


人工智能在电力系统潮流计算中的应用综述及展望

李常刚¹, 李宝亮¹, 曹永吉^{2*}, 王佳颖³

(1. 电网智能化调度与控制教育部重点实验室(山东大学), 山东 济南 250061; 2. 山东大学智能创新研究院, 山东 济南 250101; 3. 国网浙江省电力有限公司营销服务中心, 浙江 杭州 311121)



李常刚, 1984年11月出生, 博士, 教授, 博士生导师, 齐鲁青年学者, 电网智能化调度与控制教育部重点实验室副主任。主要从事电力系统运行与控制研究。中国电工技术学会高级会员, 青年工作委员会委员, 中国电机工程学会会员, IEEE 会员, IEEE PES 济南分会秘书长, IEEE PES(中国)电力系统动态技术委员会交直流混联电网安全稳定分析分委会秘书长。主持国家级重点项目1项、一般项目4项, 开发大规模交直流混联电力系统仿真软件 STEPS 并开源, 以一作/通信作者发表 SCI/EI 期刊论文 40 余篇, 授权发明专利 15 项, 获山东省科技进步奖二等奖 3 项、中国电力企业联合会电力创新奖一等奖 1 项、中国电力科技进步奖一等奖 2 项、山东电力科技进步奖一等奖 1 项等。

摘要:以深度学习为代表的新一代人工智能技术为新型电力系统的数智化运行提供新机遇。为深化人工智能在复杂潮流计算问题中的应用, 对相关领域的研究进行综述与展望。基于新一代人工智能技术的发展现状, 立足于潮流计算问题的不同应用场景, 总结传统求解方法, 综述人工智能技术在潮流计算中的研究进展。分析该领域目前的问题与挑战, 展望未来研究方向和研究范式, 为人工智能技术在电力系统潮流计算领域的进一步应用提供参考。

关键词:潮流计算; 人工智能; 深度学习; 数智化运行; 新型电力系统

中图分类号: TM71

文献标志码: A

引用格式: 李常刚, 李宝亮, 曹永吉, 等. 人工智能在电力系统潮流计算中的应用综述及展望[J]. 山东大学学报(工学版), 2025, 55(5): 1-17.

LI Changgang, LI Baoliang, CAO Yongji, et al. Review and prospect on artificial intelligence application in power system power flow calculation[J]. Journal of Shandong University (Engineering Science), 2025, 55(5): 1-17.

Review and prospect on artificial intelligence application in power system power flow calculation

LI Changgang¹, LI Baoliang¹, CAO Yongji^{2*}, WANG Jiaying³

(1. Key Laboratory of Power System Intelligent Dispatch and Control of Ministry of Education (Shandong University), Jinan 250061, Shandong, China; 2. Academy of Intelligent Innovation, Shandong University, Jinan 250101, Shandong, China; 3. State Grid Zhejiang Marketing Service Center, Hangzhou 311121, Zhejiang, China)

Abstract: The new-generation artificial intelligence technologies, represented by deep learning, provided new opportunities for the digital and intelligent operation of new power systems. To deepen the understanding of the application of artificial intelligence in complex power flow calculation problems, the review and prospect of research in relevant fields were presented. Based on the current development status of the new-generation artificial intelligence technologies and grounded in power flow calculation with various scenarios, the traditional methods were summarized and the research progress of artificial intelligence techniques in power flow calculation was reviewed. The urgent challenges were analyzed and future research directions were envisioned to provide references

收稿日期: 2024-04-20

基金项目: 智能电网重大专项(2030)资助项目(2024200801100); 山东省自然科学基金资助项目(ZR2021QE133)

第一作者简介: 李常刚(1984—), 男, 山东日照人, 教授, 博士生导师, 博士, 主要研究方向为电力系统运行与控制。

E-mail: lichgang@sdu.edu.cn

* 通信作者简介: 曹永吉(1992—), 男, 山东青州人, 副研究员, 硕士生导师, 博士, 主要研究方向为电力系统稳定分析与控制、可再生能源并网及储能技术应用。E-mail: yongji@sdu.edu.cn

for further applications of artificial intelligence technologies in the field of power flow calculation.

Keywords: power flow calculation; artificial intelligence; deep learning; digital and intelligent operation; new power systems

0 引言

潮流计算是对电力系统稳定运行状态的计算和分析过程,为经济性、安全性和稳定性评估提供基础数据。潮流计算的数学本质是非线性代数方程组的数值求解问题。目前,一般的非线性代数方程组没有解析解,故只能用迭代方法求解。受限于迭代方向、迭代步长缺少自适应的理论指导,传统方法对非线性问题的处理能力有限,大电网潮流计算的不收敛问题时常发生^[1-3]。随着能源转型和智能电网的构建,电力系统的复杂性和不确定性不断增加,在大量可再生能源和灵活负荷接入情况下,系统的非线性特性导致传统方法收敛性和稳定性受到影响,给潮流计算带来新的挑战和需求^[4]。

人工智能(artificial intelligence, AI)的快速发展为电力系统潮流计算提供了新思路^[5]。基于规则的专家系统和基于统计的机器学习(machine learning, ML)算法等传统 AI 技术已在潮流计算中得到广泛应用,通过数学模型和推断规则等解决潮流计算问题,具有一定可靠性和解释性,但在处理复杂的大规模电力系统时依旧面临计算复杂度的困扰,难以适应电力系统的快速变化和高精度的计算需求^[6-8]。近年来,深度学习(deep learning, DL)和强化学习(reinforcement learning, RL)等新一代 AI 技术在各个领域展现出巨大潜力,其强大的非线性建模、高效的数据分析及智能决策能力等优势能够更好地解决潮流计算中的复杂问题,提高电力系统效率和可靠性。DL 通过建立深度神经网络(deep neural network, DNN)模拟人脑神经元之间的连接和传递方式,从大规模数据中学习和提取特征,实现对复杂数据的高效分析和处理^[9-10]。RL 是一种通过智能体与环境交互学习优化决策和行为的方法,智能体根据环境的反馈信号调整决策策略,最终达成回报最大化或实现特定目标^[11-12]。

DL 和 RL 技术与潮流计算领域存在众多契合点:潮流计算可看作一种函数逼近或回归问题,通过给定的电力系统输入预测状态变量,DL 具有强大的函数逼近能力,可以通过学习大量数据中的模式规律,自动建模和预测复杂的非线性关系;潮流计算涉及大量的数据处理和分析过程,包括历史数据的收集、清洗和预处理,DL 可以处理高维、非线性、稀疏等数据,减少人工特征工程的依赖;潮流计

算需要对电力系统进行动态调度和控制,以实现系统的稳定性和优化效果,RL 以智能体与环境交互为基础,学习最优的决策策略,在实时中不断优化和调整,适应不断变化的电力系统条件和需求;潮流计算涉及多个目标、约束及时空尺度等复杂因素的综合考量,RL 通过端到端的学习方式综合考虑这些复杂因素,在决策过程中找到合适的平衡点,以实现系统的性能优化和约束满足。

目前已有大量研究将 AI 技术应用在潮流计算领域,并证明 AI 技术具有巨大潜力和广阔的应用前景,但缺乏系统性的总结。本研究立足于不同场景的潮流计算问题,综述以 DL 和 RL 为代表的新一代 AI 技术在潮流计算领域的研究应用。

1 人工智能技术

1.1 深度学习

DL 是由机器学习发展而来的研究分支,其概念起源于对人工神经网络(artificial neural network, ANN)的研究^[13]。DL 的核心思想的是利用 DNN 学习复杂的非线性函数关系,通过组合低层特征形成更加抽象的高层次表述属性类别或特征,以发掘数据的内在特征与规律^[14]。与传统的浅层神经网络相比,DNN 的优势在于网络层次纵深明显增加,神经元数量呈几何数级扩增,在复杂的非线性信息建模时提供更高的抽象层次,多层次的转换使模型能够从数据中学习更复杂、更抽象的特征,获得更好的性能。

DL 的学习机制涉及多种方法和技术,通过不断优化模型参数和网络结构,根据实际问题综合考虑多种因素,通过大量试验和调试,确保 DNN 具备较高的精度和泛化能力,为实际应用提供可靠预测和决策基础^[15-17]。DL 的学习机制可表现为

$$Y=f(X;\alpha,\lambda,\eta), \quad (1)$$

式中: X 为输入; Y 为输出; f 为模型; α 为模型参数; λ 为正则化参数,用于控制模型复杂度; η 为控制参数更新的学习率。DL 的学习机制核心是通过调整这些参数,最大化拟合 X 和 Y 之间的关系。

绝大部分 DL 模型是以几种核心模型衍生而来,主要包括循环神经网络(recurrent neural network, RNN)、卷积神经网络(convolutional neural networks, CNN)、图神经网络(graph neural network, GNN)、深度信念网络(deep belief

network, DBN) 和自编码器(autoencoder, AE)。这5种模型的网络结构如图1所示。许多学者以核心

神经网络为基础不断探索和创新,提出一系列新的衍生模型,如表1所示。

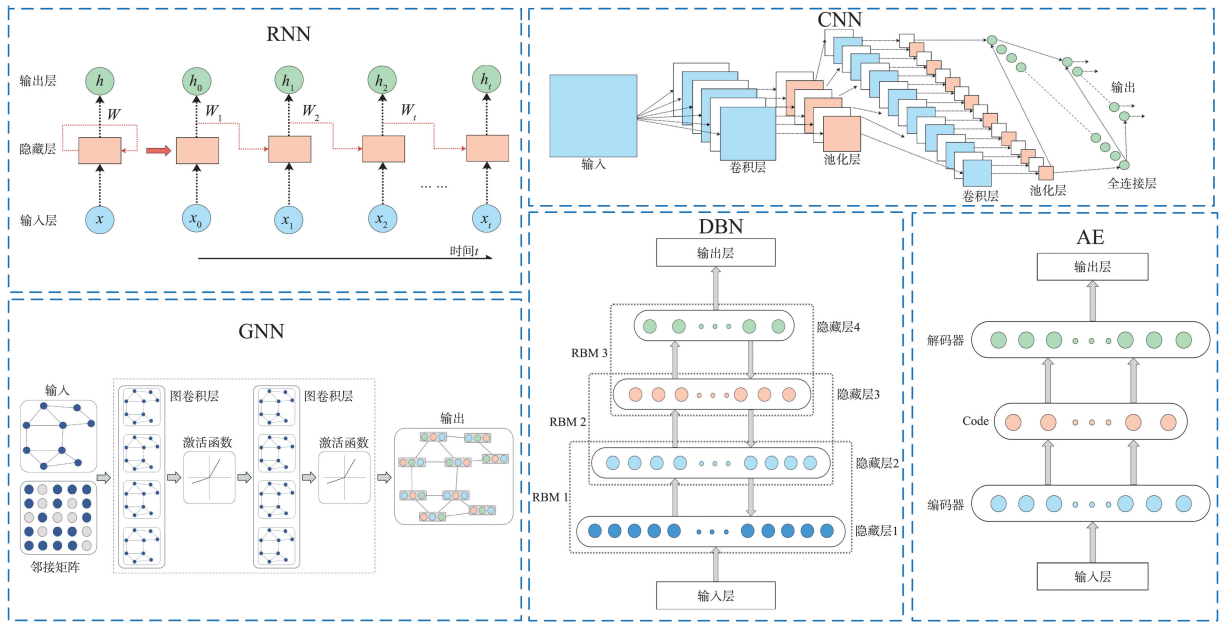


图1 典型深度学习模型结构
Fig.1 Typical structure of deep learning models

表1 深度学习衍生模型
Table 1 Derivative models for deep learning

DL 模型	衍生模型	改进机制	优势
RNN	SRNN ^[18]	循环层替换为切片层和线性层	并行计算,模型体积小
	GRU ^[19]	重置门和更新门	长期依赖关系建模能力,参数量少
	Attention RNN ^[20]	引入注意力机制	长序列建模能力强
	LSTM ^[21]	记忆单元、门控制机制	缓解梯度爆炸和梯度消失
CNN	VGGNet ^[22]	3×3 卷积核、更深的网络结构	特征提取能力和泛化能力强
	ResNet ^[23]	残差连接思想、极大增加网络深度	参数数量少,抗过拟合性
	DenseNet ^[24]	密集连接思想	增强信息流动和特征共享
	GoogLeNet ^[25]	Inception 结构、全局平均池化	模型轻量化,可扩展性强
	AlexNet ^[26]	修正线性单元(rectified linear unit, ReLU) 激活函数、Dropout 正则化	避免梯度消失,提升速度和鲁棒性
GNN	GAN ^[27]	引入注意力机制	关注相关性强的节点和边
	GraphSAGE ^[28]	多层聚合函数	摆脱全局图结构的依赖
	GCN ^[29]	图卷积操作	关联相邻节点信息
DBN	RDBN ^[30]	网络层次中引入递归结构	兼备前向和后向学习能力
	SDBN ^[31]	每层网络中引入稀疏性约束	减少冗余信息传递和处理
	TL-GDBN ^[32]	引入迁移学习和增量学习	网络结构动态生长,扩展性强
AE	SAE ^[33]	损失函数中引入稀疏惩罚项	数据稀疏表示,特征提取能力强
	VAE ^[34]	概率编码器和解码器	学习数据潜在分布
	CAE ^[35]	损失函数中引入正则化项	限制扰动敏感性,鲁棒性强
	DAE ^[36]	输入中添加噪声数据	对噪声特征的鲁棒性强

注:简单循环神经网络(simple recurrent neural network, SRNN)、门控循环单元(gated recurrent unit, GRU)、注意力机制循环神经网络(attention-based recurrent neural network, Attention RNN)、长短记忆(long short-term memory, LSTM)、视觉几何组网络(visual geometry group network, VGGNet)、残差网络(residual network, ResNet)、密集连接卷积网络(densely connected convolutional networks, DenseNet)、谷歌初始网络(Google inception network, GoogLeNet)、亚历克斯网络(AlexNet)、图注意力网络(graph attention network, GAN)、图采样与聚合(graph sample and aggregate, GraphSAGE)、图卷积网络(graph convolutional network, GCN)、受限深度信念网络(restricted deep belief network, RDBN)、稀疏深度信念网络(sparse deep belief network, SDBN)、迁移学习分组深度信念网络(transfer learning grouped deep belief network, TL-GDBN)、堆叠自编码器(stacked autoencoder, SAE)、变分自编码器(variational autoencoder, VAE)、卷积自编码器(convolutional autoencoder, CAE)、去噪自编码器(denoising autoencoder, DAE)。

RNN 是用于分析序列数据的神经网络,主要由输入层、隐藏层和输出层组成。其中,隐藏层的循环单元是 RNN 的核心,训练时将每个时间步的输入送至隐藏层,且前一个时间步的隐藏状态同时参与计算,以此在时间序列上建立依赖关系,通过反馈循环连接形式传递历史信息和隐藏状态^[18]。这种循环连接机制模拟人脑对于历史状态和当前信息的记忆和理解过程,赋予 RNN 历史记忆能力,使其能够学习和捕捉序列数据中的时间依赖关系^[19-21]。

CNN 是具有局部连接、权值共享等特点的深层前馈神经网络,其核心由卷积层、池化层、全连接层组成^[22-24]。卷积层通过卷积核对输入数据进行卷积运算,提取局部特征,实现参数共享;池化层对卷积层的输出进行下采样,减少特征图的空间尺寸和模型参数量;全连接层将卷积层和池化层提取的特征进行整合及输出。CNN 的主要特点是局部感知与参数共享。局部感知是指卷积操作可以捕捉输入数据中局部的空间结构信息,例如图像中的边缘、纹理等特征;参数共享是指在卷积操作中,卷积核参数在整个图像中被共享使用,不仅减少了模型参数量,而且提高了模型的泛化能力^[25-26]。

GNN 是用于处理图结构数据的神经网络,由节点特征矩阵、邻接矩阵、图卷积层和输出层构成^[27]。节点特征矩阵用于表示每个节点的初始特征,邻接矩阵用于表示节点之间的连接关系,图卷积层用于聚合邻居节点的信息并更新节点特征,输出层用于输出预测结果。GNN 的核心是通过消息传递机制聚合节点的邻居信息,更新节点特征表示^[28-29]。GNN 通过多轮迭代捕获图中更远距离的节点特征,每个节点特征表示将包含其邻居和更远节点的信息。

DBN 是由多个受限玻尔兹曼机 (restricted Boltzmann machines, RBM) 堆叠构成的神经网络结构,每个 RBM 都由一个可见层和一个隐藏层组成,可见层用于表示数据的输入特征,隐藏层用于构建数据的高阶特征^[30-32]。DBN 采用分阶段学习策略,通过多个 RBM 逐层学习输入信息的高阶特征,生成更抽象的特征表示。DBN 可应用于无监督学习和监督学习任务,无监督学习中的 DBN 通过学习数据分布进行特征提取,监督学习中的 DBN 可作为预训练阶段初始化神经网络的权重,加速训练过程,提高预测结果的准确性。

AE 作为无监督神经网络模型,基本结构由输入层、编码器和解码器组成^[33-34]。输入层接收原始

数据;编码器将原始数据映射到低维度特征空间;解码器将特征空间的表示重新映射回原始数据空间,通过调整网络参数使重构误差达到最小,以获得输入特征的最优抽象表示^[35-36]。AE 能够对输入信息进行表征学习,执行特征提取、重构和生成操作,不依赖标记数据即可学习数据的特征表示,广泛适用于数据降维、特征提取和数据重构领域。

1.2 强化学习

RL 也是 ML 的范式和方法论之一,旨在解决智能体如何通过与环境交互学习最优策略,以达到最大化回报或实现特定目标的问题^[37-38]。RL 的核心思想为试错机制,通常使用马尔可夫决策过程 (Markov decision process, MDP) 对问题进行建模,智能体基于环境状态和当前自身状态选择行动,从环境中接受奖励信号作为行动反馈,通过学习状态到行动的映射关系最大化累积奖励,通过不断与环境进行实时交互更新决策网参数,学习最佳决策^[39]。

RL 的学习机制如图 2 所示,智能体与环境进行交互,动作执行后,结果传递回智能体进行决策并执行下一轮动作,根据得到环境反馈的新状态和奖惩更新决策算法。此过程反复迭代,直到智能体学习最大化长期累积奖励的策略。RL 的学习机制可表示为

$$A = \phi(S, R, \theta, I), \quad (2)$$

式中: A 为动作空间; ϕ 为策略函数; S 为环境状态; R 为即时奖励; θ 为策略参数; I 为附加信息,包括环境状态的其他信息。




图 2 强化学习学习机制

Fig.2 Learning mechanism of reinforcement learning

RL 以无模型学习方法为主,主要包括基于值函数的 RL 和基于策略梯度的 RL,主要算法如表 2 所示。最典型的基于值函数的 RL 算法是深度 Q 网络 (deep Q -network, DQN) 算法。DQN 结合 Q -Learning 和 DNN,核心思想是利用 DNN 逼近 Q 函数,通过迭代更新网络参数优化 Q 函数的逼近精度^[40]。相较于传统的 Q -Learning, DQN 改进之处在于引入目标网络和经验回放机制。DQN 引入一

个单独的目标网络更新 Q 函数,从目标网络获取 Q 值并进行 Q 函数更新,避免训练过程中目标值的更新和选择动作的相互影响。经验回放机制可提高训练的稳定性,提高样本的利用效率,智能体与环境交互

产生的经验(状态、行动、奖励、下一个状态)存储在经验缓冲区,训练过程中从缓冲区随机采样一批经验样本,打破样本之间的关联性,提高样本独立性。

表 2 强化学习主要算法
Table 2 Main algorithms of reinforcement learning

RL 类型	算法	改进机制	优势
基于值函数的 RL	DQN ^[40]	经验回放、目标网络、 ϵ -贪婪策略	提高稳定性和收敛性
	D3QN ^[41]	结合 Double DQN 和 Dueling DQN	Q 函数评估准确性高
	Dueling DQN ^[42]	不同值函数进行状态评估和动作选择	提高 Q 函数估计准确性
	Double DQN ^[43]	目标 Q 函数采用双网络结构	缓解 Q 值过估计风险
	DRQN ^[44]	引入 RNN 建立序列依赖关系	处理序列和部分可观测性任务
基于策略梯度的 RL	TD3 ^[45]	引入 2 个 Q 函数网络,延迟策略更新	缓解 Q 值过估计风险
	SAC ^[46]	引入最大化策略熵思想	抗干扰能力强
	TRPO ^[47]	引入置信域约束	稳定策略更新
	PPO ^[48]	策略裁剪或惩罚	稳定策略更新,提高训练效率
	DDPG ^[49]	确定性策略、经验回放机制、演员-评论家 (actor-critic, AC) 框架	适应高维连续动作空间
	A3C ^[50]	并行工作、异步更新策略、优势函数	适用于离散和连续动作空间

注:对决双重深度 Q 网络 (dueling double deep Q -network, D3QN)、对决深度 Q 网络 (dueling deep Q -network, Dueling DQN)、双重深度 Q 网络 (double deep Q -network, Double DQN)、深度循环 Q 网络 (deep recurrent Q -network, DRQN)、双延迟深度确定性策略梯度 (twin delayed deep deterministic policy gradient, TD3)、柔性演员-评论家 (soft actor-critic, SAC)、信任域策略优化 (trust region policy optimization, TRPO)、近端策略优化 (proximal policy optimization, PPO)、深度确定性策略梯度 (deep deterministic policy gradient, DDPG)、异步优势演员-评论家 (asynchronous advantage actor-critic, A3C)。

DQN 的训练结构如图 3 所示。智能体从环境中获取初值状态并执行动作,环境反馈的经验存储于经验缓冲区中,采用经验缓冲区的随机样本计算 Q 值,通过更新神经网络参数减小 Q 值的计算误差。目标网络和估计网络实行参数共享以交替更新 Q 值,迭代直至达到预期目标。

输出状态到行动的概率分布,智能体根据概率分布选择行动,从环境中获得奖励信号作为行动的反馈,采用梯度上升或随机梯度上升的方式更新策略参数,使累积奖励最大化,逐渐收敛到最优策略^[45-51]。

2 电力系统潮流计算问题概述

2.1 常规潮流计算

电力系统潮流计算是在给定运行条件和系统接线方式下,对系统的电压分布、功率分布进行求解。进行潮流计算时,发电机和负荷通常表示为连接到相应节点上的功率注入量,因此,计算所用的电力网络由变压器、输电线路、电容器、电抗器等静止线性元件构成,用集中参数表示的串联或并联等值支路模拟^[52]。潮流方程可表示为

$$g(x, u) = 0, \quad (3)$$

式中: g 为非线性方程组; x 为系统的状态变量,包括各个节点电压及相角等; u 为控制变量,包括电源有功功率、无功功率、发电机机端电压、负荷及变压器分接头位置等。

潮流方程为非线性代数方程组,需采用数值计算方法迭代求解。根据计算中对潮流方程的不同应用和处理,形成不同的潮流算法。目前传统的常




图 3 DQN 训练结构

Fig.3 Training structure of DQN

基于值函数的 RL 在许多领域取得优异的效果,主要适用于离散动作空间,对连续动作空间问题的处理效果不佳^[41-44]。基于策略梯度的 RL 是通过拟合策略函数的形式直接在策略空间中搜寻最优策略,无需对动作离散化处理,在连续动作空间中具有较好的灵活性和探索能力。基于策略梯度的 RL 核心思想为:智能体通过与环境的交互训练,

规潮流计算方法有:高斯-赛德尔法、牛顿-拉弗森法、快速分解法、保留非线性算法等。

当电力系统接近或超出极限运行状态后,出现潮流不收敛现象。潮流不收敛是指电力系统的节点电压方程无法通过迭代法找到满足系统平衡条件的合理解。潮流不收敛可能由多种原因引起,包括网络拓扑问题、潮流计算参数设置错误、负荷和发电机数据不准确、系统参数变化、系统过载或故障及初始条件选择不当等^[53-55]。

电力系统运行空间可分为3个区域:运行域、紧急域和不可行域,如图4所示。运行域和紧急域合称为可行解域。运行域对应的潮流方程存在实数解,且满足系统所有不等式约束条件。紧急域对应的潮流方程虽然有解,但存在一个或多个不等式约束不满足的区域,属于病态潮流问题,可通过提高计算方法的收敛性得到潮流解,病态潮流算法目前主要包括最优乘子法、非线性规划法、改进连续潮流法等。不可行域对应的潮流方程无实数解,实际电力系统不可能在该区域运行,需要通过调整系统运行方式使运行点回归可行解域,重新计算得到收敛的潮流解,常用的潮流调整方法包括基于灵敏度法和内点法等。

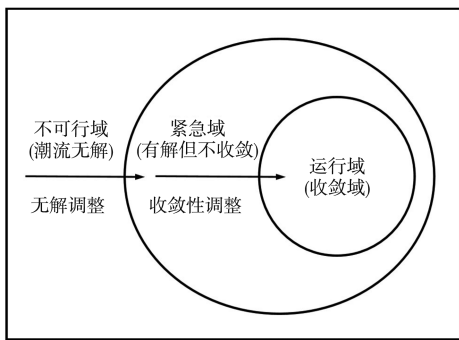


图4 电力系统运行空间

Fig.4 Operating space of power system

2.2 概率潮流计算

常规潮流计算中通常假设电力系统的输入参数是确定的,包括发电机出力、负荷需求、线路参数等。随着可再生能源的大力发展,电力系统面临更多的不确定性^[56]。不确定性潮流分析的目的是评估系统在不确定条件下的运行安全性、经济性和可靠性,为电力系统规划、设计、运行和控制提供依据。

概率潮流(probabilistic power flow, PPF)是一种考虑电力系统中不确定因素随机性情况下计算功率和电压分布的方法,旨在分析电力系统在不同运行状态下的安全性、经济性和供电质量^[57-58]。PPF将系统中的随机变量用概率分布或随机过程描述,利用统计方法求解潮流方程,得到以概率或期

望形式表示的各节点电压、功率和线路负载等参数。PPF的数学模型可表示为

$$g(x, u, P_D, P_G) = 0, \quad (4)$$

式中, P_D 和 P_G 分别为随机负荷和发电功率,作为概率密度函数的参数输入潮流方程中。调度员可根据PPF结果评估系统运行状态,做出应急调整和规划。

通常情况下,PPF方法应满足以下要求:能够计算输出随机变量的数字特征(包括均值和方差等),并且能够输出随机变量的概率分布;能够处理多个随机变量之间的相关性;为满足实际应用需求,计算结果需具有足够精度,并且在保证精度的前提下尽量提高计算效率;应具备通用性,即不要求输入变量的数学模型过于严格。目前已有的PPF计算方法包括模拟法、近似法和解析法等。这些方法为电力系统的不确定性建模和分析提供有效的工具。

2.3 最优潮流计算

最优潮流(optimal power flow, OPF)是在给定电力系统结构参数及负荷的情况下,通过优选控制变量,找到满足所有指定约束条件并使系统的某一个性能指标或目标函数达到最优时的潮流分布^[59]。OPF把电力系统调度与潮流计算有机融合在一起,以潮流方程为基础,进行经济性与安全性的全面优化^[60]。

OPF作为带约束的优化问题,主要构成包括变量集合、约束条件和目标函数,数学描述为:在网络结构和参数及系统负荷给定的条件下,确定系统的控制变量,满足各种等式和不等式约束,使描述系统运行效益的某个给定目标函数取极值。OPF的数学模型为

$$\begin{cases} \min l(x, u) \\ g(x, u) = 0 \\ h(x, u) \leq 0 \end{cases}, \quad (5)$$

式中: l 为目标函数; h 为不等式约束,包括发电机输出有功功率上下限约束、发电机和无功补偿装置输出无功功率上下限约束、移相器和带负荷调压变压器的抽头位置约束、各节点电压幅值上下限约束、各支路通过最大功率约束、线路两端节点电压相等差约束等。

目前,常用的OPF目标函数主要从经济性、环保性及稳定性等方面进行衡量,以此建立相应数学模型。经济性OPF从系统运行的经济性方面出发,降低发电成本和系统网损是最常用的目标函数;环保性OPF在满足电网负荷用电前提下,将各发电厂的污染物排放量作为目标函数;稳定性OPF旨在优

化电力系统运行,以确保系统在各种扰动和故障情况下能够保持稳定。各目标函数除单独作为优化目标,也可通过不同形式的组合建立多目标优化模型,得到系统综合运行方案。目前已有的 OPF 方法包括简化梯度法、牛顿法、内点法及仿生算法等。

3 人工智能潮流计算中的研究进展

3.1 常规潮流计算研究进展

传统潮流计算方法对准确的网络拓扑和系统状态信息敏感,在大规模潮流计算中所需时间较长。相比之下,DL 作为一种数据驱动方法,无需详细的系统模型和准确的网络拓扑信息,即可从历史数据中学习和预测电网状态。DL 计算效率远高于传统物理模型计算方法,且能够适应不同的电力系统场景和变化,具备优异的鲁棒性和泛化能力。

文献[61]针对电力系统拓扑结构变化引起的潮流计算变化,提出一种基于 DBN 的数据驱动潮流计算方法,解决传统潮流计算方法下拓扑条件变化的迭代问题,在网络参数完整信息未知的情况下可获得潮流计算结果,计算精度和效率显著提升;文献[62]提出一种基于图卷积神经网络(graph convolutional network, GCN)的潮流计算模型,实现多场景的新能源出力、负荷数据与支路潮流、节点电压之间非线性关系的快速拟合,相比于传统方法,此模型考虑电力系统拓扑结构和潮流数据空间上的关联性,计算效率显著提升,能够适应 $N-1$ 故障引起网络拓扑结构的变化和新能源的波动性;文献[63]提出一种数据驱动的分布式学习框架,用于快速求解大型复杂电力系统的潮流问题,通过分布式方法将计算负载分配到多个深度卷积神经网络(deep convolutional neural networks, DCNN)模型中,建立基于模拟结果的数据库,采用 TensorFlow 实施多图形处理器的并行训练,在保持高准确性的同时极大提高计算效率。

传统潮流计算方法的收敛性容易受初始值选择、线性化误差及系统非线性特征等因素影响,导致不收敛或收敛缓慢的情况,特别是在系统故障、线路过载、电源故障等复杂情况下,收敛性问题更为突出。当电网潮流不收敛时,目前只能在已有潮流计算程序的基础上进行人工调整,主要依赖人工经验和试凑的调整方式,大电网的潮流方程变量维度高,可调参数众多,参数之间的相互影响和调整的耦合性使找到合适的参数配置尤为复杂。RL 可通过自主探索和学习,利用知识经验和设置奖惩机

制缩小搜索空间,找到最优调整策略,实现潮流的自动快速收敛,极大提高工作效率。此外,RL 可以适应大规模系统和复杂的参数空间,通过学习抽取特征和表示处理高维度的参量信息,更好地适应电力系统的复杂性和多样性。

为实现多负荷水平下的潮流自动调整,文献[64]采用 Dueling DQN,通过学习得到发电机的最优配置方案,在给定的负荷水平下使潮流状态收敛;文献[65]提出一种基于知识经验和深度强化学习的潮流计算收敛自动调整方法,在 Double DQN 中加入知识经验,缩小搜索空间,模拟人工调整过程,先平衡有功功率,再平衡无功功率,使搜索具有方向性,实现对潮流计算收敛的自动调整;文献[66]提出 D3QN 算法和优先经验回放的潮流收敛自动调整方法,模型训练达到 10 000 次后,潮流收敛的成功率接近 100%,在不同负荷水平下执行调整策略能够保持系统网损率在较低水平;文献[67]提出一种基于 SAC 算法的弱电网无解潮流自动调整模型,可以定位系统的薄弱环节,在几个步骤内将大部分无解潮流样本调整至有解状态,通过输电通道指数评估潮流的可解程度,加快潮流的自动调整速度;文献[68]构建一种多智能体异步优势演员-评论家(multi-agent asynchronous advantage actor-critic, MA3C)算法调整潮流收敛状态,模型中的 A3C 结构独立进行局部状态的学习和策略评估,结构之间互相通信协调,共同追求潮流收敛目标,极大提升工作效率和可扩展性;文献[69]利用 PPO 算法获取电网断面功率调整策略,引入发电机提前筛选和功率补偿机制,规避潮流计算不收敛与正样本稀少问题,可根据电网运行信息自动得出断面功率调整策略,对潮流计算收敛性影响较小;文献[70]针对大规模复杂目标的求解提出基于 AC 算法框架的改进 DL 算法,引入分阶段训练和优先目标回放等措施,能够根据给定的关键输电断面目标传输功率,快速调整至满足要求的潮流结果。

常规潮流计算研究总结如表 3 所示。DL 在潮流计算中具有数据驱动、拓扑感知及高效计算等优势,能够快速准确求解电力系统中各种因素与物理量之间的非线性关系,适应复杂多变的网络环境,满足实时性要求。RL 在潮流收敛的自动调整中表现出优越的性能,根据电网的实时状态和目标要求,智能选择合适的控制变量,实现潮流的快速收敛和优化,同时通过各种机制和技术提高模型的学习效率、鲁棒性和泛化能力,使模型能够适应复杂多变的电网环境,为电网安全高效运行提供有力支撑。

表3 常规潮流计算研究总结
Table 3 Research summary of conventional power flow calculation

算法模型	对比方法或模型	优势
DBN ^[61]	牛顿-拉弗森法、径向基函数(radial basis function, RBF)	计算精度高,消耗时间少
GCN ^[62]	牛顿-拉弗森法	计算速度提高上百倍
DCNN ^[63]	5层 ANN	计算速度提高6倍
Dueling DQN ^[64]	DQN	训练效率高,调整时间短
Double DQN ^[65]	内点法	收敛成功率提高8%~30%
D3QN ^[66]	DQN	收敛成功率接近100%,系统网损率低
SAC ^[67]	DQN	收敛成功率提高5%~37%
MAA3C ^[68]	优势演员-评论家(advantage actor-critic, A2C)算法	调整成功率高,调整效率高,可扩展性强
PPO ^[69]	内点法、灵敏度法	调整误差小,用时缩短几十倍以上
AC ^[70]	内点法	调整误差小,调整时间短

3.2 概率潮流计算研究进展

传统的 PPF 算法在计算复杂性、精度及参数不确定性等方面存在诸多局限,模拟法计算复杂性高,需要进行大量随机采样和迭代计算;近似法往往基于一些假设简化计算,可能忽略高价效应或非线性关系,导致精度受限;解析法会随输入随机变量的增多导致较大误差。传统方法的局限性限制其在大规模复杂系统中的灵活应用,DL 可以从历史数据中学习电力系统的运行特征和不确定因素的影响规律,无需考虑各因素的具体分布形式和参数,不受系统规模和拓扑结构限制,减少计算量和时间,提高计算效率。

为了提高 PPF 的计算效率和精度,文献[71]提出一种基于堆栈式降噪自动编码器(stacked denoising autoencoder, SDAE)的模型,通过使用修正线性单元激活函数和离差标准化训练方式,改进参数更新效率,在 IEEE14-NGS10 系统中的仿真验证了模型优势,计算速度比 Monte Carlo 方法提高 1 353 倍;文献[72]提出一种基于 CNN 的电力系统概率潮流快速计算方法,结合拉丁超立方采样法对数据集进行处理,仿真结果显示,在保持计算精度的情况下,计算效率大幅提升;文献[73]提出一种基于 RNN 的最大频率偏差预测模型,提取区域光伏功率输出和时域频率中的高阶非线性特征,开发不确定性电力系统建模的概率潮流-动态工具(probability power flow-dynamic tool, PPDT),捕捉光伏发电输出的规律性和随机特性;文献[74]基于 RNN 和 CNN 的优势,结合注意力机制,提出一种含不完全参数 PPF 计算的门循环单元-时间卷积网络(gate recurrent unit-temporal convolutional network, GRU-TCN)模型,通过有限数据集识别关键特征,在

保证高精度计算结果的同时大幅提升计算效率;文献[75]设计一种图注意力卷积网络(graph attention enabled convolutional network, GAECN)模型,通过自适应图卷积操作捕获注入节点功率的相关性,将节点嵌入技术集成到卷积操作中,以降低系统的状态误差。在进行 PPF 计算时,一般考虑多个可能的风电和光伏输出功率情景,针对每个情景进行潮流计算。考虑风电和光伏发电的不确定性,文献[76]提出一种双向生成对抗网络(bidirectional generative adversarial network, BGAN)刻画风电出力不确定性的配电网 PPF 计算方法,在数字特征、概率分布方面与时序法计算结果一致,但具备更高的计算精度和更少的计算时间;文献[77]采用 LSTM 模型计算考虑风电、光伏和主动负荷的 PPF,通过 LSTM 优化训练求解,有效抑制不确定因素的较大变化,使系统总体成本较低;文献[78]提出一种图感知深度学习网络(graph-aware deep learning network, GADLN)模型,计算考虑新能源注入之间相关性的 PPF,不仅能够捕捉风能、太阳能、负荷需求和物理结构决定的配电系统状态变量的分布特征,而且大幅提升计算效率和计算精度。

PPF 计算研究总结如表 4 所示。DL 模型在 PPF 计算中展现出强大的性能和灵活性,能够有效提取电力系统中的非线性特征,提高计算精度和效率。通过采用不同的网络结构和激活函数,DL 模型能够适应不同的电力系统场景和不确定性因素。此外,结合注意力机制、数据预处理等技术可以进一步提高模型的泛化能力和稳定性,应对电力系统的动态变化和数据不足。无监督预训练、知识迁移等方法加速模型的训练过程,降低计算资源消耗和时间成本,在 PPF 计算中展现出广泛的适用性和优势。

表4 概率潮流计算研究总结
Table 4 Research summary of probabilistic power flow calculation

算法模型	对比方法/模型	优势
SDAE ^[71]	Monte Carlo 方法	计算速度提高 1 353 倍
CNN ^[72]	Monte Carlo 方法、点估计法	计算误差减小,速度提高 50 倍以上
RNN ^[73]	决策树模型、K 近邻模型、线性回归模型、随机森林模型	计算误差减小,开发了 PPDT
GRU-TCN ^[74]	Monte Carlo 方法	计算时间减少 99% 以上
GAECN ^[75]	点估计法	计算误差降低 90% 以上
BGAN ^[76]	时序法	计算精度高,计算次数减少
LSTM ^[77]	半不变量法	抑制不确定因素的较大变化
GADLN ^[78]	点估计法	计算误差降低 97.57%,速度提升近 50 倍

3.3 最优潮流计算研究进展

传统的 OPF 计算方法依赖于准确的电力系统数学模型,而在实际环境中,电力系统的建模和数据存在不确定性和复杂性,导致计算效率和准确性受到限制。此外,传统方法的收敛速度相对较慢,难以处理大规模和复杂非线性的电力系统问题。DL 和 RL 具备更强的非线性建模和逼近能力,在复杂、动态、不确定的环境中,能够通过与电力系统交互优化长期累积收益,获取最优的电力系统决策。

DL 在电力系统 OPF 中的研究主要集中在建模和预测方面。DL 模型利用大量的潮流数据学习电力系统非线性特征和规律,通过预测结果优化潮流计算,帮助确定最优的系统控制动作,提高运行的效率和可靠性。为求解以发电成本为目标函数的 OPF 问题,文献[79]提出一种结合知识提取的 SDAE 模型,利用知识提取技术增强有限样本的训练泛化能力,与传统内点法相比,计算精度提高的同时效率提升 3 个数量级以上;文献[80]针对具有灵活拓扑和导纳的 OPF 问题,以最小化发电成本为目标,将离散拓扑表示嵌入连续导纳空间中,利用多层前馈 DNN 学习从负载及导纳到相应 OPF 解的映射关系,结果表明,该模型生成的解决方案具有低至 0.92% 的优化损失和至少 95% 的约束满足率;为实现故障发生约束条件下控制成本最小化,文献[81]提出基于 DBN 的电力系统暂态稳定评估模型,通过无监督预训练和有监督微调方式,拟合发电机功率和暂态稳定指标间的映射关系,实现对预期故障集暂态稳定防控最优策略的快速搜索;文献[82]面向不同运行模式下的 OPF,提出基于 CNN 的计算方法,在电网运行条件和网络结构未知的情况下也能准确获取相应最优解,在保证预测精度为 99% 的同时,计算效率提升 350 倍;文献[83]提出一种基于 LSTM 和非支配排序遗传算法 II (nondomi-

nated sorting genetic algorithm II, NSGA-II) 的 OPF 计算方法,LSTM 作为预测模型,在考虑空间相关性的情况下进行光伏输出预测,NSGA-II 以有功网损和电压偏移为目标进行潮流优化,结果表明,所提方法可以协调有功网损和电压偏移的制约关系,避免发生因发电机向远程负载供电导致损耗增加的情况。

RL 在电力系统 OPF 问题中的研究更侧重于决策和控制方面,RL 通过智能体与环境交互,学习与奖励信号相关的最优策略优化电力系统操作,通过决策发电机输出、节点电压调节及线路功率分配,实现最小化发电成本、网络损耗或满足其他优化目标。在满足系统各种实际约束的基础上,为实现最大化可用传输容量,文献[84]通过模仿学习提供初始策略,利用 Dueling DQN 算法和预警机制优化控制策略,在减少训练时间的同时最大限度提升电网的可用传输容量;文献[85]采用 PPO 算法快速获得 OPF 解决方案,目标是寻找最优发电机设定,在满足安全约束的同时使二次发电成本最小,通过模仿学习初始化权重及近端策略优化算法训练智能体,PPO 算法在保持与内点法优化代价相同的情况下,求解时间缩短 7 倍以上,验证了其在考虑拓扑变化的 $N-1$ 安全校核中的有效性;文献[86]通过 DDPG 算法进行安全约束 OPF 的快速求解,双重优化技巧增强 DDPG 动作值函数,使训练过程中能够考虑安全限制因素,根据含事故约束潮流模型的状态,以最小成本确定最优调度动作,快速实时计算出满足安全约束的最优解;文献[87]提出一种凸约束柔性演员-评论家 (convex constrained soft actor-critic, CC-SAC) 算法,将 OPF 问题标准化为具有简单序列的子问题,在离线训练和在线操作过程中生成可行的解决方案,以非常低的计算负担提供最优安全控制动作;文献[88]通过 TD3 算法求解包括火电机组和新能源机组的 OPF 策略,总体优化目标被分解为

多个子目标,在得到合理发电机组布置的同时大幅提升收敛速度;针对复杂电网的多目标 OPF 问题,文献[89]提出一种分布式 $Q(\lambda)$ 学习算法,以发电成本、有功网损和电压稳定分量为目标函数,对复杂电网采用分区思想,由多个学习单元并行执行任务,通过约束边界节点的电气信息量满足实际运行条件,解决传统方法难以优化的复杂问题。

OPF 计算研究总结如表 5 所示。DL 和 RL 均展现出智能处理复杂数据和问题的能力,实现电力系统 OPF 计算的高效、自适应和数据驱动。DL 和

RL 在 OPF 问题中的研究存在如下差别。

(1)数据处理方式:DL 主要利用大量历史数据学习电力系统的规律和特征,通过训练神经网络建模潮流计算过程;RL 将 OPF 视为一个 MDP 问题,在与环境交互过程中,通过试错和奖励机制学习最优策略。

(2)目标函数建模:DL 通常将目标函数作为某种形式的损失函数进行建模;RL 通过设定奖励函数定义目标函数,例如将发电成本作为负奖励,损耗降低作为正奖励,以激励智能体学习最优策略。

表 5 最优潮流计算研究总结

Table 5 Research summary of optimal power flow calculation

算法模型	目标函数	对比方法/模型	优势
SDAE ^[79]	发电成本	内点法	计算效率提升 3 个数量级以上
前馈 DNN ^[80]	发电成本	无	优化损失低,约束满足率高
DBN ^[81]	发电成本	内点法	几秒内获得预防性控制策略
CNN ^[82]	发电成本	内点法	预测精度 99%,效率提升 350 倍
LSTM-NSGA-II ^[83]	有功网损、电压偏移	无	协调优化目标,减少损耗
Dueling DQN ^[84]	可用传输容量	无	提升电网可用传输容量
PPO ^[85]	发电成本	内点法	求解时间缩短 7 倍以上
DDPG ^[86]	发电成本	内点法	优化时间减少 99% 以上
CC-SAC ^[87]	发电成本	DDPG	计算效率提高 34 倍
TD3 ^[88]	发电成本	DDPG, PPO	收敛到更好的优化结果
分布式 $Q(\lambda)$ ^[89]	发电成本、有功网损、电压稳定分量	内点法	实现复杂目标函数的优化求解

3.4 研究框架

在电力系统潮流计算领域,DL 和 RL 具备不同的工作原理和应用框架。DL 在潮流计算中的研究框架如图 5 所示,主要包括数据预处理、模型训练和模型测试 3 个步骤,目的是利用 DNN 强大的表征能力提高潮流状态估计或预测速度及精度,为电力系统运行提供更准确和实时的潮流信息。DL 模型通过从大量历史或模拟数据中学习潮流状态与各

种因素之间的非线性关系和模式,降低潮流计算的复杂度和开销。RL 在潮流调整中的研究框架如图 6 所示,包括智能体、环境、策略和奖励等要素。RL 更注重提升决策和优化能力,通过智能体与环境交互学习最优决策策略,实现潮流的收敛和优化。RL 可以通过与环境交互进行在线学习,具备适应复杂和动态环境的能力。

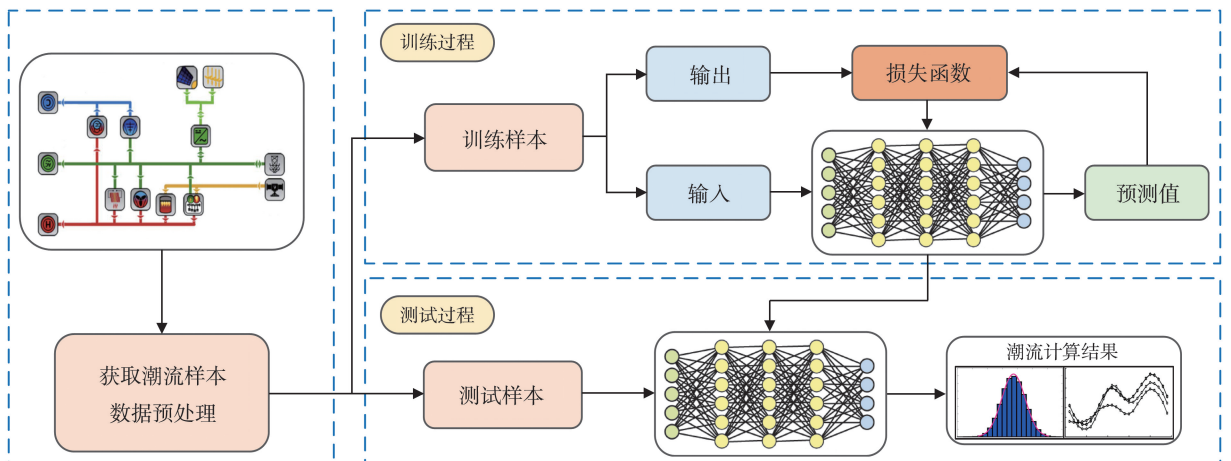


图 5 深度学习潮流计算研究框架

Fig.5 Research framework for deep learning in power flow calculation

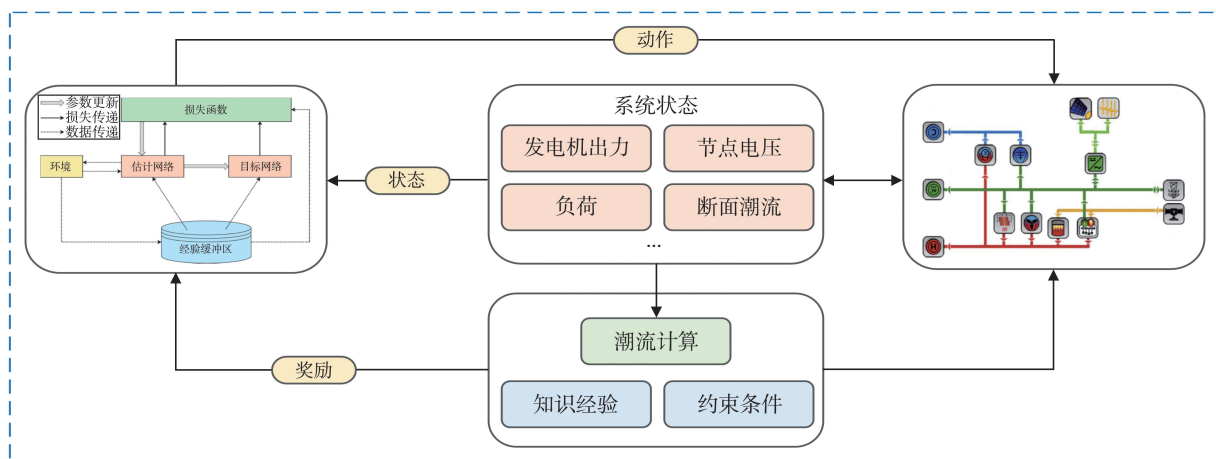


图 6 强化学习潮流计算研究框架

Fig.6 Research framework for reinforcement learning in power flow calculation

4 人工智能潮流计算的挑战与应用范式

4.1 亟待解决的问题与挑战

结合新一代 AI 技术,研究人员在电力系统潮流计算领域已取得重要进展,AI 技术的应用不仅提

升潮流计算的准确性和效率,还有助于解决电力系统复杂性和不确定性问题,为系统规划和调控提供更可靠的支持。然而,AI 技术在潮流计算领域尚面临多个问题和挑战,限制了大范围推广应用。目前,存在的问题主要包括样本数据稀缺及质量较差、模型的鲁棒性和泛化能力不足、计算资源需求较大和效率受限。未来聚焦的研究重点如图 7 所示。



图 7 人工智能潮流计算面临的挑战及未来研究重点

Fig.7 Challenges and future focus of artificial intelligence in power flow calculation

4.1.1 样本数据稀缺及质量较差问题

在电力系统中,AI 的应用面临样本数据稀缺和数据质量方面的普遍挑战。样本数据稀缺是指在潮流计算中缺乏足够数量和广度的数据。电力系统涉及众多发电机、变压器、输电线路和负荷等复杂元素,其详细数据的收集、存储和更新需要大量时间和资源。特别是对于动态电力系统,几乎不可能获取全面详尽的系统状态描述数据,导致数据稀缺,准确建模所需数据受限。数据质量问题包括数

据中可能存在的错误、噪声或缺失。此外,数据可能受传感器误差、通信故障甚至人为操作的影响,导致数据偏差、不一致性或异常。由于潮流计算对输入数据的准确性要求极高,清理错误数据以提高数据质量,确保计算结果的可靠性和准确性至关重要。

未来的研究重点之一是 AI 算法如何摆脱对海量数据的依赖,利用数据增强技术扩充样本、确保样本的合理性及实现小样本学习等^[90-91]。目前,在

电力系统潮流计算领域缺乏用于 AI 模型训练的典型数据集,因此,构建一个用于基准测试的典型开源数据集具有重要价值。

4.1.2 模型的鲁棒性和泛化能力不足

电力系统潮流计算模型的鲁棒性和泛化能力是指其在应对各种情况时的稳定性和适应能力^[92]。鲁棒性表明模型对输入数据中的噪声和干扰具有一定容忍度,即使输入数据存在一定程度的扰动,模型仍能输出合理且可靠的结果。泛化能力指模型在面对未知情况时的适应能力,由于电力系统的运行环境随时可能发生变化,如负荷变化、发电机故障或新设备接入等,具备良好泛化能力的模型能够根据新的输入数据和环境变化自适应地进行计算,无需重新训练或调整模型参数。鉴于电力系统的复杂性和不确定性,能够处理各种未知因素和变化以保持准确性和可靠性是 AI 在潮流计算领域推广应用的关键前提。

除了改善潮流数据质量外,提高模型的鲁棒性和泛化能力需要综合考虑多方面因素。集成学习可将多个不同类型的智能模型集成在一起,利用集体智能思想,通过模型间协作和决策融合提高鲁棒性和泛化能力^[93]。利用迁移学习方法将相关领域或任务得到的模型知识迁移到潮流计算中,加速模型的学习和适应能力^[94]。此外,对抗性训练、异常检测机制及网络结构设计等策略均具备提高潮流计算模型鲁棒性和泛化能力的潜力。

4.1.3 计算资源需求较大和效率受限

在潮流计算中, AI 模型可以提供更灵活的预测和控制能力。这些模型的计算需求往往非常高,需要大量的计算资源和时间进行训练和推断,给实际生产环境带来一些挑战。首先,部署和运行智能学习模型需要高性能的硬件和大规模的计算集群,包括强大的图形处理单元或专用的深度学习加速器,以及存储和网络设备支持大规模数据处理和模型通信,而硬件资源的高成本采购和维护限制了其在资源受限生产环境中的实际应用。其次, AI 模型通常需要大量的训练数据和迭代训练过程以达到良好的性能,训练过程可能需要数小时、数天甚至数周的时间,而实际生产环境对响应时间和实时性要求较高。因此,如何打破计算资源的限制,或者在计算资源受限情况下如何找到计算效率和模型性能之间的平衡点,是实现高效可靠 AI 辅助潮流计算的前提。

通过改进智能模型结构和优化算法,减小模型规模和计算负载,充分挖掘边缘计算资源,利用分布式计算及联邦学习等技术,是实现高效潮流计算

的解决方式^[95-97]。软硬件协同设计优化的趋势将在未来推动潮流计算的发展,硬件技术的不断升级将为潮流计算提供更多的计算资源,更复杂和更精确的模型得以应用。此外,针对特定硬件架构的优化编程、并行计算模型的改进将推动智能模型进行更高效训练和推断方法的研究。

4.2 应用范式转变

解决 AI 在电力系统潮流计算中的问题和挑战是该领域发展的必要条件。然而,即使这些问题得到解决,大规模推广应用仍然存在疑问。目前,几乎所有 AI 模型解决问题的研究范式均是基于数据驱动的方式,虽然数据驱动方法在处理复杂问题和挖掘模式方面取得了很大成功,但其局限包括缺乏可解释性和决策的透明性,没有明确考虑物理规律和基本原理。

传统的牛顿-拉弗森法等潮流计算方法是基于明确的物理方程和数学模型,通过对电力系统的物理特性建模提供详细的解释和理解。AI 技术通过从大量数据中学习模式和规律,适应复杂的电力系统行为。AI 技术一般是基于复杂神经网络结构的黑盒模型,缺乏可解释性,内部参数和计算过程很难以人类可理解的方式进行解释^[98]。在电力系统领域中,决策的透明性和可解释性对运营商、监管机构 and 用户都至关重要,在需要对决策进行审核、监督或解释的情况下, AI 模型解释性差的问题是难以接受的。在监管机构监督电力系统运营和对异常事件进行调查分析等情况下,可解释性的模型能够提供对决策过程的解释和理解,提高电力系统的透明度和可靠性。因此,突破黑盒模型的限制,建立一套可解释性的理论框架,在决策过程中清晰地展示模型内部的推理过程和依据,是未来 AI 技术在电力系统潮流计算领域的研究范式,同时也将推动 AI 在更多领域的广泛应用。

5 结束语

人工智能技术强大的数据发掘和分析能力为电力系统潮流计算问题提供一种全新的解决方案。本研究综述以深度学习和强化学习为代表的新一代人工智能技术在电力系统潮流计算领域的研究进展,对人工智能算法模型、潮流计算的传统求解方法及人工智能技术应用于潮流计算的研究进行全面总结,分析智能模型在不同场景潮流计算问题中的应用优势,探讨亟待解决的技术问题与解决思路。此外,针对电力系统领域中决策透明性和可解释性的需求,讨论人工智能技术在潮流计算等电力

系统领域的未来研究范式,旨在促进该研究领域理论及应用的不断进步和完善。

参考文献:

- [1] 曹永吉,张恒旭,施啸寒,等. 规模化分布式能源参与大电网安全稳定控制的机制初探[J]. 电力系统自动化, 2021, 45(18): 1-8.
CAO Yongji, ZHANG Hengxu, SHI Xiaohan, et al. Preliminary study on participation mechanism of large-scale distributed energy resource in security and stability control of large power grid[J]. Automation of Electric Power Systems, 2021, 45(18): 1-8.
- [2] LI P H, WU W C, WANG X M, et al. A data-driven linear optimal power flow model for distribution networks[J]. IEEE Transactions on Power Systems, 2022, 38(1): 956-959.
- [3] FAN Z X, YANG Z F, YU J, et al. Minimize linearization error of power flow model based on optimal selection of variable space[J]. IEEE Transactions on Power Systems, 2021, 36(2): 1130-1140.
- [4] 张恒旭,高志民,曹永吉,等. 高比例可再生能源接入下电力系统惯量研究综述及展望[J]. 山东大学学报(工学版), 2022, 52(5): 1-13.
ZHANG Hengxu, GAO Zhimin, CAO Yongji, et al. Review and prospect of research on power system inertia with high penetration of renewable energy source[J]. Journal of Shandong University (Engineering Science), 2022, 52(5): 1-13.
- [5] 张亚平,马唯婧,张宸硕,等. 基于图像识别与CAE仿真技术的输变电塔一体化分析[J]. 山东大学学报(工学版), 2023, 53(6): 122-130.
ZHANG Yaping, MA Weijing, ZHANG Chenshuo, et al. Integrated analysis of transmission and transformation towers based on image recognition and CAE simulation technology[J]. Journal of Shandong University (Engineering Science), 2023, 53(6): 122-130.
- [6] 李兴华. 基于规则的电力系统潮流自动调整研究[D]. 武汉: 华中科技大学, 2007.
LI Xinghua. Research on auto adjustment in power flow based on rule[D]. Wuhan: Huazhong University of Science and Technology, 2007.
- [7] 张恒旭,曹永吉,张怡,等. 电力系统频率动态行为衍变与分析方法需求综述[J]. 山东大学学报(工学版), 2021, 51(5): 42-52.
ZHANG Hengxu, CAO Yongji, ZHANG Yi, et al. Review of frequency dynamic behavior evolution and analysis method requirements of power system[J]. Journal of Shandong University (Engineering Science), 2021, 51(5): 42-52.
- [8] GAO Q, YANG Z F, YU J, et al. Model-driven architecture of extreme learning machine to extract power flow features[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(10): 4680-4690.
- [9] KHODAYAR M, LIU G Y, WANG J H, et al. Deep learning in power systems research: a review[J]. CSEE Journal of Power and Energy Systems, 2021, 7(2): 209-220.
- [10] ZHANG Y, SHI X H, ZHANG H X, et al. Review on deep learning applications in frequency analysis and control of modern power system[J]. International Journal of Electrical Power & Energy Systems, 2022, 136: 107744.
- [11] 余涛,周斌,甄卫国. 强化学习理论在电力系统中的应用及展望[J]. 电力系统保护与控制, 2009, 37(14): 122-128.
YU Tao, ZHOU Bin, ZHEN Weigu. Application and development of reinforcement learning theory in power systems[J]. Power System Protection and Control, 2009, 37(14): 122-128.
- [12] ROTHMANN M, PORRMANN M. A survey of domain-specific architectures for reinforcement learning[J]. IEEE Access, 2022, 10: 13753-13767.
- [13] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [14] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [15] LIAO S, LI S B, LIU J Y, et al. A zeroing neural dynamics based acceleration optimization approach for optimizers in deep neural networks[J]. Neural Networks, 2022, 150: 440-461.
- [16] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [17] WANG X P. Research and optimization of BP neural network algorithm[C]// 2015 Seventh International Conference on Measuring Technology and Mechatronics Automation. Nanchang, China: IEEE, 2015: 818-822.
- [18] PEI X J, TIAN S W, YU L, et al. A two-stream network based on capsule networks and sliced recurrent neural networks for DGA botnet detection[J]. Journal of Network and Systems Management, 2020, 28(4): 1694-1721.
- [19] HUANG Z L, YANG F F, XU F, et al. Convolutional gated recurrent unit-recurrent neural network for state-of-charge estimation of lithium-ion batteries[J]. IEEE Access, 2019, 7: 93139-93149.
- [20] DING S Y, WANG Z J, KONG W J, et al. Electrode regulating system modeling in electrical smelting furnace using recurrent neural network with attention mechanism[J]. Neurocomputing, 2019, 359: 32-40.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term

- memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [22] WANG Z, ZHENG X, LI D Y, et al. A VGGNet-like approach for classifying and segmenting coal dust particles with overlapping regions [J]. *Computers in Industry*, 2021, 132: 103506.
- [23] SHEHAB L H, FAHMY O M, GASSER S M, et al. An efficient brain tumor image segmentation based on deep residual networks (ResNets) [J]. *Journal of King Saud University - Engineering Sciences*, 2021, 33(6): 404-412.
- [24] LIAO T T, LI L, OUYANG R S, et al. Classification of asymmetry in mammography via the DenseNet convolutional neural network [J]. *European Journal of Radiology Open*, 2023, 11: 100502.
- [25] CHENG X R, CUI B J, HOU S Z. Fault line selection of distribution network based on modified CEEMDAN and GoogLeNet neural network [J]. *IEEE Sensors Journal*, 2022, 22(13): 13346-13364.
- [26] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [27] LU W, JIANG N, JIN D, et al. Learning distinct relationship in package recommendation with graph attention networks [J]. *IEEE Transactions on Computational Social Systems*, 2023, 10(6): 3308-3320.
- [28] CHEN C C, LI Q, CHEN L, et al. An improved GraphSAGE to detect power system anomaly based on time-neighbor feature [J]. *Energy Reports*, 2023, 9: 930-937.
- [29] YAO X, ZHU H Y, GU M. Brain-inspired GCN: modularity-based Siamese simple graph convolutional networks [J]. *Information Sciences*, 2024, 657: 119971.
- [30] TIAN J, LI P. An intrusion detection algorithm of dynamic recursive deep belief networks [C] // *Proceedings of the 2017 International Conference on Information Technology*. Singapore: ACM, 2017: 180-183.
- [31] DONG Q L, GE F F, NING Q, et al. Modeling hierarchical brain networks via volumetric sparse deep belief network [J]. *IEEE Transactions on Biomedical Engineering*, 2020, 67(6): 1739-1748.
- [32] WANG G M, QIAO J F, BI J, et al. TL-GDBN: growing deep belief network with transfer learning [J]. *IEEE Transactions on Automation Science and Engineering*, 2019, 16(2): 874-885.
- [33] FEI R, SHA J Y, XU Q Z, et al. A new deep sparse autoencoder for community detection in complex networks [J]. *EURASIP Journal on Wireless Communications and Networking*, 2020, 2020: 91.
- [34] KINGMA D P, WELLING M. An introduction to variational autoencoders [J]. *Foundations and Trends[®] in Machine Learning*, 2019, 12(4): 307-392.
- [35] DIALLO B, HU J, LI T R, et al. Deep embedding clustering based on contractive autoencoder [J]. *Neurocomputing*, 2021, 433: 96-107.
- [36] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion [J]. *Journal of Machine Learning Research*, 2010, 11: 3371-3408.
- [37] 赵婷婷, 孔乐, 韩雅杰, 等. 模型化强化学习研究综述 [J]. *计算机科学与探索*, 2020, 14(6): 918-927.
ZHAO Tingting, KONG Le, HAN Yajie, et al. Review of model-based reinforcement learning [J]. *Journal of Frontiers of Computer Science and Technology*, 2020, 14(6): 918-927.
- [38] MA Y, CHANG T Q, FAN W H. A single-task and multi-decision evolutionary game model based on multi-agent reinforcement learning [J]. *Journal of Systems Engineering and Electronics*, 2021, 32(3): 642-657.
- [39] CHEN X, LI Z, WANG K, et al. MDP-based network selection with reward optimization in HetNets [J]. *Chinese Journal of Electronics*, 2018, 27(1): 183-190.
- [40] YANG Y, LI J T, PENG L L. Multi-robot path planning based on a deep reinforcement learning DQN algorithm [J]. *CAAI Transactions on Intelligence Technology*, 2020, 5(3): 177-183.
- [41] YUAN H, NI J, HU J B. A centralised training algorithm with D3QN for scalable regular unmanned ground vehicle formation maintenance [J]. *IET Intelligent Transport Systems*, 2021, 15(4): 562-572.
- [42] XU W F, LI Y H, PEI B B, et al. Coordinated intelligent control of the flight control system and shape change of variable sweep morphing aircraft based on dueling-DQN [J]. *Aerospace Science and Technology*, 2022, 130: 107898.
- [43] PAN J, WANG X S, CHENG Y H, et al. Multisource transfer double DQN based on actor learning [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(6): 2227-2238.
- [44] LIU X H, ZHANG H W, DONG S Q, et al. Network defense decision-making based on a stochastic game system and a deep recurrent Q-network [J]. *Computers & Security*, 2021, 111: 102480.
- [45] WU J L, WU Q M J, CHEN S Y, et al. A-TD3: an adaptive asynchronous twin delayed deep deterministic for continuous action spaces [J]. *IEEE Access*, 2022, 10: 128077-128089.
- [46] HUO W W, ZHAO T Y, YANG F, et al. An improved soft actor-critic based energy management strategy of fuel cell hybrid electric vehicle [J]. *Journal of Energy*

- Storage, 2023, 72: 108243.
- [47] MENG W J, ZHENG Q, SHI Y, et al. An off-policy trust region policy optimization method with monotonic improvement guarantee for deep reinforcement learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(5): 2223-2235.
- [48] TANG C Y, LIU C H, CHEN W K, et al. Implementing action mask in proximal policy optimization (PPO) algorithm[J]. ICT Express, 2020, 6(3): 200-203.
- [49] TAN C D, WANG C Q, TIAN J J, et al. Optimization of profile control and oil displacement scheme parameters based on deep deterministic policy gradient [J]. ACS Omega, 2023, 8(26): 23739-23753.
- [50] SHEN H, ZHANG K Q, HONG M Y, et al. Towards understanding asynchronous advantage actor-critic: convergence and linear speedup [J]. IEEE Transactions on Signal Processing, 2023, 71: 2579-2594.
- [51] JIN Z H, WU J H, LIU A D, et al. Policy-based deep reinforcement learning for visual servoing control of mobile robots with visibility constraints[J]. IEEE Transactions on Industrial Electronics, 2021, 69(2): 1898-1908.
- [52] JI Y, YUAN J, QIAN J F, et al. Power flow calculation in smart distribution network based on power machine learning based on fractional differential equations [J]. Applied Mathematics and Nonlinear Sciences, 2023, 8(1): 1037-1044.
- [53] 彭慧敏, 袁虎玲, 鲍颜红, 等. 大电网病态潮流的识别和修正方法 [J]. 电力系统保护与控制, 2018, 46(22): 116-123.
- PENG Huimin, YUAN Huling, BAO Yanhong, et al. Identification and correction method for ill-conditioned power flow of large scale network [J]. Power System Protection and Control, 2018, 46(22): 116-123.
- [54] 安军, 宋俊达, 葛维春. 大规模电力系统潮流计算收敛性诊断与调整方法 [J]. 电力自动化设备, 2020, 40(2): 103-109.
- AN Jun, SONG Junda, GE Weichun. Convergence identification and adjustment method of power flow calculation for large-scale power system [J]. Electric Power Automation Equipment, 2020, 40(2): 103-109.
- [55] KARIMI M, SHAHRIARI A, AGHAMOHAMMADI M R, et al. Application of Newton-based load flow methods for determining steady-state condition of well and ill-conditioned power systems: a review [J]. International Journal of Electrical Power & Energy Systems, 2019, 113: 298-309.
- [56] CAO Y J, ZHANG Y, ZHANG H X, et al. Probabilistic optimal PV capacity planning for wind farm expansion based on NASA data [J]. IEEE Transactions on Sustainable Energy, 2017, 8(3): 1291-1300.
- [57] 朱星阳, 刘文霞, 张建华, 等. 电力系统随机潮流及其安全评估应用研究综述 [J]. 电工技术学报, 2013, 28(10): 257-270.
- ZHU Xingyang, LIU Wenxia, ZHANG Jianhua, et al. Reviews on power system stochastic load flow and its applications in safety evaluation [J]. Transactions of China Electrotechnical Society, 2013, 28(10): 257-270.
- [58] RAMADHANI U H, SHEPERO M, MUNKHAMMAR J, et al. Review of probabilistic load flow approaches for power distribution systems with photovoltaic generation and electric vehicle charging [J]. International Journal of Electrical Power & Energy Systems, 2020, 120: 106003.
- [59] DE MEL I, KLYMENKO O V, SHORT M. Balancing accuracy and complexity in optimisation models of distributed energy systems and microgrids with optimal power flow: a review [J]. Sustainable Energy Technologies and Assessments, 2022, 52: 102066.
- [60] YANG Z F, ZHONG H W, XIA Q, et al. Fundamental review of the OPF problem: challenges, solutions, and state-of-the-art algorithms [J]. Journal of Energy Engineering, 2018, 144(1): 04017075.
- [61] YU Z, BAO Y Q. Data-driven power flow calculation based on deep learning [C]//2021 IEEE 5th Conference on Energy Internet and Energy System Integration (EI2). Taiyuan, China: IEEE, 2021: 3230-3234.
- [62] 杨梅, 刘俊勇, 刘挺坚, 等. 节点图和边图切换卷积驱动的快速静态安全分析方法 [J]. 电网技术, 2021, 45(6): 2070-2080.
- YANG Mei, LIU Junyong, LIU Tingjian, et al. Switching convolution of node graph and line graph-driven method for fast static security analysis [J]. Power System Technology, 2021, 45(6): 2070-2080.
- [63] VYAKARANAM B, MAHAPATRA K, LI X Y, et al. Novel data-driven distributed learning framework for solving AC power flow for large interconnected systems [J]. IEEE Open Access Journal of Power and Energy, 2021, 8: 281-292.
- [64] XU H, YU Z, ZHENG Q, et al. Improved deep reinforcement learning based convergence adjustment method for power flow calculation [C]//The 16th IET International Conference on AC and DC Power Transmission (ACDC 2020). [S. l.]: IET, 2020: 1898-1903.
- [65] 王甜婧, 汤涌, 郭强, 等. 基于知识经验和深度强化学习的大电网潮流计算收敛自动调整方法 [J]. 中国电机工程学报, 2020, 40(8): 2396-2406.
- WANG Tianjing, TANG Yong, GUO Qiang, et al. Automatic adjustment method of power flow calculation convergence for large-scale power grid based on knowledge experience and deep reinforcement learning [J]. Proceedings of the CSEE, 2020, 40(8):

- 2396-2406.
- [66] 郑清平. 基于深度强化学习的电网断面功率调整研究[D]. 北京: 北京邮电大学, 2021.
ZHENG Qingping. Research on tie-line power of grid adjustment based on deep reinforcement learning[D]. Beijing: Beijing University of Posts and Telecommunications, 2021.
- [67] WANG T J, TANG Y. An unsolvable power flow adjustment method for weak power grid based on transmission channel positioning and deep reinforcement learning[J]. *Electric Power Systems Research*, 2022, 210: 108050.
- [68] PU T J, WANG X Y, CAO Y F, et al. Power flow adjustment for smart microgrid based on edge computing and multi-agent deep reinforcement learning[J]. *Journal of Cloud Computing*, 2021, 10(1): 48.
- [69] 杨晓东, 严剑峰, 刘佳霖. 结合深度强化学习与人工经验的电网输电断面功率调整方法[J]. *电力系统自动化*, 2023, 47(15): 133-141.
YANG Xiaodong, YAN Jianfeng, LIU Jialin. Power adjustment method for transmission section in power grid combining deep reinforcement learning and artificial experience[J]. *Automation of Electric Power Systems*, 2023, 47(15): 133-141.
- [70] XU H T, YU Z H, ZHENG Q P, et al. Deep reinforcement learning-based tie-line power adjustment method for power system operation state calculation[J]. *IEEE Access*, 2019, 7: 156160-156174.
- [71] 余娟, 杨燕, 杨知方, 等. 基于深度学习的概率能量流快速计算方法[J]. *中国电机工程学报*, 2019, 39(1): 22-30.
YU Juan, YANG Yan, YANG Zhifang, et al. Fast probabilistic energy flow analysis based on deep learning[J]. *Proceedings of the CSEE*, 2019, 39(1): 22-30.
- [72] WANG D W, ZHENG K D, CHEN Q X, et al. A data-driven probabilistic power flow method based on convolutional neural networks[J]. *International Transactions on Electrical Energy Systems*, 2020, 30(7): e12367.
- [73] SONG S, JUNG Y, HAN C, et al. Recurrent neural-network-based maximum frequency deviation prediction using probability power flow dynamic tool[J]. *IEEE Access*, 2020, 8: 182054-182064.
- [74] XIAO H, PEI W, WU L, et al. A novel deep learning based probabilistic power flow method for multi-microgrids distribution system with incomplete network information[J]. *Applied Energy*, 2023, 335: 120716.
- [75] WU H Y, WANG M H, XU Z, et al. Graph attention enabled convolutional network for distribution system probabilistic power flow[J]. *IEEE Transactions on Industry Applications*, 2022, 58(6): 7068-7078.
- [76] 白洁, 王守相, 赵倩宇, 等. 考虑风电出力不确定性的配电网概率潮流计算[J]. *电力系统及其自动化学报*, 2021, 33(1): 78-84.
BAI Jie, WANG Shouxiang, ZHAO Qianyu, et al. Probabilistic load flow calculation for distribution network considering uncertainties in wind power output[J]. *Proceedings of the CSU-EPSCA*, 2021, 33(1): 78-84.
- [77] 蔡新雷, 董锴, 崔艳林, 等. 基于长短期记忆网络的电网概率潮流计算及态势感知[J]. *电子器件*, 2022, 45(4): 939-946.
CAI Xinlei, DONG Kai, CUI Yanlin, et al. Probabilistic power flow calculation and situation awareness based on long short term memory network[J]. *Chinese Journal of Electron Devices*, 2022, 45(4): 939-946.
- [78] WU H Y, WANG M H, XU Z, et al. Probabilistic power flow of distribution system based on a graph-aware deep learning network[C]//2021 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia). Chengdu, China: IEEE, 2021: 105-109.
- [79] DONG Z H, HOU K, LIU Z Y, et al. A sample-efficient OPF learning method based on annealing knowledge distillation[J]. *IEEE Access*, 2022, 10: 99724-99733.
- [80] ZHOU M, CHEN M H, LOW S H. DeepOPF-FT: one deep neural network for multiple AC-OPF problems with flexible topology[J]. *IEEE Transactions on Power Systems*, 2023, 38(1): 964-967.
- [81] SU Q G, KHAN H U, KHAN I, et al. An optimized algorithm for optimal power flow based on deep learning[J]. *Energy Reports*, 2021, 7: 2113-2124.
- [82] JIA Y J, BAI X Q, ZHENG L Q, et al. ConvOPF-DOP: a data-driven method for solving AC-OPF based on CNN considering different operation patterns[J]. *IEEE Transactions on Power Systems*, 2023, 38(1): 853-860.
- [83] LI H, LI H J, LU W H, et al. Optimal power flow calculation considering large-scale photovoltaic generation correlation[J]. *Frontiers in Energy Research*, 2020, 8: 590418.
- [84] LAN T, DUAN J J, ZHANG B, et al. AI-based autonomous line flow control via topology adjustment for maximizing time-series ATCs[C]//2020 IEEE Power & Energy Society General Meeting (PESGM). Montreal, Canada: IEEE, 2020: 1-5.
- [85] ZHOU Y H, ZHANG B, XU C L, et al. A data-driven method for fast AC optimal power flow solutions via deep reinforcement learning[J]. *Journal of Modern Power Systems and Clean Energy*, 2020, 8(6): 1128-1139.

- [86] YAN Z M, XU Y. A hybrid data-driven method for fast solution of security-constrained optimal power flow[J]. IEEE Transactions on Power Systems, 2022, 37(6): 4365-4374.
- [87] SAYED A R, WANG C, ANIS H I, et al. Feasibility constrained online calculation for real-time optimal power flow: a convex constrained deep reinforcement learning approach [J]. IEEE Transactions on Power Systems, 2023, 38(6): 5215-5227.
- [88] SUN B W, SONG M G, LI A, et al. Multi-objective solution of optimal power flow based on TD3 deep reinforcement learning algorithm[J]. Sustainable Energy, Grids and Networks, 2023, 34: 101054.
- [89] 余涛, 刘靖, 胡细兵. 基于分布式多步回溯 $Q(\lambda)$ 学习的复杂电网最优潮流算法[J]. 电工技术学报, 2012, 27(4): 185-192.
- YU Tao, LIU Jing, HU Xibing. Optimal power flow for complex power grid using distributed multi-step backtrack $Q(\lambda)$ learning [J]. Transactions of China Electrotechnical Society, 2012, 27(4): 185-192.
- [90] 摆世彬, 严明辉, 徐伟, 等. 含大规模风电集群电网的在线计算数据生成技术[J]. 电力系统保护与控制, 2021, 49(3): 66-73.
- BAI Shibin, YAN Minghui, XU Wei, et al. An online calculation data generation technology for a power grid integrated with a large-scale wind farm[J]. Power System Protection and Control, 2021, 49(3): 66-73.
- [91] DU Z M, CHEN K, CHEN S L, et al. Deep learning GAN-based data generation and fault diagnosis in the data center HVAC system [J]. Energy and Buildings, 2023, 289: 113072.
- [92] LIU X L, SHEN F R, ZHAO J, et al. AugRmixAT: a data processing and training method for improving multiple robustness and generalization performance [C]//2022 IEEE International Conference on Multimedia and Expo (ICME). Taipei, China: IEEE, 2022: 1-6.
- [93] MOHAMMED A, KORA R. A comprehensive review on ensemble deep learning: opportunities and challenges [J]. Journal of King Saud University – Computer and Information Sciences, 2023, 35(2): 757-774.
- [94] WANG W P, WANG Z R, ZHOU Z F, et al. Anomaly detection of industrial control systems based on transfer learning[J]. Tsinghua Science and Technology, 2021, 26(6): 821-832.
- [95] 陈祎鹏, 杨哲, 谷飞, 等. 一种基于博弈论的移动边缘计算资源分配策略[J]. 计算机科学, 2023, 50(2): 32-41.
- CHEN Yipeng, YANG Zhe, GU Fei, et al. Resource allocation strategy based on game theory in mobile edge computing[J]. Computer Science, 2023, 50(2): 32-41.
- [96] HUSSAIN H, MALIK S U R, HAMEED A, et al. A survey on resource allocation in high performance distributed computing systems [J]. Parallel Computing, 2013, 39(11): 709-736.
- [97] YANG Q, LIU Y, CHEN T, et al. Federated machine learning: concept and applications[J]. ACM Transactions on Intelligent Systems and Technology, 2019, 10(2): 12.
- [98] 成科扬, 王宁, 师文喜, 等. 深度学习可解释性研究进展[J]. 计算机研究与发展, 2020, 57(6): 1208-1217.
- CHENG Keyang, WANG Ning, SHI Wenxi, et al. Research advances in the interpretability of deep learning [J]. Journal of Computer Research and Development, 2020, 57(6): 1208-1217.

(编辑:孙亚彤)