (GRU)

由于故障引起的新型电力系统电压暂降是一个在态过程，因此从 PMU 终端采集的数据呈时间序列形式。为了更好地感知电压暂降过程，将 GRU 引入到多通道监测数据的序列特征提取中。

作为长短时记忆 (Long short-term memory, LSTM) 的高级版本，GRU 通过减少 LSTM 的门来提高计算效率。GRU 的结构如图 4-3 所示。 \mathbf{z}^t 和 \mathbf{r}^t 分别是更新门和重置门，它们替换 LSTM 中的原始输入门、忘记门和输出门。GRU 的输入 \mathbf{x}^t 是 t 时刻的数据， \mathbf{h}^{t-1} 表示在 $t-1$ 时刻提取的特征，并且输出 \mathbf{h}^t 是 GRU 提取得到的 t 时刻的数据特征。

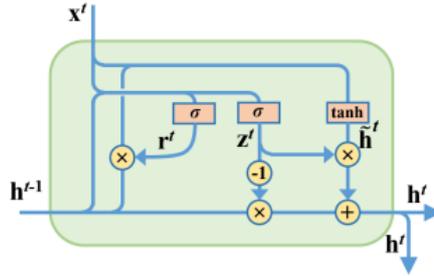


图 4-3 一个门控循环单元的结构

因此，GRU 单元的正向传播过程被定义为：

$$\mathbf{h}^t = (1 - \mathbf{z}^t) \odot \mathbf{h}^{t-1} + \mathbf{z}^t \odot \tilde{\mathbf{h}}^t \quad (4-1)$$

$$\mathbf{z}^t = \sigma(W_z \mathbf{x}^t + U_z \mathbf{h}^{t-1}) \quad (4-2)$$

$$\tilde{\mathbf{h}}^t = \tanh(W \mathbf{x}^t + U(\mathbf{r}^t \odot \mathbf{h}^{t-1})) \quad (4-3)$$

$$\mathbf{r}^t = \sigma(W_r \mathbf{x}^t + U_r \mathbf{h}^{t-1}) \quad (4-4)$$

其中， W_z 和 U_z 分别是针对 \mathbf{x}^t 和 \mathbf{h}^{t-1} 的更新门的权重。类似地， W_r 和 U_r 分别是重置门的权重， W 和 U 是重置后保留特征的权重。 $\tilde{\mathbf{h}}^t$ 是隐藏层特征。 \odot 表示按元素的乘法运算。从 (4-1) 到 (4-4) 可以看出，更新门 \mathbf{z}^t 控制了前一时间步特征 \mathbf{h}^{t-1} 和当前隐藏特征 $\tilde{\mathbf{h}}^t$ 的组合比率，从而实现了时间序列信息的特征提取。

(2) 图注意力网络 (GAT)

如前文所述，考虑到新型电力系统中多个节点互连的拓扑结构，新型电力系统

的节点监测信息是一种图结构的数据形式，使用 GCN 对其进行特征提取可以取得不错的效果。但是，在线路故障引起的电压暂降期间，电力系统节点之间的阻抗会发生变化，这也会影响节点之间的连接关系。因此，本章引入了基于图拓扑和注意机制的 GAT 来实现故障过程中电力系统信息的精确特征提取。

考虑一个具有 N 个节点 $v_i \in \mathcal{V}$ 、 K 个边 $(v_i, v_j) \in \mathcal{E}$ 的无向图 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ ，构造邻接矩阵 $A \in \mathbb{R}^{N \times N}$ 来表示图的拓扑结构，构造度矩阵 $D_{ii} = \sum_j A_{i,j}$ 来表示节点的度。图卷积操作定义为：

$$y = \sigma(g_\theta(A)x) \quad (4-5)$$

其中， y 是节点的输出特征， g_θ 是图卷积核。 $g_\theta(A)$ 表示 g_θ 在 A 上的卷积运算。 x 是输入节点特征， $\sigma(\cdot)$ 是激活函数。

从(4-5)可以看出，图卷积运算基于固定邻接矩阵融合了互连节点的特征。然而，在很多情况下，所有值均为 1 的或者如 (2-3) 中基于谱分析邻接矩阵无法实时反映相邻节点对每个节点的重要性变化。例如在本章中的场景中，电力系统节点的连接关系在故障发生后发生变化。同时，不同潮流功率的线路对电力系统节点的影响也明显不同。因此，本章引入 GAT 进行电力系统特征提取，通过在 GCN 中引入的注意机制，GAT 根据节点的输入特征获得动态的节点连接关系。

在图注意力层中，在图卷积运算之前，需要构造一个多输出的注意力模块以获得动态邻接矩阵。首先，通过以下公式计算第 k 个注意力输出的所有连接节点之间的注意力系数：

$$e_{i,j}^k = a_k^T [W^k x_i \parallel W^k x_j] \quad (4-6)$$

其中， $x_i \in \mathbb{R}^{M_0}$ 表示第 i 个节点的输入特征。 $W^k \in \mathbb{R}^{M_1 \times M_0}$ 和 $a_k \in \mathbb{R}^{2M_1}$ 分别是第 k 个注意力输出的权重矩阵和注意机制矩阵。 $e_{i,j}^k$ 表示第 k 个注意力输出的第 i 个和第 j 个节点之间的注意系数。 T 表示转置运算， \parallel 是合并运算。

然后，注意力系数通过以下方式归一化：

$$\alpha_{i,j}^k = \frac{\exp(e_{i,j}^k)}{\sum_{h \in \mathcal{N}_i} \exp(e_{i,h}^k)} \quad (4-7)$$

其中， \mathcal{N}_i 是第 i 个节点在图中相邻节点的集合。 $\alpha_{i,j}^k$ 是第 k 个注意力输出在新的邻接矩阵 (i,j) 处的数值。

最后，图注意力层的输出特征由多个注意力输出的所有新邻接矩阵上的图卷积之和计算得到：

$$y_i = \sigma\left(\frac{1}{H} \sum_1^H \sum_{h \in \mathcal{N}_i} \alpha_{i,j}^k W^k x_i\right) \quad (4-8)$$

其中， y_i 代表第 i 个节点的输出特征， H 是注意力输出的个数。

图 4-4 示出了具有三个注意输出的图形注意力层的结构。本章使用的 GAT 模型具有多个堆叠图注意层，以获得节点的最终特征。在每个图注意层之后，根据注意机制获得的相邻矩阵，通过组合相邻节点的信息来更新每个节点的特征。

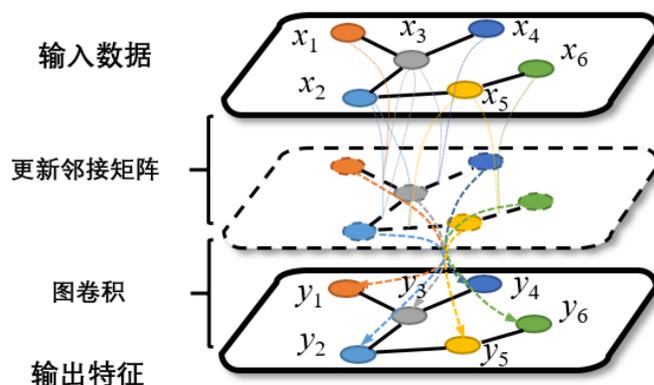
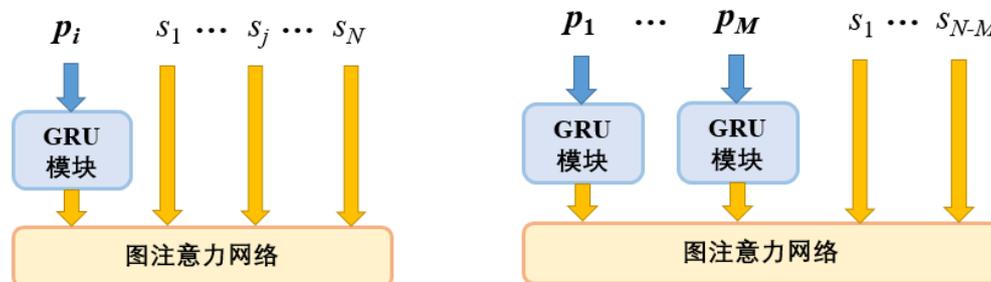


图 4-4 图注意力网络结构

(3) DRL 主体和中心云服务器的状态感知模型

为了综合利用 GRU 的时序特征提取能力和 GAT 的拓扑感知能力，我们提出了一种新的新型电力系统状态感知模型，该模型考虑了实际的数据采集场景，然后为分布式无功补偿的策略制定和效果评估提供数据特征。

在该方法中，DRL 主体采用与中心云服务器不同的状态感知方法。DRL 主体作为在线决策过程中最重要的模块，在线实施过程中只能访问本地节点的 PMU 数据。因此，如图 4-5 (a) 所示，DRL 主体综合本地节点的 PMU 数据和其他节点的 SCADA 数据，以提取 EI 系统的状态特征。第 i 个代理的 PMU 监控数据由 $p_i \in \mathbb{R}^{T \times 6}$ 表示，第 j 个代理的 PMU 监控数据由 $s_j \in \mathbb{R}^4, j \neq i$ 表示。然而，中心云服务器只需要在训练过程中实时获取各节点的暂态数据，并进行整体无功补偿效果评价，而在线实施过程中对暂态数据的实时性要求不高。因此，对于中心服务器的状态感知模型，可以将所有 M 个安装有 PMU 节点的暂态数据同时作为输入，再加上 $N-M$ 个未安装 PMU 节点的 SCADA 数据，做出更精准的无功补偿效果评价。



(a) DRL 主体

(2) 中心云服务器

图 4-5 DRL 主体和中心云服务器的电力系统状态感知模型

上图中,相同颜色的所有 DRL 主体和中心云服务器的 GRU 共享相同的参数,这意味着所有安装有 PMU 采样的电力系统节点共享相同的特征提取过程。这种设计可以减少网络参数,同时提高模型的通用性。

4.3.2 多主体深度强化学习框架

强化学习是一种解决决策或优化问题的方法,在这种方法中,决策主体通过在环境中尝试不同的策略进行学习和更新,并以获得最大的奖励值为目标。强化学习的常见模型是马尔可夫决策过程,它由一组状态 s 和动作 a 组成。新的系统状态 s' 和奖励 r 仅取决于上一时间步的状态和操作。

基于强化学习中的 Advantage Actor-Critic (A2C)算法,本章设计了一种多主体深度强化学习框架来实现无功补偿装置的协同出力优化。如图 4-6 所示,该多主体 DRL 框架由 GRU 模块、GAT 模块、多个 Actor 模块和 Critic 模块组成。 a_j 是第 j 个无功功率补偿装置的动作, $V(s)$ 是对控制动作的效果评估。

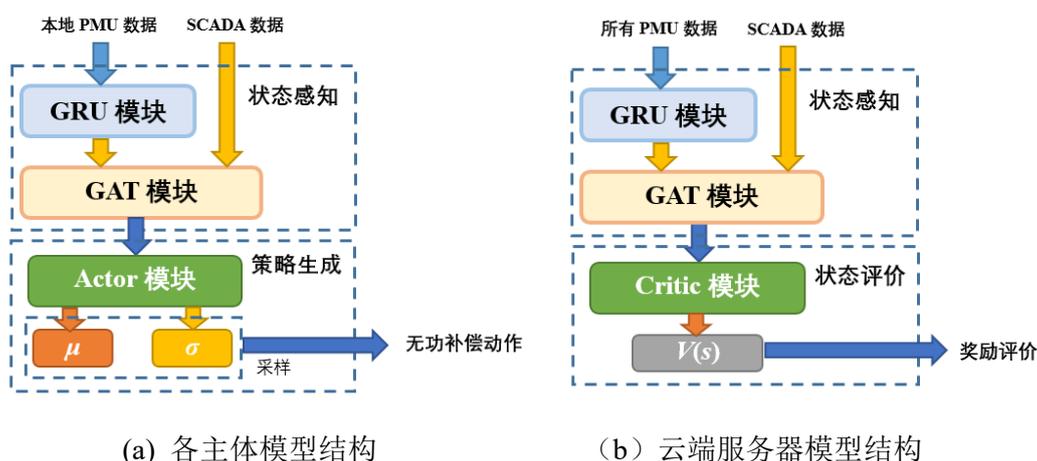


图 4-6 多主体深度强化学习框架结构图

多主体深度强化学习框架中的奖励函数用于评估无功补偿措施执行后的环境状态。为了评估无功补偿后的电压稳定性,首先,无功补偿动作完成后,节点电压应接近 1 p.u.。其次,为确保无功补偿过程中的电压不超限额,整个无功补偿过程中的最大电压的偏离情况将作为惩罚项。最后,考虑到无功补偿装置动作的成本,同时防止无功补偿装置的误动作,在奖励函数中添加无功补偿设备的输出作为惩罚。综上所述,所提出方法中的奖励函数定义为:

$$r(s) = -\frac{1}{N} \sum_i^N |U_i^T - 1| - \alpha_1 \max_{i,t} (|U_i^t - 1|) - \alpha_2 \sum_j^M O_j \quad (4-9)$$

其中, $r(s)$ 是单次无功补偿动作的奖励函数, s 是表示新型电力系统的状态。 U_i^T 表示第 i 个节点在补偿后的线路电压, U_i^t 表示第 i 个节点在第 t 个时刻的线路电压,

O_j 表示第 j 个无功功率补偿装置的输出, α_1 和 α_2 是两个惩罚项的权重系数, 在本章的实验研究中设置为 0.1 和 0.001。N 和 M 分别是电力系统节点和无功功率补偿装置的数量。可以看出, 接近 1 p.u.的电压将获得更高的奖励值。除惩罚外, $R(s)$ 的范围为 0 以下, 如果考虑可接受的无功补偿后的电压范围[0.8~1.2] p.u., 则 $R(s)$ 大于-0.2 时, 无功补偿后电压达到稳定。

在所提出方法中, 每次监测到电压暂降之后, 将按照 T_0 的间隔, 连续进行 K 次补偿动作, 来确保电压的稳定。在本文中, T_0 设置为 1.1s, 其中包括对每次补偿后电力系统状态的监测 1s 的数据, 以及深度强化学习控制器用来给出无功策略所需的 0.1s。为了使每次动作策略考虑后续动作的影响, 使用衰减系数来确定每次动作的预期奖励。

$$R^k(s) = \sum_{i=k}^K \gamma^{i-k} r^i \quad (4-10)$$

其中, $R^k(s)$ 为第 k 次动作的预期奖励, γ 为奖励衰减系数, r^i 为第 i 次无功补偿动作的奖励。不同于强化学习常用的一些游戏或规划场景, 无功补偿的目的是使系统电压尽快达到稳定, 因此, γ 建议设置为较小的值, 如 0.2, 即强化学习主体会更关注短期收益。

4.3.3 无功补偿框架训练策略

为了获得准确且鲁棒较强的模型, 提出了一种全新的基于 GRU 和 GAT 的多主体深度强化学习模型的训练过程, 如算法 4-1 所示。

算法 4-1 用于电压稳定控制的多智能体 DRL 模型的训练流程

- 1: 建立具有 N 个节点和 M 个 SVG 的新型电力系统的暂态仿真模型;
- 2: 准备 m 种新型电力系统状态和 n 种要注入的故障和干扰;
- 3: 重复:
- 4: 随机采样一种新型电力系统状态为初始潮流;
- 5: 对于 $t \in 1, 2, \dots, n$:
- 6: 将第 t 种故障或干扰注入新型电力系统暂态仿真模型, 采集暂态过程的 SCADA 数据和 PMU 数据, 作为环境初始状态 s ;
- 7: 对于 $k \in 1, 2, \dots, K$:
- 8: 将状态 s 作为多主体强化学习模型输入, 获得 SVG 的无功补偿动作 $O_j (j = 1, 2, \dots, M)$ 和评价估计 $V(s)$;

- 9: 在暂态仿真模型中应用无功补偿动作 O_j ，获取新的系统状态 s' ；
- 10: 评价系统状态 s' 的电压稳定性，得到真实奖励 $r(s'; \theta)$ ；
- 11: 用 s' 替代 s 。
- 12: 根据公式(4-10)计算累积的预期奖励 $R(s; \theta)$ ；
- 13: 计算 Critic 模块的损失函数： $L_c = (R(s; \theta) - V(s))^2$ ；
- 14: 计算各 Actor 模块的损失函数： $L_{a,j} = (R(s; \theta) - V(s)) \log_{\pi}(O_j | s; \theta)$ ；
- 15: 使用 Adam 优化器执行网络反向传播，更新 DRL 模型中各模块参数。
- 16: 直到 $\sum_{i=1}^n R(s; \theta)$ 收敛

Critic 模块的损失函数是减少预期奖励和实际奖励之间的偏差，即获得准确的环境估计。然后，在 Actor 模块的损失函数中， $\log_{\pi}(O_j | s; \theta)$ 表示面对环境状态 s 时选择动作 O_j 的概率。因此，当实际奖励高于预期奖励时，最小化损失函数可以增加动作 O_j 被选择的概率。相反，如果动作 O_j 带来的实际回报低于预期，则选择 O_j 的概率将降低。以这种方式，多智能体 DRL 模型被训练以获得具有高奖励的控制动作。

4.4 仿真实验及结果分析

在本小节中，对基于 IEEE 9 总线系统的新型电力系统进行了案例研究和无功补偿实验，以评估所提出方法的有效性。此外，还将该方法与其他方法进行了比较，以显示其优越性。

4.4.1 新型电力系统仿真

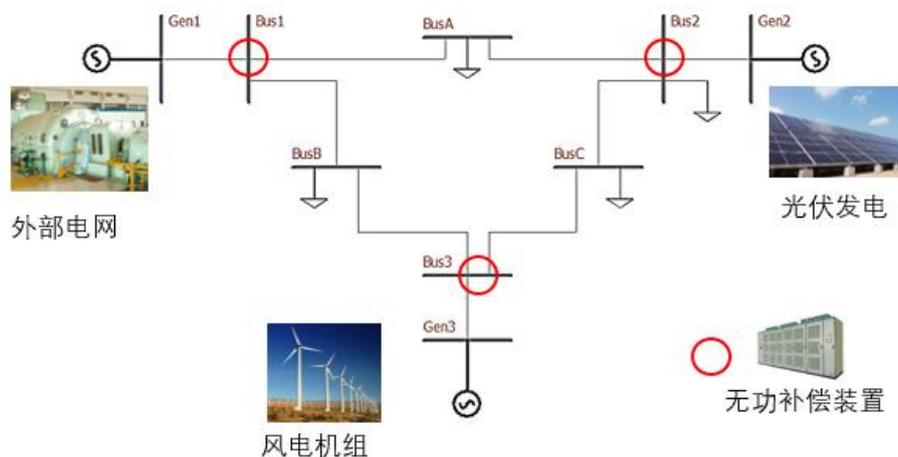


图 4-7 含分布式发电的新型电力系统的仿真模型结构

基于图 4-7 所示的结构，通过 PSD/BPA 软件构建新型电力系统的仿真模型。该系统在 10kV、50Hz 下运行，发电机 1 代表外部主电网，发电机 3 是额定容量为 1.5 MW 的风力发电机，发电机 2 是 1.0 MW 光伏发电。母线 A、母线 B、母线 C 和母线 2 连接有不同功率因数的可变负载。母线 1、母线 2 和母线 3 是安装有无功功率补偿装置的三条母线。然后，将每次的功率曲线作为初始功率流，将表 4-1 中所示的故障和扰动注入电力线，以产生母线和负载上的电压骤降。故障类型包括不同相的短路和接地，故障阻抗在 0.1 到 3 p.u. 之间变化。

表 4-1 故障引入情况

故障类型	故障相	故障位置	故障阻抗
短路 / 接地	A / B / C	故障线路的 10%、 30%、50%、70%、90%	0.1 – 3.0 p.u.
	AB / AC / BC		
	ABC		

图 4-8 显示了当母线 1 和母线 A 之间的线路上出现两相接地时，新型电力系统所有节点的电压曲线。故障发生在 0.4 秒。

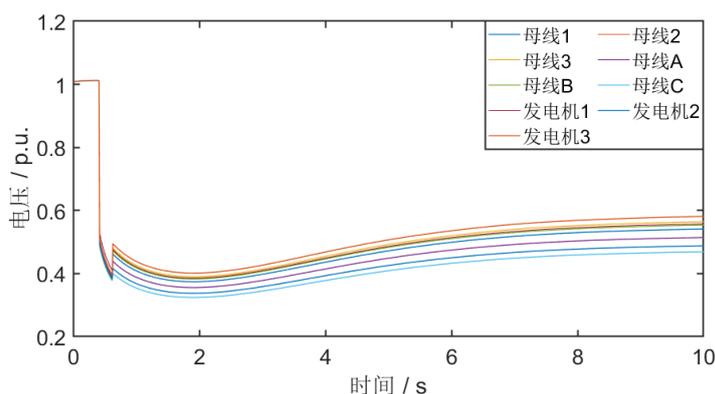


图 4-8 电力系统各节点在故障情况下的电压曲线

4.4.2 参数设置及离线训练

在参数设置中，首先，构建大小为 9×9 的原始邻接矩阵 **A**，以描述图 4-7 中新型电力系统的拓扑结构：

$$A = \begin{bmatrix} 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 1 & 0 & 0 & 1 & 1 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 1 \end{bmatrix} \quad (4-11)$$

其中，矩阵 \mathbf{A} 的 (i, j) 处的 1 表示在第 i 和第 j 个电力系统节点之间存在电力线路。节点的顺序为：发电机 1、发电机 2、发电机 3、母线 1、母线 2、母线 3、负载 1、负载 2 和负载 3。

然后，通过组合 GRU 模块、GAT 模块、多个 actor 模块和 critic 模块构建多主体深度强化学习模型，详细参数列于表 4-2。GRU 模块由两个 GRU 单元和 1 个全连接层组成，GAT 模块由两个图注意力层组成。actor 模块和 critic 模块均由完全连接的层组成。在表 4-2 GRU 单元参数中，参数大小代表神经元数量，图注意力层的参数中，3 表示注意头的数量。3 个 Actor 模块分别用来获得三个无功功率补偿装置的最佳输出，范围从 0 MVar 到 10 MVar。Actor 模块和 Critic 模块的输入为图注意力模块的输出。不同的是，Actor 模块所连接的图注意力模块的输入是本地 PMU 数据的 GRU 模块提取结果加上其他节点的 SCADA 数据，而 Critic 模块所连接的图注意力模块的输入是所有 PMU 数据的 GRU 模块提取结果加上其他节点的 SCADA 数据。

表 4-2 多主体深度强化学习模型参数

编号	模块	层类型	输入大小	参数大小	输出大小
1	GRU 模块	GRU 单元	100×7	20	100×20
		GRU 单元	100×20	5	100×5
		全连接层	100×5	500×4	4
2	图注意力模块	图注意力层	9×4	4×50 / 3	9×50
		图注意力层	9×50	50×20 / 3	9×20
3	Actor 模块	全连接层	1×180	180×100	1×100
		全连接层	1×100	100×20	1×20
		全连接层	1×20	20×1	1
		全连接层	1×20	20×1	1
4	Critic 模块	全连接层	1×180	180×50	1×50
		全连接层	1×50	50×10	1×10
		全连接层	1×10	10×1	1

包含 1650 个样本的仿真数据中有 80% 用于离线训练，20% 用于评估经过训练的多主体 DRL 模型。该模型的训练由 Tensorflow 在一台配备有 GTX 1070 GPU 和 16 GB 内存的计算机上的 Python 环境中进行。GRU、GAT 和 Actor 模块的学习速率设置为 0.0001，而 Critic 模块的学习率设置为 0.0005，以获得无功补偿性能的快速评估。使用算法 4-1 中所示的训练方法，当平均奖励达到较高值且不增加时，多主体 DRL 模型达到收敛。

经过大约 100000 步的训练之后，模型的训练实现收敛。大部分训练时间用于与 PSD/BPA 提供的新型电力系统环境交互。训练过程中的奖励曲线如图 4-9 所示。可以看出，奖励曲线在前 5000 步中波动较大，这是深度强化学习算法的决策空间搜索和 critic 网络训练过程。在最后 10000 步左右的训练中，奖励值相对稳定，并逐步提升，达到收敛状态。

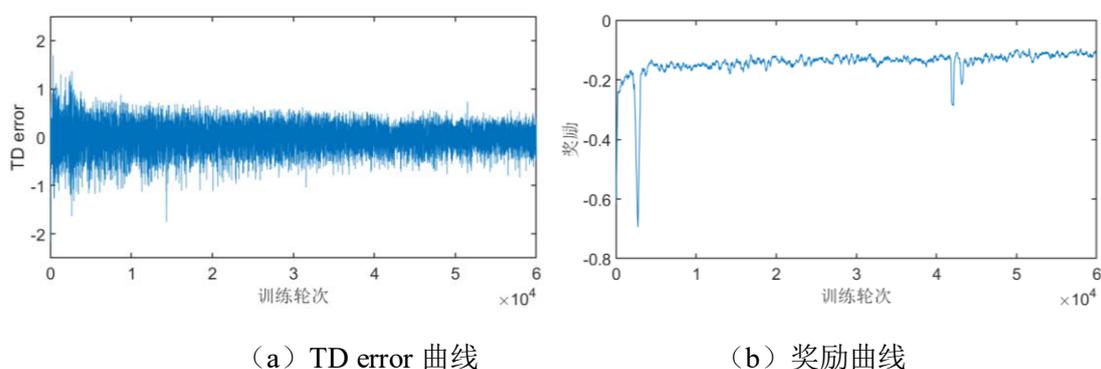


图 4-9 多主体强化学习模型训练过程中的 TD error 及奖励曲线

4.4.3 实验结果分析

在获得经过训练的多主体 DRL 模型后，使用该模型对剩余的 330 个电压失稳场景进行在线无功补偿，以测试模型效果。表 4-3 列出了训练集和测试集的平均损失和奖励值。从中可以看出，平均奖励值远大于 -0.2，并且非常接近 0，这意味着所有的训练和测试场景都可以在电压骤降期间通过合理的无功补偿动作实现电压稳定。

表 4-3 多主体 DRL 在训练及测试集上的结果

数据集	训练集	测试集
奖励	-0.125	-0.117

为了显示所提出方法的优越性，进一步将本文提出的多主体深度强化学习方法与 SVG 的原始控制策略进行了比较。表 4-4 显示了使用训练和测试集的所有方法的平均奖励。

表 4-4 多种方法对比结果

方法	训练集奖励	测试集奖励	平均奖励
SVG 控制	-0.180	-0.179	-0.180
多主体 DRL	-0.125	-0.117	-0.123

比较结果表明，与 SVG 原始控制方法相比，该方法在电压稳定性方面的平均

奖励高出 1.1%。SVG 原始控制方法仅对本地母线电压做出响应，这导致平均回报较低。单主体 DRL 方法没有考虑电力系统拓扑，因此无功功率补偿不够精确。与其他方法方法相比，本文提出的基于 GCN 的多主体强化学习模型具有更好的相邻电力系统节点特征融合能力和快速响应能力，是更有效的电压稳定方法。

图 4-10 显示了对图 4-8 所示的电压波动的无功补偿结果。所提出方法将大部分节点的电压提高到 0.8 p.u.以上，确保新型电力系统的电压稳定性。虚线显示了 SVG 自带控制器给出的无功功率补偿结果。由于每个 SVG 仅接收本地母线电压值，因此无法通过协同合作将整个网络的线路电压恢复到 0.8 p.u.以上。

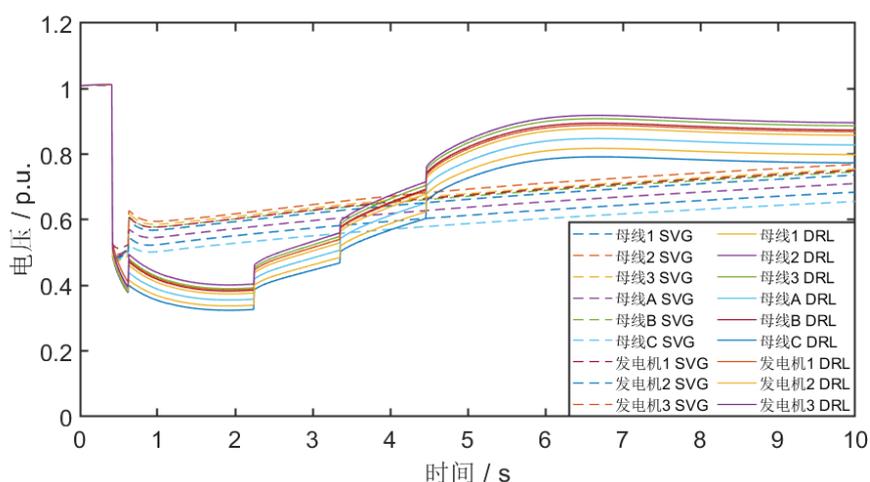


图 4-10 所提出方法的无功补偿结果

值得注意的是，由于需要新型电力系统的稳定性和安全性，在实际新型电力系统操作中需要一种鲁棒控制方法。因此，在所提出方法的实际部署中，为了使在线部署的控制模型更贴近实际电力系统，可以基于实际采样数据通过增量学习来更新训练模型。

4.4.4 消融实验

为了证明所提出方法的每个组成部分的有效性，进行了消融实验。每次实验移除所提出方法中的一个或两个组件，得到的无功功率补偿结果如表 4-5 所示。

表 4-5 消融实验结果

多主体 DRL	SCADA 数据	GRU 模块	GAT 模块	训练集奖励	测试集奖励
√				-0.224	-0.220
√	√			-0.214	-0.221

√		√		-0.182	-0.176
√	√	√	√	-0.125	-0.117

从表 4-5 可以看出，获取其他新型电力系统节点的 SCADA 数据有助于无功补偿决策，这表明了异构数据融合的有效性。GRU 模块增强了模型的时间序列特征提取能力，有助于提高总体奖励值，具有相邻节点信息融合能力的 GAT 块对奖励的提升贡献最大。因此，该框架中所有模块的构建都有助于更准确无功补偿决策。

4.5 本章小结

本章提出了一种新的基于多主体 DRL 和 GAT 的为确保新型电力系统电压稳定的无功补偿优化方法。该方法首次将可以动态感知电力系统拓扑的图注意力网络引入电力系统优化。同时，多主体 DRL 框架充分考虑了现场数据采集情况，并有效集成了 PMU 和 SCADA 的异构数据。最终使用多个经过训练的 DRL 主体协同实现精确的无功补偿策略，以确保电压稳定。对新型电力系统模型的案例研究表明，所提出的方法可以确保电力系统在电压骤降期间稳定运行。

5. 新型电力系统综合能效优化

5.1 引言

在过去几十年中，能源危机和过度碳排放已成为两个日益严重的问题^[113]。全球温室气体排放数据表明，全球二氧化碳排放的最大贡献者来自电力生产^[114]，这意味着迫切需要提高电力系统的能效，减少碳排放。大力发展和高效利用可再生能源是减少碳排放的有效途径。可再生能源比例高的能源互联网被视为实现能源低碳生产、消费和转化的战略途径^[115]。

因此，在前面章节新型电力系统状态评估及安全保障的基础上，本章进行了新型电力系统能效综合优化方面的研究，提出了新型电力系统能量传输和系统运行过程中的能效优化方法，实现了在可再生能源最优利用的情况下，新型电力系统的运行能效最优。

5.2 新型电力系统能效仿真

为了进行新型电力系统能效优化，现有很多方法通过简单数学方程描述电力系统模型，虽然有计算简单快速的优势，但并不能完全反应现有的电力系统仿真。为保证电力系统能效仿真的准确性，可选用一些商业软件如 Simulink、PSD-BPA 等，但这些软件虽然功能强大，但与人工智能算法的交互时，需要编写复杂的接口程序，仿真速度受限。特别是对于需要长时间训练的深度强化学习模型，较低的仿真速度将极大降低模型的训练速度。

因此，本节开发了交流潮流仿真程序，并实现了三相潮流计算。进而，对 IEEE30 节点电力系统进行了建模，与 PSD-BPA 软件对比了仿真结果，验证了仿真的准确性。

5.2.1 交流供电系统建模

(1) 节点模型

在潮流计算中，节点可分为 PQ 节点、PV 节点和平衡节点，PQ 节点已知有功和无功功率，PV 节点已知有功功率和电压，平衡节点已知电压和相角。在轨道交通供电系统中，交流节点可分为外部电网、母线和负载。外部电网被设置为平衡节点，母线和负载为 PQ 节点。

(2) 线路模型

线路模型采用 π 型等值电路， Z 为线路导纳， Y 为线路阻抗。此外，开关被定

义为线路的一个属性，如果线路包含开关，则可以通过控制开关的闭合状态来连接或断开线路。

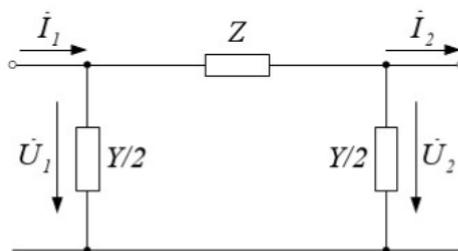


图 5-1 交流线路模型

(3) 变压器模型

变压器模型采用 π 型等值电路， Z_T 为变压器阻抗， k 由原副边电压和电压等级计算得到。为了计算变压器的空载损耗，在变压器副边增加了支路阻抗。

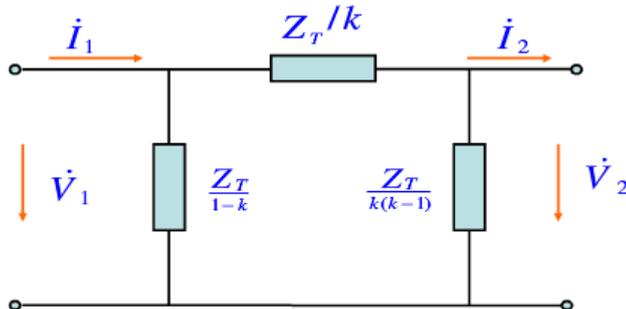


图 5-2 变压器模型

5.2.2 三相潮流仿真建模

在单相潮流计算模型的基础上，考虑到轨道交通供电系统中可能出现的三相不平衡潮流，建立了三相潮流仿真模型。

(1) 三相节点模型

三相节点模型较为简单，在单相节点模型的基础上，分别构造了 A、B、C 三相的电压、有功功率和无功功率，可以分别对每相参数进行设置。

(2) 三相线路模型

在三相线路模型中，假设输电线路均匀分布，构造了每相和相间的阻抗及导纳，如下图所示， Z_{aa} 、 Z_{bb} 、 Z_{cc} 为每相自阻抗， Z_{ab} 、 Z_{ac} 、 Z_{bc} 为相间阻抗； B_{a0} 、 B_{b0} 、 B_{c0} 为每相对地电纳， B_{ab} 、 B_{ac} 、 B_{bc} 为相间电纳。

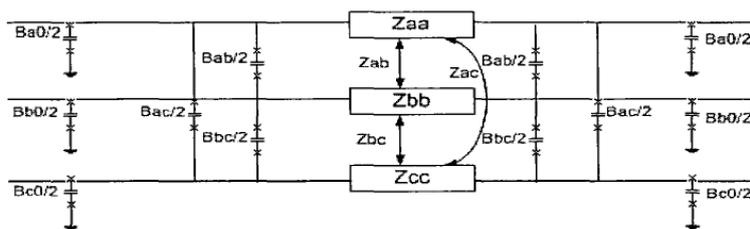


图 5-3 三相线路模型

在转化为 π 型等值电路时，中间阻抗部分的导纳为：

$$Y_{abc} = \begin{bmatrix} Y_{aa} & Y_{ab} & Y_{ac} \\ Y_{ba} & Y_{bb} & Y_{bc} \\ Y_{ca} & Y_{cb} & Y_{cc} \end{bmatrix} = \begin{bmatrix} Z_{aa} & Z_{ab} & Z_{ac} \\ Z_{ba} & Z_{bb} & Z_{bc} \\ Z_{ca} & Z_{cb} & Z_{cc} \end{bmatrix}^{-1} \quad (5-1)$$

两侧导纳为：

$$Y_{abc}^0 = Y_{abc}^1 = \begin{bmatrix} jB_{aa}/2 & -jB_{ab}/2 & -jB_{ac}/2 \\ -jB_{ba}/2 & jB_{bb}/2 & -jB_{bc}/2 \\ -jB_{ca}/2 & -jB_{cb}/2 & jB_{cc}/2 \end{bmatrix} \quad (5-2)$$

(3) 三相变压器模型

三相变压器模型在考虑阻抗、导纳的基础上，还需要考虑接线方式的影响。三相变压器有多种连接方式，y、d 分别代表了星型接法和三角型接法，在每种接法基础上，还可以根据三相顺序的不同，衍生出不同原副边相位差的接线方式。由于变压器接线方式组合较多，本系统由变压器的原始导纳矩阵和节点一支路关联矩阵进行推导得到变压器整体的导纳矩阵，具体步骤如下：

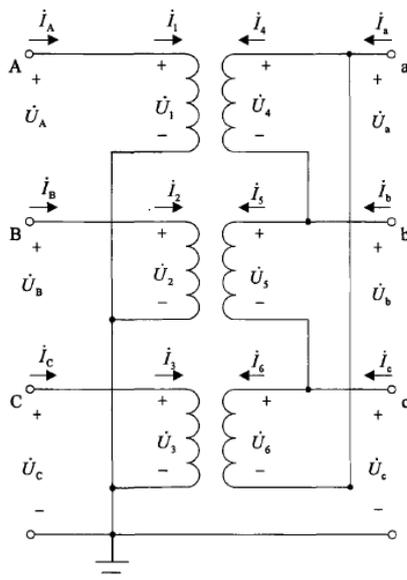


图 5-4 变压器等值电路

首先，根据变压器绕组两侧实际变比，建立变压器绕组两侧电压电流的原始导

纳矩阵。式中， y_T 为单相导纳， k 为绕组变比。

$$\mathbf{Y}_0 = \begin{bmatrix} y_T & 0 & 0 & -\frac{y_T}{k} & 0 & 0 \\ 0 & y_T & 0 & 0 & -\frac{y_T}{k} & 0 \\ 0 & 0 & y_T & 0 & 0 & -\frac{y_T}{k} \\ -\frac{y_T}{k} & 0 & 0 & \frac{y_T}{k^2} & 0 & 0 \\ 0 & -\frac{y_T}{k} & 0 & 0 & \frac{y_T}{k^2} & 0 \\ 0 & 0 & -\frac{y_T}{k} & 0 & 0 & \frac{y_T}{k^2} \end{bmatrix} \quad (5-3)$$

然后，根据变压器接线方式，建立变压器绕组支路电压 $\mathbf{U}_0 = [\dot{U}_1 \ \dot{U}_2 \ \dot{U}_3 \ \dot{U}_4 \ \dot{U}_5 \ \dot{U}_6]^T$ 与节点电压 $\mathbf{U}_n = [\dot{U}_A \ \dot{U}_B \ \dot{U}_C \ \dot{U}_a \ \dot{U}_b \ \dot{U}_c]^T$ 之间的关系方程 $\mathbf{U}_0 = \mathbf{C}\mathbf{U}_n$ 。对于图 5-4 所示 Yd1 接线方式的变压器，关系矩阵 \mathbf{C} 为：

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & -1 & 0 \\ 0 & 0 & 0 & 0 & 1 & -1 \\ 0 & 0 & 0 & -1 & 0 & 1 \end{bmatrix} \quad (5-4)$$

最后，可以得到三相变压器的导纳矩阵 \mathbf{Y} ：

$$\mathbf{Y} = \mathbf{C}^T \mathbf{Y}_0 \mathbf{C} \quad (5-5)$$

5.2.3 交流模型的建立及计算流程

在本仿真系统中，交流模型通过 txt 文件进行配置，模型配置文件主要分为以下几部分：

1) 线路参数配置：定义线路参数对象，设置线路每公里的阻抗导纳参数、线路回路数。

2) 变压器参数配置：可以设置变压器标称容量、两侧电压等，变压器阻抗可以通过设置短路和开路损失，由内部程序计算获得，也可以直接对阻抗进行设置。

3) 节点配置：可以设置节点类型及设备类型，并根据节点类型设置电压及三相有功、无功出力和负载，以及 PV 或平衡节点的电压值。

4) 线路设置：需要给定线路参数、长度及所连接的节点名称，并可设置线路是否有开关器件及开关状态。

5) 变压器设置：需要给定变压器参数及所连接的节点名称。

仿真软件读取模型文件，进行进行三相潮流计算，潮流计算的主要步骤如下图所示：



图 5-5 交流三相潮流仿真流程图

1) 建立交流系统模型: 从模型配置文件中读取模型参数, 依次建立线路配置、变压器配置、节点、线路和变压器模型。

2) 计算导纳矩阵: 根据对应的配置模型信息, 计算并建立线路和变压器的三相导纳矩阵, 并根据节点连接关系构建整个交流网络的导纳矩阵。

3) 建立潮流方程组: 基于牛拉法建立三相潮流方程组, 其中包括有功功率方程、无功功率方程和电压方程。

4) 牛拉法解方程组: 对方程组求导, 使用牛拉法迭代求解三相潮流方程组, 节点电压直至达到收敛条件。

5) 计算结果存储及损耗计算: 将方程组求解获得的各节点电压、有功和无功功率信息返回各节点模型, 计算线路和变压器的三相功率的流入和流出值, 进而得到有功和无功损耗。

5.2.4 交流系统稳态计算程序验证

为验证交流潮流计算的准确性, 建立了 IEEE30 节点电力系统模型对潮流计算程序进行验证, 图 5-6 分别展示了本潮流计算程序和 PSD-BPA 的潮流计算结果, 可以看出计算误差较小。

考虑线路损耗，以获得总损耗最小的最优能量传输路径。

因此，本节研究了考虑碳排放和优化能量传输路径的合理购电选择问题，提出了一种多任务强化学习的能量路由方法。首先，考虑到新型电力系统中能量路由器互联的网络结构，通过 GCN 观测包含每个能量路由器实时状态信息。然后，考虑碳排放和电价因素，采用深度 Q 学习（Deep Q Learning, DQN）来选择每个时段内最适合的购电能量路由器。最后，Actor-Critic 模型用以获得最佳能量传输路径。

5.3.1 能量传输优化问题描述

本节介绍了所提出方法的应用场景，并阐述了电源选择和能量路由的优化问题。

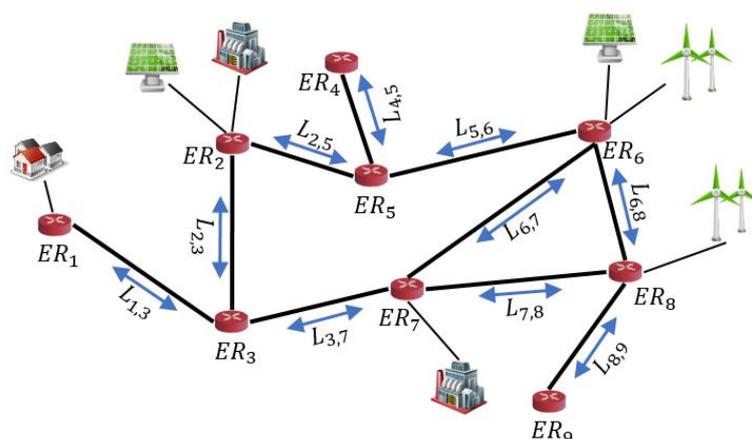


图 5-7 新型电力系统中的多能量路由器结构

图 5-7 展示了一个具有互连的多个能量路由器（Energy Router, ER）的典型新型电力系统。由能量路由器连接的每个区域具有特定的能量组成，例如，能量路由器 2 与风电场和热电厂连接，能量路由器 4 与光伏和柴油发电机连接。从这个意义上说，作为一个电力供应商，能量路由器连接的每个地区都将有不同的电价和碳排放。可再生能源往往具有分配给用户的低碳排放，但电价较高。从火电厂低价购电通常意味着承担高碳排放。同时，在具有复杂互连的新型电力系统中，线路中的传输损耗和能量路由器中的能量转换损耗也构成了用户成本。因此，新型电力系统中电力需求不断变化的用户面临两个主要问题：

- 1) 为每次用电需求选择最佳的供电能量路由器，并确保一定时期内价格低、碳排放不超标。
- 2) 选择从所选供电能量路由器到用户能量路由器的最佳能量路由路径，该路径在整个路径期间具有最小的能量传输损耗。

为了解决上述问题，应建立能量路由器之间的功率传输关系。因此，在不考虑连接到每个能量路由器的特定发电设备（通常被视为隐私）的情况下，建立了图模型 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ ，以表示新型电力系统中能量路由器的连接关系。 \mathcal{V} 是图节点集， \mathcal{E} 是图边集， $v_i \in \mathcal{V}$ 是第 i 个能量路由器，而 $(v_i, v_j) \in \mathcal{E}$ 是第 i 和第 j 个能量路由器之间的传输线，边的权重影响着线路的传输损耗。基于图模型，能量路由优化问题的公式描述如下。

1) 供电能量路由器选择

供电节点的选择主要基于电价和相应的碳排放。对于在时间 t 具有电力需求 ΔP 的用户，价格成本通过以下公式计算：

$$C_p(t) = \Delta P(t) \times b_{v_i}(t) \quad (5-6)$$

其中， $b_{v_i}(t)$ 表示第 i 个能量路由器在时刻 t 的电价^[121]。

然后，购买的电力将附带一定比例的电力生产商的碳排放。碳排放成本计算如下：

$$C_{cb}(t) = \Delta P(t) \times E_{v_i}(t) \times b_{cb} \quad (5-7)$$

其中， $E_{v_i}(t)$ 是在 t 时刻单位功率下由能量路由器 v_i 附加的碳排放量， b_{cb} 是每单位碳排放的价格。

在选择供电能量路由器时，应考虑一些约束。首先，供电能量路由器中的可用功率应大于功率需求：

$$\Delta P(t) \leq S_{v_i}(t) \quad (5-8)$$

式中， $S_{v_i}(t)$ 是 t 时刻能量路由器 v_i 的可用功率。

然后，每个时间段的累积碳排放量不得超过规定值，否则用户将面临大额罚款。累积碳排放的约束定义为：

$$\sum_{t=0}^T C_{cb}(t) \leq K_{cb} \quad (5-9)$$

式中， K_{cb} 是时段 T 内的碳排放限值。

同时，在选择供电能量路由器时，路由过程中的传输损耗也不容忽视。电价低但传输距离长的能量路由器可能会有较大的传输损耗，这会增加购电成本。因此，供电能量路由器选择的总的优化模型如下：

$$\min: J = \sum_{t=0}^T (\alpha C_p(t) + \beta C_{cb}(t)) (1 + P_{loss}(t) / \Delta P(t)) \quad (5-10)$$

$$\text{s.t.} \quad (5-8) \quad (5-9)$$

式中， $P_{loss}(t)$ 是传输过程中的功率损耗，将在下一小节中定义。

2) 能量路由优化

在选择了供电能量路由器之后，能量路由优化需要为当前的电力需求找到具有最小能量传输损耗的最佳路由路径。从供电能量路由器到用户所在能量路由器，路由路径可以表示为：

$$\text{path}(v_s \rightarrow v_l): v_s \equiv v_a, v_b, \dots, v_c \equiv v_l \quad (5-11)$$

式中， v_s 是供电能量路由器， v_l 是具有电力需求的能量路由器。

与普通路由算法不同，能量路由不仅考虑形成路由路径的传输线的长度，还考虑路径期间的功率损耗。考虑输电线路中的现有功率，对于新增功率，输电线路的新增损耗计算如下：

$$C_{(v_i, v_j)} = \frac{r_{(v_i, v_j)}}{U_{(v_i, v_j)}^2} \left((\Delta P + P_{(v_i, v_j)})^2 - P_{(v_i, v_j)}^2 \right) \quad (5-12)$$

式中， $r_{(v_i, v_j)}$ 是能量路由器 v_i 和 v_j 间传输线路的阻抗， $U_{(v_i, v_j)}^2$ 是传输线路的电压， $P_{(v_i, v_j)}$ 是该传输线路中现有的传输功率。需要注意的是，如果 ΔP 和 $P_{(v_i, v_j)}$ 是反方向的，新增损耗 $C_{(v_i, v_j)}$ 将为负值，这意味着通过该线路的电力传输使总的传输损耗减少了，可以通过能量路由器内的能量分配来实现。

同时，在能量路由器中，在能量路由器内部的功率转换期间也会产生功率损耗。一般而言，能量路由器损失通过以下公式计算：

$$C_{v_i} = (1 - \eta_{v_i}) \Delta P \quad (5-13)$$

式中， η_{v_i} 是指的能量路由器 v_i 内部的能量转化效率。

同时，为确保输电线路的安全，线路传输的总功率不得超过线路容量。因此，能量路由的约束被定义为：

$$\Delta P + P_{(v_i, v_j)} \leq K_{(v_i, v_j)} \quad (5-14)$$

式中， $K_{(v_i, v_j)}$ 是能量路由器 v_i 和 v_j 间传输线路的容量。

因此，能量路由优化的模型被定义为：

$$\min: J_{\text{path}: v_s \rightarrow v_l} = \sum_{v_i \in \text{path}} C_{v_i} + \sum_{(v_i, v_j) \in \text{path}} C_{(v_i, v_j)} \quad (5-15)$$

$$\text{s.t. (5-14)}$$

5.3.2 基于图卷积神经网络的多任务强化学习算法

为了以精确和智能的方式解决上述优化问题，本节提出了一种基于图卷积神经网络的多任务强化学习方法，该方法具有两个主要优点。1) 强化学习可以解决具有累积奖励的优化问题，这是一般启发式优化算法难以处理的。2) 经过训练的强化学习模型可以直接基于系统状态的观察获得最优策略，避免了复杂的在线优化过程。所提出方法的流程图如图 5-8 所示，主要包括以下步骤：

- 1) 基于新型电力系统中能量路由器之间的互连关系, 根据线路和能量路由器参数构建新型电力系统的图形模型。
- 2) 考虑到新型电力系统的图模型, 建立了基于图拓扑的图卷积神经网络模型。然后利用图卷积神经网络模型 $G(\theta_G)$ 对多个能量路由器的实时状态进行融合, 得到新型电力系统的特征 F 。
- 3) 利用从图卷积神经网络中提取的所有能量路由器的特征, 构造 Q 网络 $Q(\theta_Q)$ 来评估每个能量路由器的成本。然后用深度 Q 学习方法训练 Q 网络, 以获得供电能量路由器的最优选择。
- 4) 基于提取的能量路由器特征和输电线路的状态, 构造了一个包含 Actor 网络和 Critic 网络的 A2C 深度强化学习模型, 以获得和评估能量路由策略。
- 5) 在能量路由器上实现多任务强化学习模型。在从连接到能量路由器的用户接收到电力需求后, 该模型将为用户生成最优供电选择和能量路由策略。

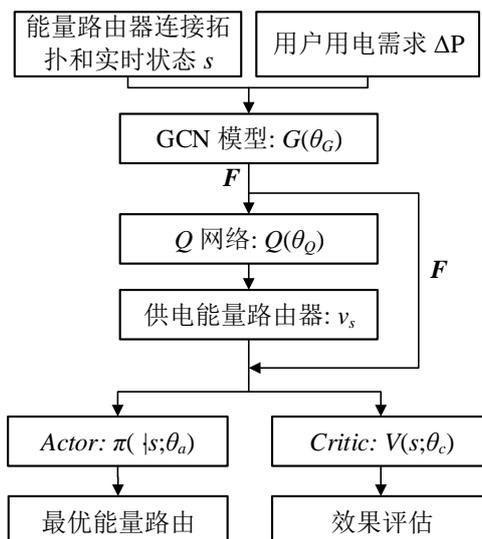


图 5-8 基于多任务强化学习的能量传输优化方法

5.3.2.1 基于图卷积神经网络的新型电力系统状态观测

如上所述, 能量路由器互连的新型电力系统是典型的图形结构, 指示能量传输关系的图的拓扑结构对于理解新型电力系统中能量路由器的状态非常重要。因此, 可以基于拓扑来融合图内节点数据的图卷积神经网络用于提取新型电力系统的实时状态特征。

对于具有 N 个能量路由器节点和 M 条传输线的新电力系统, 可以构建邻接矩阵 $A \in \mathbb{R}^{N \times N}$ 来表示图的拓扑。进而基于公式 (2-4), 使用图 5-9 的网络结构进行实时特征提取。

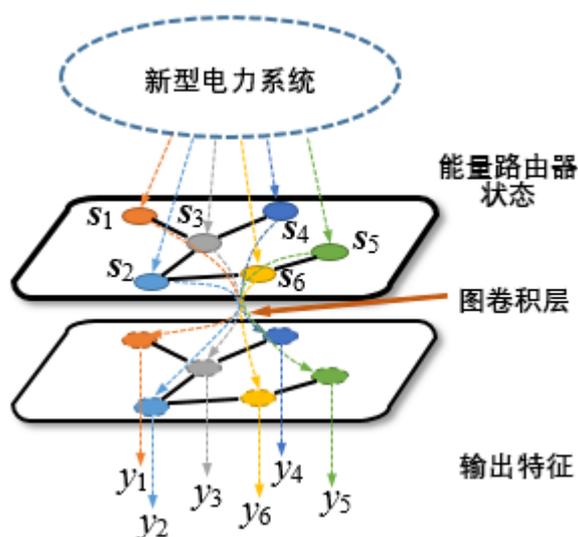


图 5-9 基于图卷积神经网络的能量路由器特征提取

由所有能量路由器的状态组成的新型电力系统状态 s 被用作图卷积神经网络节点的输入。第 i 个能量路由器的状态 s_i 由下式定义：

$$s_i = [Cap_{v_i}, b_{v_i}, S_{v_i}, E_{v_i}] \quad (5-16)$$

式中， Cap_{v_i} 是第 i 个能量路由器的容量。图卷积神经网络的输出特征通过基于拓扑的图卷积运算获得，因此能量路由器的互连关系反映在输出特征中。

5.3.2.2 基于 DQN 的供电能量路由器选择

供电能量路由器选择的目的是选择价格较低的能量路由器，并确保碳排放量在有限范围内。通过求解优化方程不容易获得最优解，因为目标函数和约束是针对一天中的累积值。因此，引入深度 Q 学习（Deep Q Learning, DQN）来给出全天的最优购电策略。作为一种基于值的强化学习方法，DQN 使用 Q 网络评估当前系统状态，并根据 Q 值选择最佳动作^[122]。

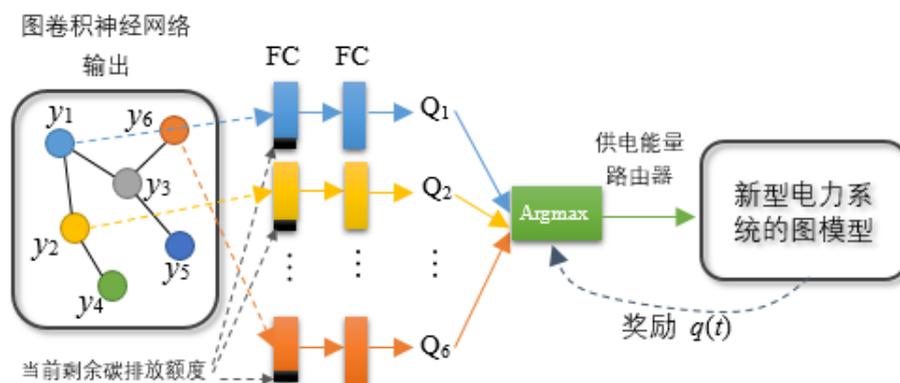


图 5-10 基于 DQN 的供电能量路由器选择

当将 DQN 应用于供电能量路由器选择时，如图 5-10 所示，通过将图卷积神经网络提取的能量路由器特征与剩余碳排放和当前系统时间相结合来构建系统状态。然后构造几个全连接层以分别获得所有能量路由器的 Q 值。选择具有最大 Q 值的能量路由器作为此时的最佳供电能量路由器。

为了评估某一能量路由器节点在某种系统状态下作为供电能量路由器的合适程度，在 t 时刻选择第 i 个能量路由器作为供电能量路由器的奖励函数被定义为：

$$q(t) = -\left(\alpha C_{price}(t) + \beta C_{carbon}(t)\right) (\Delta P(t) + J_{path:v_s \rightarrow v_l}) \Delta t \quad (5-17)$$

式中， $q(t)$ 是第 t 时刻的奖励， $J_{path:v_s \rightarrow v_l}$ 是传输线路上的损失，将在能量路由的选择过程中计算得到。然后，一整天的累积奖励 Q_π 由下式计算得到：

$$\begin{aligned} Q_\pi(t) &= q(t) + \gamma_Q Q_\pi(t+1) \\ Q_\pi(T) &= q(T) - p_1 - p_2 \end{aligned} \quad (5-18)$$

式中， π 为整天的购电策略， T 是当天的终止时刻， γ_Q 是 DQN 的奖励衰减系数， p_1 和 p_2 分别是针对公式 (5-8) 和 (5-9) 的惩罚项。

5.3.2.3 基于 Actor-Critic 的能量路由优化

能量路由优化是在考虑每条输电线路的拓扑结构和现有功率的情况下，找到最优的能量传输路径。由于输电线路的状态是动态变化的，因此基于人工智能路由算法比维护静态路由表更适用于新型电力系统场景。同时，路径中下一个节点的选择与前一个节点相关，使用离线更新策略的基于值的 DQN 不再可用。因此，构建了一个基于在线更新策略的强化学习的 Actor-Critic 模型，以获得最优能量路由。

从 DQN 模型获得的供电能量路由器，需要将功率传输到用户负载所在的能量路由器。因此，在每个路由步骤中，所有能量路由器节点的特征、传输线的状态和供电能量路由器的选择结果应包括在 Actor-Critic 模型的输入中。详细输入矩阵如下所示：

$$\begin{bmatrix} \mathbf{f}_1 & r_{s,1} & P_{s,1} & C_{s,1} \\ \mathbf{f}_2 & r_{s,2} & P_{s,2} & C_{s,2} \\ \vdots & \vdots & \vdots & \vdots \\ \mathbf{f}_i & r_{s,i} & P_{s,i} & C_{s,i} \\ \vdots & \vdots & \vdots & \vdots \\ \mathbf{f}_N & r_{s,N} & P_{s,N} & C_{s,N} \end{bmatrix} \quad (5-19)$$

其中， $\mathbf{f}_i \in \mathbb{R}^{1 \times n}$ 是由图卷积神经网络得到的第 i 个能量路由器的特征。 $r_{s,i}$ 、 $P_{s,i}$ 和 $C_{s,i}$ 分别是当前能量路由器节点和第 i 个能量路由器节点间线路的阻抗、现有功率和线路容量。如果没有线路连接， $r_{s,i}$ 、 $P_{s,i}$ 和 $C_{s,i}$ 将被置为 0。

然后，如图 5-11 所示，构建全连接层以提取所有能量路由器节点的特征，分

别用于动作生成和奖励评估。为了获得电能传输的下一个能量路由器,通过 softmax 函数使用与供电能量路由器连接的节点的最终特征来计算 Actor 网络的输出。通过融合所有节点特征来评估动作的回报,从而获得 Critic 网络的输出。

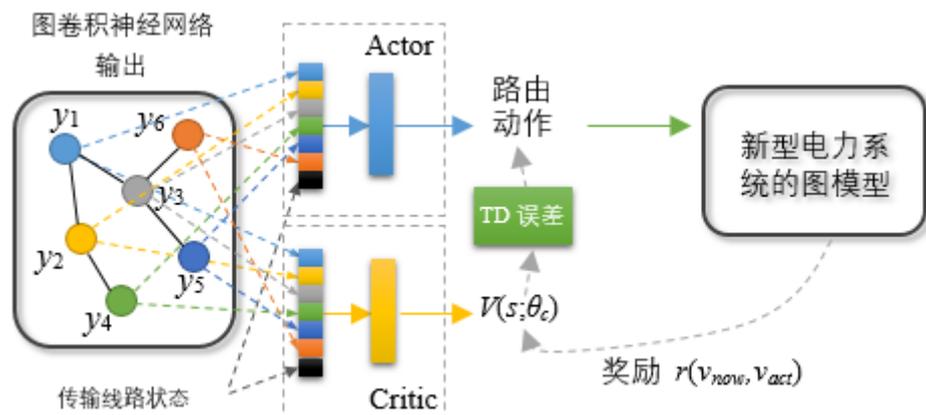


图 5-11 基于 Actor-Critic 的能量路由优化

在采取能量传输动作后,供电能量路由器将被更改为传输动作对应的能量路由器,路由动作的奖励定义为:

$$r(v_{now}, v_{act}) = -C_{v_{act}} - C_{v_{now}, v_{act}} \quad (5-20)$$

式中, v_{now} 为要传输的能量所在的当前能量路由器, v_{act} 为传输动作对应的能量路由器, v_{act} 将接收 v_{now} 传输的能量,并进入下一步的能量路由步骤。

对于完整的路由路径,每个路由步骤的累积奖励定义为:

$$R(v_{now}, v_{act}) = r(v_{now}, v_{act}) + \gamma_{ac} R(v_{act}, v'_{act}) - \gamma P_{loss}$$

$$R(v_c, v_l) = r(v_c, v_l) - p_3 + r_4 - P_{loss} \quad (5-21)$$

式中, γ_{ac} 为 Actor-Critic 网络的累积奖励系数, p_3 对重复的能量路由动作的惩罚项, r_4 为完成能量传输的奖励项, P_{loss} 是路由路径的总功率损耗,用于使 Actor-Critic 模型找到功率损耗较小的路径。 γ 是 P_{loss} 的权重, v'_{act} 是能量路由器 v_{act} 下一步的传输目标。

5.3.2.4 多任务深度强化学习模型的训练策略

图 5-12 展示了所提出的多任务深度强化学习方法的训练策略。实线表示正向过程,虚线表示新型电力系统环境返回的值,点划线表示反向传播过程。

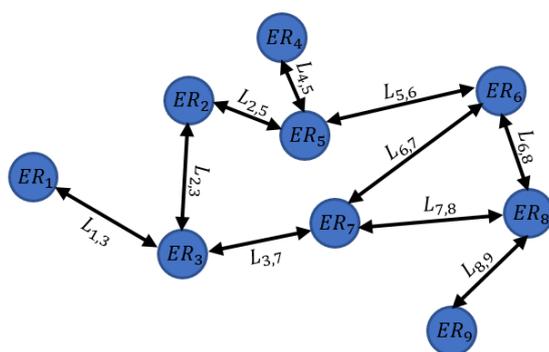


图 5-13 新型电力系统的无向图模型

如表 5-1 所示，每个可供电的能量路由器配置有不同类型和比例的能源，默认情况是发电方和用户各承担一半的碳排放。同时，能源也影响所提供的最大电量。使用煤炭资源的火力发电厂具有持续的电力供应，但光伏资源只能在白天提供足够的能源供应，这也在选择供电能量路由器时予以考虑。图 5-14 显示了一些典型能量路由器一天内的价格和碳排放曲线。可以看出，能量路由器 7 的煤炭资源总量始终保持低价格但碳排放较高。具有光伏资源的能量路由器 2 在白天具有很低的碳排放，而具有 80%风力发电资源的能量路由器 6 在全天具有较低的碳排放。图 5-15 显示了五天中能量路由器 1 的功率需求曲线，用于多任务深度强化学习模型的训练。

表 5-1 能量路由器的发电配置

能量路由器编号	可用功率 (kW)	发电能源 / 比例	价格 (\$ / kWh)	碳排放 (kg / kWh)
ER 2	50 ~ 70	光伏 20% 煤电 80%	0.15 ~ 0.25	0.13 ~ 0.4
ER 3	35 ~ 70	光伏 50% 煤电 50%	0.15 ~ 0.26	0.1 ~ 0.38
ER 4	25 ~ 75	光伏 70% 煤电 30%	0.16 ~ 0.26	0.06 ~ 0.37
ER 5	35 ~ 50	风电 50% 煤电 50%	0.18 ~ 0.26	0.2 ~ 0.3
ER 6	30 ~ 50	风电 80% 煤电 20%	0.18 ~ 0.26	0.19 ~ 0.23
ER 7	80	煤电 100%	0.15 ~ 0.22	0.4 ~ 0.44
ER 8	25 ~ 60	风电 50% 光伏 50%	0.18 ~ 0.27	0.05 ~ 0.13
ER 9	55 ~ 75	风电 20% 光伏 20%	0.17 ~ 0.24	0.19 ~ 0.33

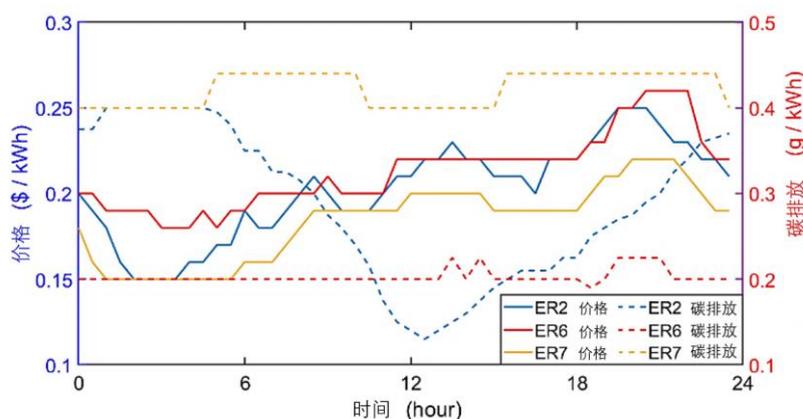


图 5-14 能源互联网电价及碳排放曲线

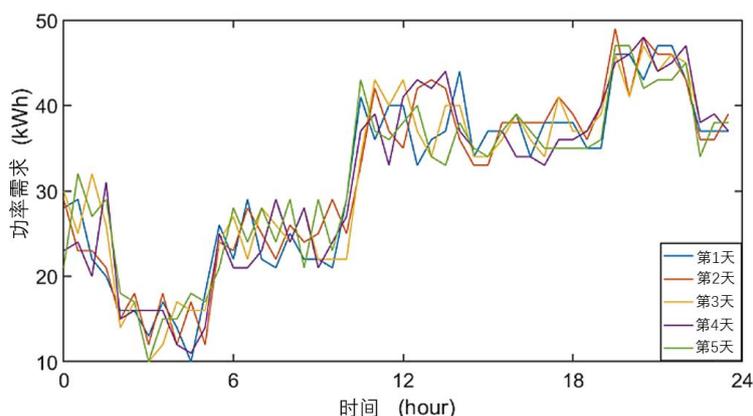


图 5-15 能量路由器 1 的功率需求曲线

5.3.3.1 多任务深度强化学习模型构建

基于图 5-13 所示的新型电力系统的图模型，构建了多任务深度强化学习模型，其结构如表 5-3 所示，包括图卷积神经网络、 Q 网络、Actor 网络和 Critic 网络。首先，建立具有三个图卷积层的图卷积神经网络来提取新型电力系统的实时状态。图卷积神经网络参数的第一维表示切比雪夫多项式的阶数。图卷积神经网络中使用的邻接矩阵构造如下：

$$A_{i,j} = \begin{bmatrix} 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix} \quad (5-22)$$

其中，1 表示在能量路由器 i 和能量路由器 j 之间存在传输线路。然后 Q 网络由三个完全连接的层构成。 Q 网络的输入是由图卷积神经网络提取的 8 个供电能量路由器的特征。最后，分别用两个完全连接的层构 Actor 网络和 Critic 网络。actor 和 critic 网络的输入结合了图卷积神经网络提取的特征、供电能量路由器和传输线路的状态。

表 5-3 多任务深度强化学习模型结构

模块	层	参数	输入	输出
图卷积神经网络	图卷积层	$3 \times 5 \times 10$	9×5	9×5
	图卷积层	$3 \times 10 \times 10$	9×10	9×10
	图卷积层	$3 \times 10 \times 10$	9×10	9×10
Q 网络	全连接层	$8 \times 10 \times 10$	8×10	8×10
	全连接层	$8 \times 10 \times 5$	8×10	8×5
	全连接层	$8 \times 5 \times 1$	8×5	8×1
Actor 网络	全连接层	13×5	9×13	9×5
	全连接层	5×1	9×5	9×1
Critic 网络	全连接层	13×1	9×13	9×1
	全连接层	9×1	9×1	1

5.3.3.1 多任务深度强化学习模型构建

多任务深度强化学习模型是在一台具有 i7-8700 CPU、16GB 内存和 GTX 1070 GPU 的计算机上，在 python 环境中使用 tensorflow 进行构建和训练的。训练过程在大约 25000 个周期后实现收敛。供电能量路由器选择的任务的奖励曲线如图 5-16 所示。可以看出，在前几个时期的不稳定探索过程之后，训练过程在最后 2000 个时期平稳收敛。前几轮的奖励波动较大是因为搜索率较大。每次的奖励是公式 (5-20) 的归一化值。图 5-16 (b) 展示了 Actor-Critic 网络训练期间的 TD 误差曲线。TD 误差的绝对值逐渐减小到零，这意味着 Critic 网络可以准确地评估参与者网络生成的动作的回报。

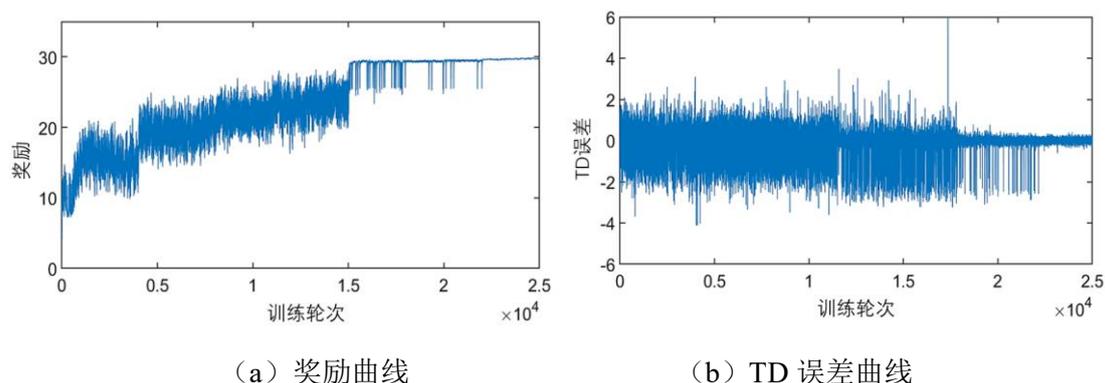


图 5-16 奖励及 TD 误差曲线

图 5-17 显示了 Q 网络在不同碳排放限制下获得的供电能量路由器选择策略。可以看出，较低碳排放限制使得具有低碳排放的能量路由器如 ER3 和 ER8，更有可能被选择。在较高碳排放限制下，低价格的能量路由器，如 ER7 和 ER9，是更好的选择。同时，最受选择的供电能量路由器是 ER 3，其价格相对较低，碳排放可接受。夜间，光伏比例较高的 ER 4 可能无法满足能源需求。因此，更可能选择风电比例较高的 ER 6。

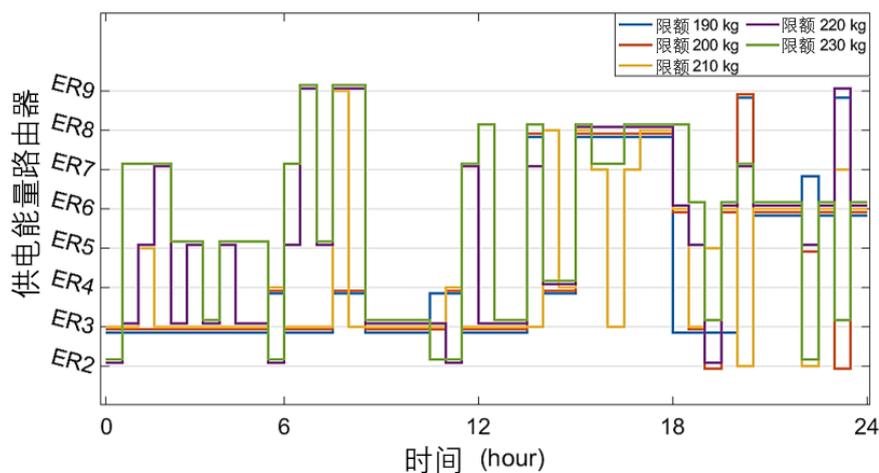


图 5-17 不同碳排放限额下供电能量路由器选择

在能量路由优化部分，表 5-4 列出了最常用的能量路由路径及其在每个能量路由器中被选择的比例。为了比较，还列出了由 Dijkstra 算法^[118]获得的能量路由路径。可以看出，所提出的方法在大多数情况下获得完全相同的能量路由。一些路由路径直观地不是短路径，但由于一些线路可能具有负权重，通过这些线路的电力传输将减少总功率损耗，这可以被视为整个新型电力系统中的能量传输的优化。该方法和 Dijkstra 算法的平均功率损耗分别为 3.28 kW 和 3.39 kW，这意味着该方法将能量传输效率提高了 3%。

表 5-4 不同方法得到的能量路由路径对比

供电能量 路由器	GCN + Actor-Critic 方法 能量路由路径 (比例)	Dijkstra Algorithm 算法 能量路由路径 (比例)
ER 2	2 -> 3 -> 1 (80%) 2 -> 5-> 6 -> 7 -> 3 -> 1 (20%)	2 -> 3 -> 1 (91%) 2 -> 5-> 6 -> 7 -> 3 -> 1 (9%)
ER 3	3 -> 1 (100%)	3 -> 1 (100%)
ER 4	4 -> 5 -> 2 -> 3 -> 1 (100%)	4 -> 5 -> 2 -> 3 -> 1 (95%) 4 -> 5-> 6 -> 7 -> 3 -> 1 (5%)
ER 5	5 -> 2 -> 3 -> 1 (77%) 5-> 6 -> 7 -> 3 -> 1 (23%)	5 -> 2 -> 3 -> 1 (69%) 5-> 6 -> 7 -> 3 -> 1 (31%)
ER 6	6 -> 7 -> 3 -> 1 (53%) 6 -> 8 -> 7 -> 3 -> 1 (47%)	6 -> 7 -> 3 -> 1 (47%) 6 -> 8 -> 7 -> 3 -> 1 (53%)
ER 7	7 -> 3 -> 1 (54%) 7 -> 6 -> 5 -> 2 -> 3 -> 1 (46%)	7 -> 3 -> 1 (63%) 7 -> 6 -> 5 -> 2 -> 3 -> 1 (31%) 7 -> 8 -> 6 -> 5 -> 2 -> 3 -> 1 (6%)
ER 8	8 -> 7 -> 3 -> 1 (56%) 8 -> 6 -> 5 -> 2 -> 3 -> 1 (39%) 8 -> 7 -> 6 -> 5 -> 2 -> 3 -> 1 (5%)	8 -> 7 -> 3 -> 1 (61%) 8 -> 6 -> 5 -> 2 -> 3 -> 1 (39%)
ER 9	9 -> 8 -> 7 -> 3 -> 1 (69%) 9 -> 8 -> 6 -> 5 -> 2 -> 3 -> 1 (15%) 9 -> 8 -> 7 -> 6 -> 5 -> 2 -> 3 -> 1 (15%)	9 -> 8 -> 7 -> 3 -> 1 (64%) 9 -> 8 -> 6 -> 5 -> 2 -> 3 -> 1 (18%) 9 -> 8 -> 7 -> 6 -> 5 -> 2 -> 3 -> 1 (18%)

同时，在某些情况下，所提出的方法可以规划比 Dijkstra 算法更好的能量路由路径。如图 5-18 所示，线上的数字和箭头指示现有能量传输的大小和方向。为了将 43 kW 功率从 ER 6 传输到 ER 1，Dijkstra 算法给出红色标出的路由路径，这似乎是最短的路由路径，因为传输线路 $L_{3,7}$ 的现有功率比 $L_{2,3}$ 小得多。然而，由于传输线路 $L_{2,5}$ 和 $L_{5,6}$ 具有相反方向的能量流，通过线路 $L_{2,5}$ 和 $L_{5,6}$ 的电力传输路径将具有负功率损耗，这是 Dijkstra 算法无法进行处理的。通过提出的方法获得的黄色路由的功率损耗为 4.75kW，比红线的功率损耗 5.07kW 低 0.32kW。同时，根据能量路由过程之前的总传输功率计算 Dijkstra 算法中的线路权重。权重不能反映先前路由路径中的传输功率损失，这也导致在某些情况下能量路由不是最优的。

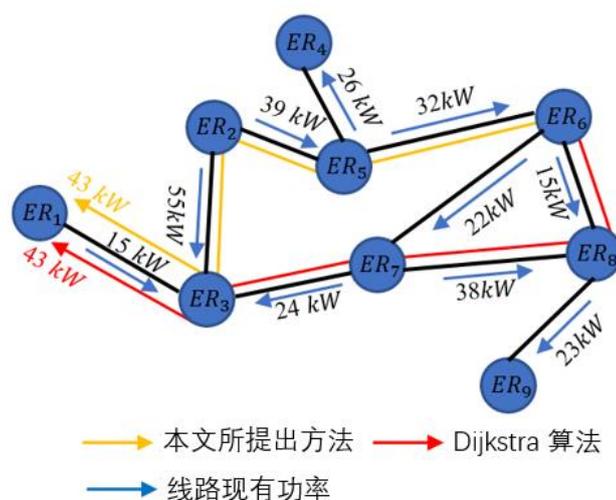


图 5-18 特定情况下不同方法获得的能量路由策略

综上所述，所提出的多任务深度强化学习方法可以获得供电能量路由器选择和能量路由的最优策略。在现场实现中，经过训练的多任务强化学习模型可以部署在能量路由器上。然后，对于本地区的新增的负荷需求，能量路由器可以根据新型电力系统的实时状态采取最优的能源购买和路由策略。

5.4 新型轨道交通供电系统综合能效优化

在轨道交通系统运行过程中，列车刹车时列车电机产生可大量再生制动能量，可再生制动能量的合理回收利用可以使牵引供电能效提高。如果不加利用，反而引起牵引网直流母线电压的升高，需要安装制动电阻来吸收过多的制动能量，来保持直流母线电压的稳定。目前可再生制动能量的利用方式有电池储能、超级电容储能、逆变回馈等。电池、超级电容等储能型的利用方式在列车制动引起母线电压升高时，吸收并存储多余的可再生制动能量，同时可以在列车启动引起母线电压时释放能量，但频繁的能量交换会带来能量损失，并引起储能设备的损耗，在储能配置不合理的情况下，由于储能容量的限制，还有可能造成可再生制动能量的浪费。逆变回馈直接将可再生制动能量通过逆变装置传送到牵引变电站的中压交流网络，能量损失较小，但由于逆变装置中电力电子设备会产生较多的谐波，会对电能质量产生影响。

因此，为了综合利用储能和逆变回馈的优势，本节提出了一种基于序优化和果蝇算法的储能及逆变回馈装置协同优化方法，通过对储能及逆变回馈装置的优化，实现了可再生制动能量的最大化利用和直流母线电压的稳定。

5.4.1 储能及逆变能馈协同优化控制

储能和逆变能馈装置是列车再生制动能量利用的两种主要方式，因其利用原理不同，每种方式都有各自的优势。储能系统可以吸收制动能量，并在列车启动时通过放电维持直流母线电压的稳定，但存在着设备寿命的问题。逆变能馈直接将制动能量传回中压网络，效率较高，但会产生谐波影响电能质量。如能综合利用两种方式的优点，则有助于达到能效和电能质量的协同最优。

储能和逆变能馈分别采用双向变换器和电压型逆变器这两个功率变换器，当列车启动时，直流牵引网电压低于预设值时，储能通过双向变换器开始放电，一定程度上防止直流牵引网电压的跌落，当列车再生制动时，分为并网优先和储能优先两种情况。如何优选这两种控制策略，以及如何设置合理的储能及逆变能馈开启电压，以达到能效和直流网压的最优，是亟待解决的问题。

1) 并网优先控制：列车再生制动使直流牵引网电压超过并网系统的预设值时逆变器启动，把再生制动能量首先回馈给交流电网，当直流牵引网电压超过储能系统的预设值时，储能装置启动，并网逆变器不工作，再生制动能量通过双向变换器储存到储能装置中；

2) 储能优先控制：列车再生制动使直流牵引网电压超过储能系统的预设值时，储能装置首先启动，此时再生制动能量通过双向变换器储存到储能装置中，当直流牵引网电压超过并网系统的预设值时，并网逆变器工作，储能装置不工作，再生制动能量回馈给交流电网。

目前对于再生制动能量处理装置的控制，一般通过设定固定的开启电压。在直流母线电压大于设定值 U_{\max} 时，开始投入储能、逆变能馈，当母线电压低于某一设定值 U_{\min} 时，储能放电。 U_{\max} 通常设置为高于直流侧空载电压 20~30V， U_{\min} 为低于直流侧空载电压 20~30V。现场的开启电压的设置依赖于运行经验，文献中也有对储能和逆变能馈控制优化方面的研究。在储能方面，文献[123]提出了一种基于遗传算法的储能充放电电压阈值的优化方法，以能效最优为目标，实现了在线的充放电电压阈值调整。文献[124]基于一种对储能的电流电压双环控制方法，通过动态调整充放电电压阈值实现了节能的目标。文献[125]使用深度 Q 学习的方法实现了储能充放电阈值的动态调整，但由于深度强化学习的不稳定性，作者只在轨道交通系统 6 分钟的运行时间内验证了其效果。相对于储能的优化，目前对于逆变能馈装置的研究多集中于容量和选址优化方面^{[126][127]}，有关开启阈值的研究文献则较少。同时，现有文献很少考虑储能、逆变能馈同时投入的情况，没有文献明确给出开启电压的高低次序以及准确的电压阈值设定^[128]，因此无法保证交直流供电系统在最优能效下运行。

5.4.2 优化问题描述

为了获得精准的储能及逆变能馈开启电压阈值设定，不应使用简化的数学模型进行求解，本章使用了交直流仿真模型作为对真实交直流供电系统的仿真，并提出了基于果蝇算法的序优化方法对该问题进行求解。首先，对该优化问题的描述为下：

优化目标：牵引供电能耗最小，直流母线电压稳定性最高：

$$\begin{aligned} \min J &= J_1 + \alpha J_2 \\ J_1 &= \sum_{i=1}^n \int_0^T P_i(t) dt, \quad J_2 = \sum_{i=1}^n \int_0^T [U_i(t) - U_0] dt \end{aligned} \quad (5-23)$$

其中， J_1 、 J_2 分别为牵引供电能耗和直流母线电压稳定性的优化目标， α 为优化目标的重要性系数； n 为牵引变电站数量， $P_i(t)$ 和 $U_i(t)$ 分别为第 i 个牵引变电站在时刻 t 的功率和直流母线电压， U_0 为直流母线空载电压， T 为牵引供电系统的总运行时间。

决策变量：储能装置的充电阈值电压 U_{charge} 、放电阈值电压 $U_{discharge}$ ，能馈的开启电压 U_{feed} 、中止电压 U_{feed0} 。

约束条件：储能装置容量、数量、位置和充电功率限制，牵引变电站配置，交直流供电网络结构。

5.4.3 基于序优化和果蝇算法的储能及能馈装置协同优化方法

通常的优化问题会转化为方程组的形式进行求解，但供电系统结构复杂，很难用一组公式来描述供电系统模型。同时，为了保证能效计算的准确性，上述优化问题被当做仿真优化问题进行求解，考虑到列车时刻表对供电系统的影响，每一次完整的能效仿真需要 20 个小时的时间，如果直接用启发式算法寻找最优解，将带来很大的计算消耗。因此，本项目使用序优化方法对该优化问题进行求解，序优化先在庞大的候选输入中随机选取一个子集；然后用一个粗糙模型进行两两性能比较得到这个子集的前 n 个候选值；再用一个精细模型评估刚刚选出来的这 n 个候选输入哪个是性能最好的。基于序优化的思想，储能及逆变能馈装置协同优化方法的流程如图 5-19 所示，对每个步骤的具体描述如下：

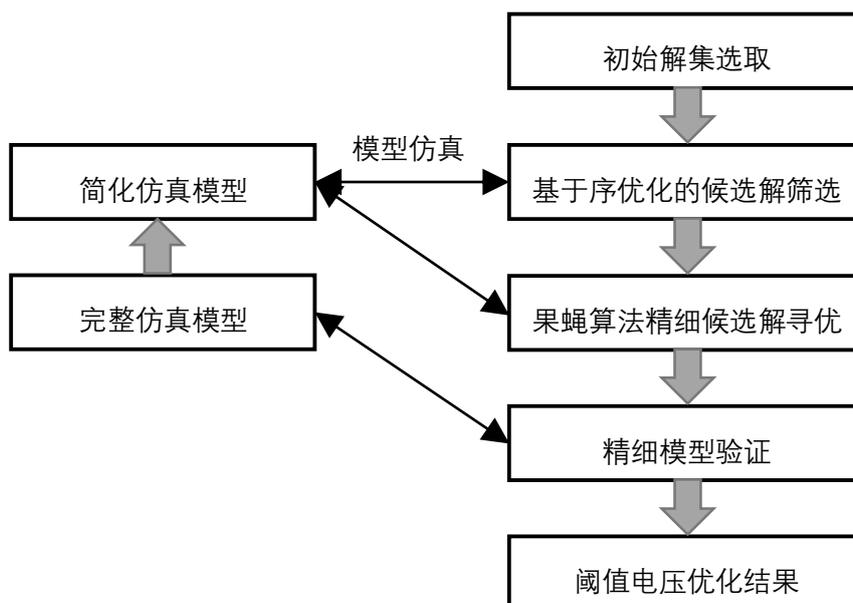


图 5-19 储能及逆变能馈装置协同优化方法流程

(1) 轨道交通供电仿真模型简化

在供电仿真模型中，仿真时段、仿真步长和收敛精度是影响仿真速度的主要因素。因此，在简化模型的构建中，使用缩短仿真时段、增大步长、降低收敛精度等措施加快仿真速度。

(2) 初始解集选取及简化模型仿真

在每个决策变量的可行范围内，等间隔抽取多个候选值，将多个决策变量的候选值进行组合，得到初始解的集合。进而使用简化模型对初始解集中的所有初始解进行仿真。

(3) 候选解筛选

对初始解集得到的仿真模型进行分析，在牵引供电和直流母线电压这两个优化目标上，对所有初始解集的表现进行排序。如果存在支配解，将支配解加入候选解的集合，然后选择每个优化目标上最优的前 n 个解加入候选解集。

(4) 基于果蝇算法的精细候选解寻优

以每个候选解作为果蝇种群的初始位置，在给定迭代次数内，以较小的搜索步长，使用果蝇算法在每个候选解附近寻找更优的候选解，最为更精细的候选解。果蝇寻优算法的主要流程如下^[129]：

- 1) 果蝇种群初始化。确定种群规模、最大迭代数 maxgen 等参数，并根据候选解初始化每个优化参数的果蝇种群的初始位置 $(X_{\text{axis}}^k, Y_{\text{axis}}^k)$ ，其中 $k=1, 2, 3, 4$ 为优化参数的索引。
- 2) 种群随机搜索。在第 i 轮迭代中，设定迭代过程中果蝇个体在嗅觉觅食阶

段的随机飞行方向和搜索步进值（距离）。设定两个搜索方向的随机数 (R_x, R_y)，则有：

$$\begin{cases} X_i^k = X_{i-1}^k + R_x^k \\ Y_i^k = Y_{i-1}^k + R_y^k \end{cases} \quad (5-24)$$

- 3) 初步计算。因为现在不能知道食物源的具体方位，所以，只有通过计算个体距离坐标原点的距离 $Dist_i$ 进而求得味道浓度的判定值 S_i 。具体公式如下：

$$\begin{cases} Dist_i^k = \text{sgn}(X_i^k Y_i^k) \sqrt{X_i^{k2} + Y_i^{k2}} \\ S_i^k = 1/Dist_i^k \end{cases} \quad (5-25)$$

其中， $\text{sgn}()$ 为符号函数，是对原始果蝇算法的改进，使果蝇群体具备了向负方向搜索的能力。

- 4) 根据味道浓度的判定值 S_i ，将其代入味道浓度判断函数，计算当前每个果蝇个体的气味浓度值 $smell_i$ ：

$$smell_i = \text{function}(S_i^1, S_i^2, S_i^3, S_i^4) \quad (5-26)$$

其中， $\text{function}()$ 在本方法中为仿真模型，输出值为能效和直流母线电压稳定性的综合评价。

- 5) 根据气味浓度值，找出当前种群中气味浓度最低的果蝇个体：

$$[bestSmell, bestindex] = \min(smell_i) \quad (5-27)$$

- 6) 视觉定位。记录并保留最佳味道浓度值 $bestSmell$ 和此时的最优果蝇个体坐标(X, Y)，与此同时，整个果蝇种群利用敏锐的视觉飞往最优个体位置：

$$\begin{aligned} Smell_{best} &= bestSmell \\ X_{axis}^k &= X^k(bestindex) \\ Y_{axis}^k &= Y^k(bestindex) \end{aligned} \quad (5-28)$$

- 7) 迭代寻优。首先判断是否达到终止条件 $i = \maxgen$ 。当 $i < \maxgen$ 时，则重复 2) ~ 5)，并判断此时的最佳味道浓度值是否优于前一次迭代的最佳味道浓度，若是则执行 6)，若否则继续重复步骤 2) ~ 5)，循环该过程。直到当 $i = \maxgen$ 时，结束算法。

(1) 寻优结果精细模型验证

将所有精细候选解输入精细模型进行仿真，根据对两个优化目标的重要性判断，选取仿真结果中在最优的策略作为储能装置和逆变能馈的阈值电压。

5.4.4 仿真优化实验及结果分析

按照上述提出的基于序优化和果蝇算法的协同优化方法，对储能及逆变能馈开启电压阈值设定问题进行了求解，在该实验中，超级电容作为储能装置。在模型

简化过程中，将仿真时段限制在 4000 秒，至少覆盖了一辆列车的全程运行，仿真步长放大到了 0.2 秒，在每个步长内进行 2 次仿真，收敛精度设置为 10^{-3} 。在经过简化后，仿真模型能在 20 分钟左右给出仿真结果，以及单个电压策略在能效和电压稳定性上的表现。

在初始解的选择上，设定 U_{charge} 范围为[1680V,1730V]， $U_{discharge}$ 范围为 [1570V,1620V]， U_{feed0} 范围为[1680V,1730V]， U_{feed} 为高于 U_{feed0} [0V,15V]。进而以 10V 为间隔， U_{feed} 以 5V 为间隔，获取每个决策变量的可选值，因此，总共获得了 $6^3 \times 4 = 864$ 个初始解，并使用粗糙模型对所有初始解进行了仿真。在按照超级电容和逆变能馈分别进行统计后，得到各决策变量对能效和直流母线电压稳定性的影响如下图：

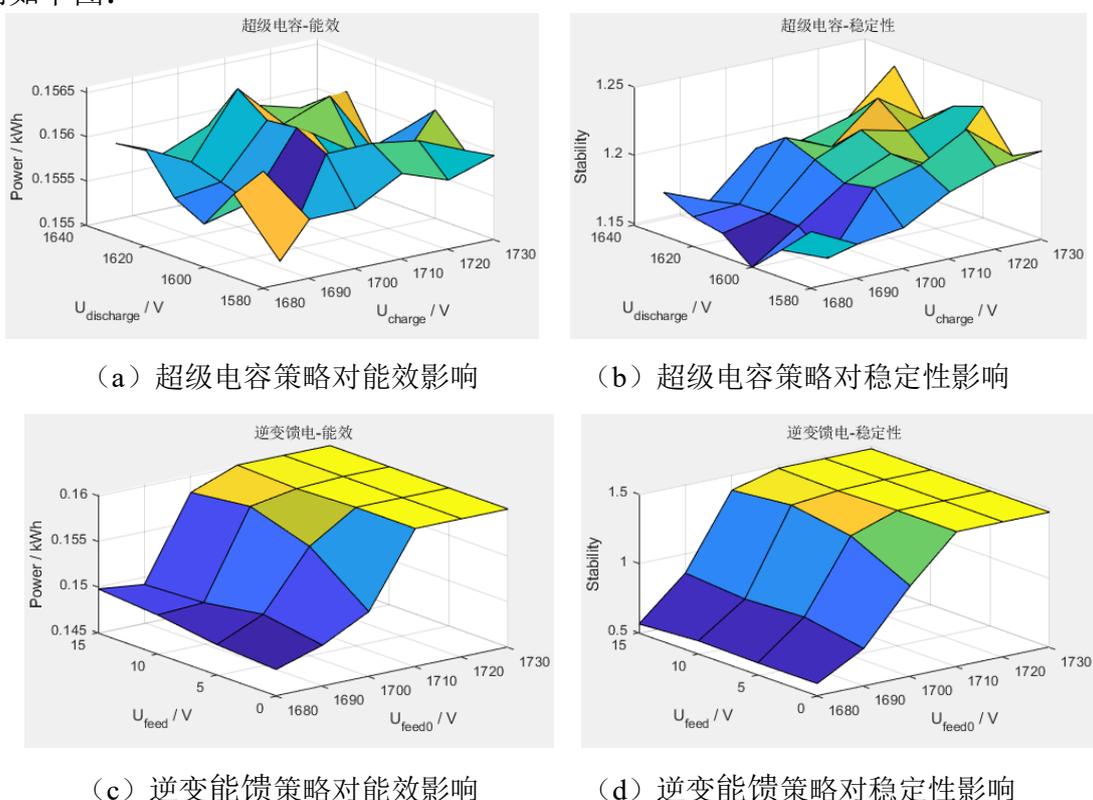


图 5-20 决策变量对控制目标的影响

在上图中，power 和 stability 分别对应两个优化目标 J_1 和 J_2 ，因此 power 和 stability 越小，说明控制效果越好。可以看出，超级电容充电电压和放电电压分别在[1680V, 1700V]和[1590V, 1610V]范围时，逆变能馈开启电压在 1680V 时，能效和电压稳定性较好，优选的初始解如表 5-4 所示。

表 5-4 优选的初始解

序号	$U_{discharge}$	U_{charge}	U_{feed0}	U_{feed}	Power	Stability
1	1630	1680	1680	1685	0.1640	0.2734

2	1590	1720	1680	1685	0.1643	0.2876
3	1580	1710	1680	1685	0.1646	0.2897
4	1610	1720	1680	1690	0.1647	0.2928
5	1610	1680	1680	1690	0.1649	0.2815
6	1610	1700	1680	1695	0.1650	0.2771
7	1590	1730	1680	1685	0.1654	0.2883
8	1580	1730	1680	1685	0.1657	0.3021
9	1580	1720	1680	1685	0.1657	0.2880
10	1630	1680	1680	1690	0.1657	0.2726

从表中可以看出，逆变能馈的开启电压比超级电容充电电压都要略高，这表明了超级电容优先的控制策略整体效果较好。为了获得更精细的解，使用果蝇算法以每个优选的初始解为基础，在一定范围内进行寻优。每个果蝇种群经过 10 代的寻优，对优选初始解进行了修正，每个果蝇种群获得的精细优选解如表 5-5 所示，从中可以看出修正后的优选解比表 5-4 中有高的能效。

表 5-5 精细优选解

序号	$U_{discharge}$	U_{charge}	U_{feed0}	U_{feed}	Power	Stability
1	1630	1680	1680	1685	0.1629	0.2734
2	1590	1720	1681	1686	0.1629	0.2877
3	1580	1711	1680	1685	0.1630	0.2897
4	1610	1720	1680	1690	0.1626	0.2739
5	1613	1680	1680	1690	0.1633	0.2707
6	1610	1700	1680	1695	0.1636	0.2850
7	1590	1730	1680	1685	0.1640	0.2883
8	1580	1730	1680	1685	0.1636	0.3021
9	1580	1720	1680	1685	0.1642	0.2880
10	1630	1681	1679	1689	0.1632	0.2859

进一步地，将所有精细的优选初始解带入完整的供电仿真模型进行仿真，获得的最优解及对应的总能耗及稳定性如表 5-6。

表 5-6 精细优选解在供电仿真模型的验证结果

序号	$U_{discharge}$	U_{charge}	U_{feed0}	U_{feed}	Power	Stability
1	1630	1680	1680	1685	0.1620	0.3244
2	1590	1720	1681	1686	0.1617	0.3223
3	1580	1711	1680	1685	0.1620	0.3349
4	1610	1720	1680	1690	0.1629	0.3191
5	1613	1680	1680	1690	0.1630	0.3341
6	1610	1700	1680	1695	0.1634	0.3197
7	1590	1730	1680	1685	0.1617	0.3326
8	1580	1730	1680	1685	0.1621	0.3352
9	1580	1720	1680	1685	0.1624	0.3268
10	1630	1681	1679	1689	0.1626	0.3195

从表中可以看出，在完整的仿真模型上，获得的能效评价和简化模型略有不同，

这是因为简化模型更多的包含了列车数较少的时间段，但都集中在较小的范围内，这说明了所提出方法的可靠性。最终，综合能耗和稳定性指标，选取第 2 组电压配置，即[1590V, 1720V, 1681V, 1686V]，作为最终的超级电容和逆变能馈装置的开启电压配置。

综上所述，本节提出了一种储能和逆变能馈装置的协同优化方法，以可再生制动能量利用的最优和直流母线的电压稳定性为优化目标，实现了储能和逆变能馈开启电压的优化配置。该方法基于序优化的思想，首先使用简化的仿真模型对候选解区间进行排序，进而以较优的候选解为初始值，使用果蝇算法对较优候选解的临近区间进行搜索调优，最终使用完整的仿真模型对调优后的候选解进行评价和选择。基于青岛 11 号线仿真模型的优化实验表明，该方法获取的储能和逆变能馈开启电压的设置可以在保证直流母线电压稳定的前提下，充分利用可再生制动能量，取得最优的供电能效。

5.5 本章小结

本章进行了新型电力系统综合能效优化方面的研究，首先，开发了一套电力系统潮流仿真系统，为能效优化研究提供了基础。然后，提出了一种基于图神经网络和深度强化学习的能量路由器能量传输路径优化算法，实现了考虑碳排放因素的情况下，新型电力系统中最优供电节点和能量传输路径的选择。最后，提出了一种基于序优化和果蝇算法的轨道交通交直流供电系统的能效优化算法，通过对储能和逆变能馈装置开启电压的优选，实现了列车轨道交通供电系统全天运行过程中稳定运行及能效最优。

6. 总结与展望

6.1 论文工作总结

为保障新型电力系统的高效、安全、稳定运行，本研究基于人工智能算法，提出了新型电力系统状态评估、故障诊断以及能效优化算法。本文的主要研究工作可总结为以下几个方面：

(1) 提出了一种基于图卷积神经网络和异构数据融合的新型电力系统状态估计方法。该方法利用新型电力系统中的 SCADA 系统和 PMU 系统采集到的多源异构监测数据，并考虑电力系统拓扑结构，使用 GCN 中的邻接矩阵和图卷积运算相邻电力系统节点的多源异构监测数据进行融合和特征提取。最后，通过构造多任务输出，实现了在故障和扰动情况下，新型电力系统高精度的暂态状态估计。

(2) 提出了一种基于改进 GCN 的新型电力系统输电线路故障诊断方法，该方法基于 PMU 监测数据和新型电力系统拓扑，构造卷积神经网络模块提取各节点 PMU 的暂态监测数据，并结合 GCN 对电力系统拓扑的表示，对每个节点及其相邻节点的 PMU 数据中的故障特征进行提取。然后通过构造以电力系统线路特征为输入的多任务分类模块，实现了新型电力系统准确的故障线路的检测、识别和定位。进一步地，提出了一种基于卷积神经网络和异构信息融合的新型电力系统中的发电设备故障诊断方法，实现了风电机组关键传动系统的故障诊断。该方法结合故障机理知识，构造了风电传动链系统领域知识图，并结合改进的多任务卷积神经网络，实现了部件级的风电机组传动链系统的准确故障诊断和定位。

(3) 提出了一种基于多主体深度强化学习和分布式协同控制的无功补偿优化控制框架，为保持新型电力系统故障及扰动情况下的系统稳定性。该方法基于注意力网络，利用动态邻接矩阵表示故障后的新型电力系统拓扑。并对现场实际采集的异构 SCADA 和 PMU 数据进行融合，提取相邻电力系统节点的监测数据中的特征。最终使用深度强化学习方法使每个无功补偿节点的控制器协同得到了最优的无功补偿控制效果。

(4) 开发了一套电力系统潮流仿真系统，并在此基础上进行电力系统能效优化研究。首先，提出了一种基于图神经网络和深度强化学习的能量路由器能量传输路径优化算法，实现了考虑碳排放因素的情况下，新型电力系统中最优供电节点和能量传输路径的选择。其次，提出了一种基于序优化和果蝇算法的轨道交通交直流供电系统的能效优化算法，通过对储能和逆变回馈装置开启电压的优选，实现了列车全天运行过程中的轨道交通系统能效最优。

6.2 研究工作展望

本文基于人工智能算法，考虑新型电力系统的领域知识，针对多个应用场景提出了一系列新型电力系统安全保护及能效优化方法，但还有以下方面值得进一步的研究。

(1) 为增强人工智能算法在工业应用中的通用性和鲁棒性，应在人工智能算法的网络结构和输入过程中，考虑更多的领域知识。本文将电力系统拓扑和部分故障特征知识加入人工智能算法构建过程，但还有很多在专家人工决策中用到的知识没有得到充分利用，如设备参数、历史运行信息等。如何引入更多领域知识，提升人工智能算法效果及安全性，是值得研究的重要方面。

(2) 应紧跟人工智能领域的发展，将更多先进的人工智能方法与电力领域相结合。本文尝试将图神经网络引入电力领域，并取得了一些效果。而在人工智能领域，如 transformer 模型、知识图谱、联邦学习等方面的研究发展迅速，也有和工业领域较好的结合点，需要进一步做深入研究。

(3) 本文研究所使用的数据大多是在实验或仿真情况下获得的，与现场数据分布相差极大，因此，所训练模型在工业现场的有效性是存在疑问的。在进一步的研究中，需要更多的从现场获取真实的监测数据，提升算法在高噪声、数据分布复杂情况下的性能。

参考文献

- [1] 赵冬梅,徐辰宇,陶然,郑亚锐.多元分布式储能在新型电力系统配电侧的灵活调控研究综述[J/OL].中国电机工程学报:1-23[2022-09-08].
- [2] 陈皓勇,谭碧飞,伍亮,林镇佳,杨苹,李立涅.分层集群的新型电力系统运行与控制[J/OL].中国电机工程学报:1-15[2022-09-08].
- [3] 任大伟,肖晋宇,侯金鸣,杜尔顺,金晨,刘耀.双碳目标下我国新型电力系统的构建与演变研究[J/OL].电网技术:1-9[2022-09-08].
- [4] 郭威,张凯,魏新杰,张华铭.高渗透率分布式光伏接入的新型电力系统净功率预测[J/OL].电测与仪表:1-8[2022-09-09].
- [5] 姜鸿飞.基于机器视觉的变电站高压开关柜设备检测与识别研究[D].四川大学,2021.
- [6] 盛戈皞,钱勇,罗林根,宋辉,刘亚东,江秀臣.面向新型电力系统的电力设备运行维护关键技术及其应用展望[J].高电压技术,2021,47(09):3072-3084.
- [7] 陈艳波,高瑜珑,赵俊博,葛磊蛟.综合能源系统状态估计研究综述[J].高电压技术,2021,47(07):2281-2292.
- [8] Angel A D, Geurts P, Ernst D, et al. Estimation of rotor angles of synchronous machines using artificial neural networks and local PMU-based quantities[J]. Neurocomputing, 2007, 70(16-18):2668-2678.
- [9] Netto M, Mili L. Robust Data-Driven Koopman Kalman Filter for Power Systems Dynamic State Estimation[J]. IEEE Transactions on Power Systems, 2018, 33(6):7228-7237.
- [10] 臧海祥,郭镜玮,黄蔓云,卫志农,孙国强,俞文帅.基于深度迁移学习的时变拓扑下电力系统状态估计[J].电力系统自动化,2021,45(24):49-56.
- [11] 穆强.考虑分布式电源的主动配电网分布式状态估计研究[D].南京邮电大学,2021.
- [12] 王泽,张玉敏,吉兴全,徐波,杨明,韩学山.基于深度学习与内核岭回归的电力系统鲁棒状态估计[J].高电压技术,2022,48(04):1332-1342.
- [13] 刘晓莉,曾祥晖,黄翊阳,董凌,张昊天,刘大贵,王学斌,李永光,邓长虹.联合粒子滤波和卷积神经网络的电力系统状态估计方法[J].电网技术,2020,44(09):3361-3367.
- [14] Patnaik B, Mishra M, Bansal R C, et al. MODWT-XGBoost based smart energy solution for fault detection and classification in a smart microgrid[J]. Applied Energy,

- 2021, 285(113503):116457.
- [15] Jayamaha D, Lidula N, Rajapakse A D. Wavelet-Multi Resolution Analysis Based ANN Architecture for Fault Detection and Localization in DC Microgrids[J]. IEEE Access, 2019, 7: 145 371–145 384.
- [16] 黄梓晴. 基于监控信息的电网故障智能辅助诊断方法研究[D].广东工业大学,2022.
- [17] 肖玮. 基于卷积神经网络的电力线路故障诊断研究[D].吉林大学,2021.
- [18] Chen K, Hu J, He J. Detection and Classification of Transmission Line Faults Based on Unsupervised Feature Learning and Convolutional Sparse Autoencoder[J]. IEEE Transactions on Smart Grid, 2016, 9(3):1748-1758.
- [19] James J Q , Hou, Yunhe, et al. Intelligent Fault Detection Scheme for Microgrids With Wavelet-Based Deep Neural Networks[J]. IEEE Transactions on Smart Grid, 2019, 10(2):1694–1703.
- [20] 徐先峰,李芷菡,刘状壮,王轲,马志雄,姚景杰,蔡路路.基于半监督学习标签传播-极端随机树算法的光伏阵列故障诊断及定位[J/OL].电网技术:1-9[2022-09-08].
- [21] 田佳强. 储能锂电池系统健康评估与故障诊断研究[D].中国科学技术大学,2021.
- [22] Jiang G, He H, Yan J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. IEEE Transactions on Industrial Electronics, 2018, 66(4): 3196-3207.
- [23] Anilkumar R, Devriese G, Srivastava A K. Voltage and Reactive Power Control to Maximize the Energy Savings in Power Distribution System with Wind Energy[J]. IEEE Transactions on Industry Applications, 2017, 54(1): 656–664.
- [24] 李凯强. 基于蜂拥算法的智能电网暂态稳定分布式控制研究[D].华东交通大学,2021.
- [25] 朱泓宇. 基于深度学习的电力系统频率稳定紧急控制[D].西南交通大学,2021.
- [26] 田芳,周孝信,史东宇,陈勇,黄彦浩,于之虹.基于卷积神经网络的电力系统暂态稳定预防控制方法[J].电力系统保护与控制,2020,48(18):1-8.
- [27] Bruce J, Suenderhauf N, Mirowski P, et al. One-Shot Reinforcement Learning for Robot Navigation with Interactive Replay[J]. 2017.
- [28] Cao J, Zhang W, Xiao Z, et al. Reactive Power Optimization for Transient Voltage Stability in Energy Internet via Deep Reinforcement Learning Approach[J]. Energies, 2019, 12(8):1556.

- [29] 李柏培,赵津蔓,韩肖清,杨晶.基于双智能体深度强化学习的电力系统静态安全预防控制方法[J/OL].中国电机工程学报:1-13[2022-09-08].
- [30] 莫逆垒. 基于强化学习的微电网最优频率控制研究[D].华中科技大学,2021.
- [31] 夏岩. 基于强化学习的孤岛微电网频率电压控制研究[D].南昌大学,2021.
- [32] 熊珞琳,毛帅,唐漾,孟科,董朝阳,钱锋.基于强化学习的综合能源系统管理综述[J].自动化学报,2021,47(10):2321-2340.
- [33] Jayaraj S, Ahamed T P I, Kunju K B. Application of reinforcement learning algorithm for scheduling of microgrid[C]. Proceedings of the 2019 Global Conference for Advancement in Technology (GCAT). Bangalore, India: IEEE, 2019. 1–5
- [34] Gorostiza F S, Gonzalez-Longatt F M. Deep reinforcement learning-based controller for SOC management of multi-electrical energy storage system[J]. IEEE Transactions on Smart Grid, 2020, 11(6): 5039–5050
- [35] Yu Y J, Cai Z F, Huang Y S. Energy storage arbitrage in gridconnected micro-grids under real-time market price uncertainty: A double-Q learning approach[J]. IEEE Access, 2020, 8: 54456–54464
- [36] Qazi H S, Liu N, Wang T. Coordinated energy and reserve sharing of isolated microgrid cluster using deep reinforcement learning[C]. Proceedings of the 5th Asia Conference on Power and Electrical Engineering (ACPEE). Chengdu, China: IEEE, 2020. 81–86
- [37] Parag Y, Sovacool B K. Electricity market design for the prosumer era[J]. Nature Energy, 2016, 1(4): Article No. 16032
- [38] Ruan L N, Yan Y, Guo S Y, Wen F S, Qiu X S. Priority-based residential energy management with collaborative edge and cloud computing[J]. IEEE Transactions on Industrial Informatics, 2020, 16(3): 1848–1857
- [39] Diyan M, Khan M, Cao Z B, Silva B N, Han J H, Han K J. Intelligent home energy management system based on Bi-directional long-short term memory and reinforcement learning[J]. Proceedings of the 2021 International Conference on Information Networking (ICOIN). Jeju Island, South Korea: IEEE, 2021. 782–787
- [40] Li H P, Wan Z Q, He H B. Real-time residential demand response[J]. IEEE Transactions on Smart Grid, 2020, 11(5): 4144–4154
- [41] Mocanu E, Mocanu D C, Nguyen P H, Liotta A, Webber M E, Gibescu M, et al. On-line building energy optimization using deep reinforcement learning[J]. IEEE

- Transactions on Smart Grid, 2019, 10(4): 3698–3708
- [42] Gao M, Wang K, He L. Probabilistic Model Checking and Scheduling Implementation of an Energy Router System in Energy Internet for Green Cities[J]. IEEE Transactions on Industrial Informatics, 2018, 14(4): 1501-1510.
- [43] Wang K, Li H, Feng Y, et al. Big Data Analytics for System Stability Evaluation Strategy in the Energy Internet[J]. IEEE Transactions on Industrial Informatics, 2017, 13(4): 1969-1978.
- [44] Guo H, Wang F, James G, et al. Graph theory based topology design and energy routing control of the energy internet[J]. IET Generation, Transmission & Distribution, 2018, 12(20).
- [45] Yi P, Zhu T, Jiang B, et al. Deploying Energy Router in an Energy Internet Based Electric Vehicles[J]. IEEE Transactions on Vehicular Technology, 2016, 65(6): 4714-4725.
- [46] Miao J, Zhang N, Kang C, et al. Steady-state Power Flow Model of Energy Router Embedded AC Network and Its Application in Optimizing Power System Operation[J]. IEEE Transactions on Smart Grid, 2017, 9(5): 4828-4837.
- [47] Guo H, Wang F, Zhang L, et al. A Hierarchical Optimization Strategy of the Energy Router-Based Energy Internet[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4177-4185.
- [48] 肖泽青, 华昊辰, 曹军威. 人工智能在能源互联网中的应用综述[J]. 电力建设, 2019, 40(05): 63-70.
- [49] 唐文虎, 牛哲文, 赵柏宁, 季天瑶, 李梦诗, 吴青华. 数据驱动的人工智能技术在电力设备状态分析中的研究与应用[J]. 高电压技术, 2020, 46(09): 2985-2999.
- [50] Z. Li, W. Wu, B. Zhang, et al. Analytical Reliability Assessment Method for Complex Distribution Networks Considering Post-Fault Network Reconfiguration[J]. IEEE Transactions on Power Systems, 2020, 35(2): 1457-1467.
- [51] Li W, Deka D, Chertkov M, et al. Real-Time Faulted Line Localization and PMU Placement in Power Systems Through Convolutional Neural Networks[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4640-4651.
- [52] Cui M, Wang J, Jin T, et al. A Novel Event Detection Method Using PMU Data with High Precision[J]. IEEE Transactions on Power Systems, 2018, 34(1): 454–466.
- [53] Zhang Y, Wang J, Khodayar M E. Graph-based Faulted Line Identification Using Micro-PMU Data in Distribution Systems[J]. IEEE Transactions on Smart Grid,

- 2020, 11(5): 3982–3992.
- [54] Aghaei J, Baharvandi A, Rabiee A, et al. Probabilistic PMU Placement in Electric Power Networks: An MILP-Based Multiobjective Model[J]. IEEE Transactions on Industrial Informatics, 2015, 11(2):332-341.
- [55] Wu Z, Pan S, Chen F, et al. A Comprehensive Survey on Graph Neural Networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019.
- [56] Zhao L, Song Y, Zhang C, et al. T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(9): 3848–3858.
- [57] Yan Z, Ge J, Wu Y, et al. Automatic Virtual Network Embedding: A Deep Reinforcement Learning Approach With Graph Convolutional Networks[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(9):1040-1057.
- [58] Zheng Z, Yang Y, Niu X, et al. Wide and Deep Convolutional Neural Networks for Electricity-Theft Detection to Secure Smart Grids[J]. IEEE Transactions on Industrial Informatics, 2018, 14(4): 1606–1615.
- [59] Guo S, Zhang B, Yang T, et al. Multitask Convolutional Neural Network With Information Fusion for Bearing Fault Diagnosis and Localization[J]. IEEE Transactions on Industrial Electronics, 2020, 67(9):8005-8015.
- [60] Kipf T N, Welling M. Semi-Supervised Classification with Graph Convolutional Networks[J]. 2016.
- [61] Teng H, Liu C, Han M, et al. IEEE9 Buses System Simulation and Modeling in PSCAD[C]. 2010 Asia-Pacific Power and Energy Engineering Conference. IEEE, 2010.
- [62] Zidan A, Khairalla M, Abdrabou A M, et al. Fault Detection, Isolation, and Service Restoration in Distribution Systems: State-of-the-Art and Future Trends[J]. IEEE Transactions on Smart Grid, 2017, 8(5):2170-2185.
- [63] Zhao J, Zhang G, Das K, et al. Power System Real-Time Monitoring by Using PMU-Based Robust State Estimation Method[J]. IEEE Transactions on Smart Grid, 2016, 7(1):300-309.
- [64] Zanjani M, Mazlumi K, Kamwa I. Combined Analysis of Distribution level PMU data with Transmission level PMU for Early Detection of Long Term Voltage Instability[J]. IET Generation, Transmission & Distribution, 2019, 13(16):3634-3641.

- [65] Hl A , Yang W A , Yl B , et al. Distribution grid impedance & topology estimation with limited or no micro-PMUs[J]. International Journal of Electrical Power & Energy Systems, 2021, 129:106794.
- [66] A. Shukla, S. Dutta, and P. K. Sadhu. An island detection approach by μ -pmu with reduced chances of cyber attack[J]. International Journal of Electrical Power & Energy Systems, 2021, 126:106599.
- [67] Affijulla S , Tripathy P . A Robust Fault Detection and Discrimination Technique for Transmission Lines[J]. IEEE Transactions on Smart Grid, 2018, 9(6): 6348–6358.
- [68] Lien K Y , Bui D M , Chen S L , et al. A novel fault protection system using communication-assisted digital relays for AC microgrids having a multiple grounding system[J]. International Journal of Electrical Power & Energy Systems, 2016, 78: 600–625.
- [69] Cui Q , Weng Y . Enhance High Impedance Fault Detection and Location Accuracy via μ -PMUs[J]. IEEE Transactions on Smart Grid, 2020, 11(1):797–809.
- [70] Gush T , Bukhari S , Haider R , et al. Fault detection and location in a microgrid using mathematical morphology and recursive least square methods[J]. International Journal of Electrical Power & Energy Systems, 2018, 102: 324-331.
- [71] Liang X , Wallace S , Nguyen D . Rule-Based Data-Driven Analytics for Wide-Area Fault Detection Using Synchrophasor Data[J]. IEEE Transactions on Industry Applications, 2017, 53(3):1789–1798.
- [72] Eto J , Lasseter R , Schenkman B , et al. CERTS Microgrid Laboratory Test Bed[J]. IEEE Transactions on Power Delivery, 2010, 26(1):325-332.
- [73] Beck D , Haffari G , Cohn T . Graph-to-Sequence Learning using Gated Graph Neural Networks[J]. 2018.
- [74] Defferrard M , Bresson X , Vandergheynst P . Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering[J]. Advances in Neural Information Processing Systems, 2016, 29:3844–3852.
- [75] Hua H , Qin Y , Hao C , et al. Stochastic Optimal Control for Energy Internet: A Bottom-Up Energy Management Approach[J]. IEEE Transactions on Industrial Informatics, 2019, 15(3):1788-1797.
- [76] Kendall A , Gal Y , Cipolla R . Multi-Task Learning Using Uncertainty to Weigh Losses for Scene Geometry and Semantics[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018.

- [77] Mbungu N T , Naidoo R , Bansal R C , et al. Optimisation of grid connected hybrid photovoltaic–wind–battery system using model predictive control design[J]. *Iet Renewable Power Generation*, 2017, 11(14):1760-1768.
- [78] Elforjani M . Diagnosis and prognosis of real world wind turbine gears[J]. *Renewable Energy*, 2020, 147:1676-1693.
- [79] Zhong J H , Zhang J , Liang J , et al. Multi-fault rapid diagnosis for wind turbine gearbox using sparse Bayesian extreme learning machine[J]. *IEEE Access*, 2018, 7:773-781.
- [80] Cheng F , Wang J , Qu L , et al. Rotor-Current-Based Fault Diagnosis for DFIG Wind Turbine Drivetrain Gearboxes Using Frequency Analysis and a Deep Classifier[J]. *IEEE Transactions on Industry Applications*, 2018, 54 (2):1062-1071.
- [81] Jiang G , He H , Xie P , et al. Stacked Multilevel-Denoising Autoencoders: A New Representation Learning Approach for Wind Turbine Gearbox Fault Diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66 (9):2391-2402.
- [82] Wang Z , Wang J , Wang Y . An intelligent diagnosis scheme based on generative adversarial learning deep neural networks and its application to planetary gearbox fault pattern recognition[J]. *Neurocomputing*, 2018, 310(8):213-222.
- [83] Jing L , Wang T , Ming Z , et al. An Adaptive Multi-Sensor Data Fusion Method Based on Deep Convolutional Neural Networks for Fault Diagnosis of Planetary Gearbox[J]. *Sensors*, 2017, 17(2):414.
- [84] Wang T , Han Q , Chu F , et al. Vibration based condition monitoring and fault diagnosis of wind turbine planetary gearbox: A review[J]. *Mechanical Systems and Signal Processing*, 2019, 126(1):662-685.
- [85] Jiang, Guoqian, Haibo, et al. Multiscale Convolutional Neural Networks for Fault Diagnosis of Wind Turbine Gearbox[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66 (4):3196-3207.
- [86] Wei, Teng, Xian, et al. Multi-fault detection and failure analysis of wind turbine gearbox using complex wavelet transform[J]. *Renewable Energy*, 2016, 93:591-598.
- [87] Senanayaka J , Huynh K V , Robbersmyr K G . Multiple Classifiers and Data Fusion for Robust Diagnosis of Gearbox Mixed Faults[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15 (8):4569-4579.
- [88] Liu R , Meng G , Yang B , et al. Dislocated Time Series Convolutional Neural Architecture: An Intelligent Fault Diagnosis Approach for Electric Machine[J].

- IEEE Transactions on Industrial Informatics, 2017, 13 (3):1310-1320.
- [89] C. Zhang, W. Gao, S. Guo, Y. Li, T. Yang, Opportunistic maintenance for wind turbines considering imperfect, reliability-based maintenance[J]. Renewable Energy, 2017, 103:606-612.
- [90] Zhao M , Kang M , Tang B , et al. Deep Residual Networks With Dynamically Weighted Wavelet Coefficients for Fault Diagnosis of Planetary Gearboxes[J]. IEEE Transactions on Industrial Electronics, 2018, 65(5):4290-4300.
- [91] Guo S , Yang T , Gao W , et al. An Intelligent Fault Diagnosis Method for Bearings with Variable Rotating Speed Based on Pythagorean Spatial Pyramid Pooling CNN[J]. Sensors, 2018, 18(11):3857.
- [92] Guo S , Zhang B , Yang T , et al. Multitask Convolutional Neural Network With Information Fusion for Bearing Fault Diagnosis and Localization[J]. IEEE Transactions on Industrial Electronics, 2020, 67(9):8005-8015.
- [93] Wang L , Cai G , Wang J , et al. Dual-Enhanced Sparse Decomposition for Wind Turbine Gearbox Fault Diagnosis[J]. IEEE Transactions on Instrumentation & Measurement, 2018, PP(2):450-461.
- [94] He G , Ding K , Lin H . Gearbox coupling modulation separation method based on match pursuit and correlation filtering[J]. Mechanical Systems and Signal Processing, 2016, 66:597-611.
- [95] Bartelmus W , Chaari F , Zimroz R , et al. Modelling of gearbox dynamics under time-varying nonstationary load for distributed fault detection and diagnosis[J]. European Journal of Mechanics, 2010, 29(4):637-646.
- [97] Liang P , Deng C , Wu J , et al. Compound Fault Diagnosis of Gearboxes via Multi-label Convolutional Neural Network and Wavelet Transform[J]. Computers in Industry, 2019, 113(2):103132.
- [98] Camacho A , Castilla M , Miret J , et al. Reactive Power Control for Distributed Generation Power Plants to Comply With Voltage Limits During Grid Faults[J]. IEEE Transactions on Power Electronics, 2014, 29(11):6224-6234.
- [99] L. Liu, H. Li, Y. Xue, et al. Reactive power compensation and optimization strategy for grid-interactive cascaded photovoltaic systems[J]. IEEE Transactions on Power Electronics, 30(1):188–202.
- [100] T. Sousa, H. Morais, Z. Vale, et al. A multi-objective optimization of the active and reactive resource scheduling at a distribution level in a smart grid context[J].

- Energy, 2015, 85:236–250.
- [101] Tang Z , Hill D , Liu T . Fast Distributed Reactive Power Control for Voltage Regulation in Distribution Networks[J]. IEEE Transactions on Power Systems, 2019, 34(1):802–805.
- [102] Sun Q , Cheng H , Song Y . Bi-Objective Reactive Power Reserve Optimization to Coordinate Long-and Short-Term Voltage Stability[J]. IEEE Access, 2018, 6:13057-13065.
- [103] Shi H , Wen H , Hu Y , et al. Reactive power Minimization in Bidirectional DC-DC converters Using A Unified-Phasor-Based Particles Swarm Optimization[J]. IEEE Transactions on Power Electronics, 2018, 33(12):10 990–11 006.
- [104] M. N. Gilvaei, H. Jafari, et al. A novel hybrid optimization approach for reactive power dispatch problem considering voltage stability index[J]. Engineering Applications of Artificial Intelligence, 2020, 96:103963.
- [105] Morshed M J , Sardoueinassab Z , Fekih A . A coordinated control for voltage and transient stability of multi-machine power grids relying on wind energy[J]. International Journal of Electrical Power & Energy Systems, 2019, 109:95-109.
- [106] Fu T , Wang C , Cheng N . Deep-Learning-Based Joint Optimization of Renewable Energy Storage and Routing in Vehicular Energy Network[J]. IEEE Internet of Things Journal, 2020, 7(7):6229–6241.
- [107] Hua H , Qin Y , Hao C , et al. Optimal energy management strategies for energy Internet via deep reinforcement learning approach[J]. Applied Energy, 2019, 239:598-609.
- [108] Y. Ye, Y. Tang, H. Wang , et al. A scalable privacy-preserving multi-agent deep reinforcement learning approach for large-scale peer-to-peer transactive energy trading[J]. IEEE Transactions on Smart Grid, 2021, 12(6):5185–5200.
- [109] Velikovi P , Cucurull G , Casanova A , et al. Graph Attention Networks[C]// International Conference on Learning Representations. 2018.
- [110] Zhong R , Wang R , Zou Y , et al. Graph Attention Networks Adjusted Bi-LSTM for Video Summarization[J]. IEEE Signal Processing Letters, 2021, 28: 663–667.
- [111] Tian S , Kang L , Xing X , et al. A Relation-Augmented Embedded Graph Attention Network for Remote Sensing Object Detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60:1–18.

- [112] J. Long, R. Zhang, Z. Yang, et al. Self-adaptation graph attention network via meta-learning for machinery fault diagnosis with few labeled data[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71:1–11.
- [113] Ejaz W , Naeem M , Shahid A , et al. Efficient Energy Management for the Internet of Things in Smart Cities[J]. IEEE Communications Magazine, 2017, 55(1):84-91.
- [114] Wang Y , Qiu J , Tao Y , et al. Carbon-Oriented Operational Planning in Coupled Electricity and Emission Trading Markets[J]. IEEE Transactions on Power Systems, 2020, 35(4):3145-3157.
- [115] Zhao N , You F . Can renewable generation, energy storage and energy efficient technologies enable carbon neutral energy transition?[J]. Applied Energy, 2020, 279:115889.
- [116] Jiang D , Zhang P , Lv Z , et al. Energy-Efficient Multi-Constraint Routing Algorithm With Load Balancing for Smart City Applications[J]. IEEE Internet of Things Journal, 2016, 3(6):1437-1447.
- [117] Zhou N , Xie D , Gu C , et al. Coordinated planning of multi-area multi-energy systems by a novel routing algorithm based on random scenarios[J]. International Journal of Electrical Power & Energy Systems, 2021, 131(6):107028.
- [118] Wang R , Wu J , Qian Z , et al. A Graph Theory Based Energy Routing Algorithm in Energy Local Area Network (e-LAN)[J]. IEEE Transactions on Industrial Informatics, 2017, 13(6):3275-3285.
- [119] Guo H , Wang F , Li L , et al. A Minimum Loss Routing Algorithm Based on Real-Time Transaction in Energy Internet[J]. IEEE Transactions on Industrial Informatics, 2019, 15(12):6446-6456.
- [120] Y. Sun, C. Kang, Q. Xia, et al. Analysis of transmission expansion planning considering consumption-based carbon emission accounting[J]. Applied Energy, 2017, 193:232-242.
- [121] A. S. Algarni, S. Suryanarayanan, H. J. Siegel, et al. Combined Impact of Demand Response Aggregators and Carbon Taxation on Emissions Reduction in Electric Power Systems[J]. IEEE Transactions on Smart Grid, 2021, 12(2):1825-1827.
- [122] V. Mnih, K. Kavukcuoglu, D. Silver, et al. Human-level control through deep reinforcement learning[J]. Nature, 2015, 518:529–533.
- [123] Yang Z , Yang Z , Li X , et al. The real-time optimization of charge/discharge

- voltage threshold for energy storage system in urban rail transit[C]// IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society. IEEE, 2017.
- [124] Lin F, Li X, Zhao Y, et al. Control Strategies with Dynamic Threshold Adjustment for Supercapacitor Energy Storage System Considering the Train and Substation Characteristics in Urban Rail Transit[J]. Energies, 2016, 9(4):257.
- [125] ang Z , Zhu F , Lin F . Deep-Reinforcement-Learning-Based Energy Management Strategy for Supercapacitor Energy Storage Systems in Urban Rail Transit[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(2): 1150-1160.
- [126] 叶小雯. 城市轨道逆变回馈装置的系统优化设计研究[D].西南交通大学,2018.
- [127] 卫巍. 再生能馈装置在城市轨道交通供电系统中的优化配置研究[D].北京交通大学,2016.
- [128] 张秋瑞. 城市轨道交通再生制动能量利用技术研究[D].北京交通大学,2012.
- [129] 霍慧慧. 果蝇优化算法及其应用研究[D].太原理工大学,2015.

致 谢

项目及研究成果

1. 参与项目：

(1) 南方电网公司科技项目：

基于新一代人工智能和 5G 通信技术的电能质量数据监测管理与分析技术

(2) 清华-丰田研究院跨学科基金项目：

信息物理融合的城市能源系统综合状态感知、安全评估以及能量管理

(3) 国家高铁创新中心项目：

新型高效能城市轨道交通系统建模与综合智能优化

2 学术论文

- [1] **Sheng Guo**, Tao Yang, Haochen Hua, Junwei Cao. Coupling Fault Diagnosis of Wind Turbine Gearbox based on Multitask Parallel Convolutional Neural Networks with Overall Information[J]. Renewable Energy, 2021, 178:639-650.
- [2] **Sheng Guo** and Junwei Cao. Reactive Power Optimization for Voltage Stability in Energy Internet Based on Graph Convolutional Networks and Deep Q-learning[C]. 2021 4th IEEE International Conference on Industrial Cyber-Physical Systems (ICPS), 2021, pp. 511-516.
- [3] Xian Wu, Huaying Zhang, **Sheng Guo**, and Junwei Cao. State Estimation of Energy Internet Using SCADA and PMU Data Based on Graph Convolutional Networks[C]. Proc. 5th IEEE Int. Conf. on Energy Internet, Southampton, UK, 2021.

3. 发明专利

- [1] **郭盛**, 曹军威. 一种能量路由优化方法, 专利号: ZL202110261579.7
- [2] 汪伟, 张华赢, **郭盛**, 等. 无功补偿装置配置方法, 装置, 设备及存储介质, 申请号: CN202011422745.9