

考虑数据中心负载灵活迁移特性的 主动配电网阻塞管理

薛霖^{1,2}, 周越³, 王建学^{1,2}, 古宸嘉⁴, 侯果^{1,2}, 田子豪^{1,2}

(1. 西安交通大学电气工程学院, 710049, 西安; 2. 西安交通大学电工材料电气绝缘全国重点实验室,
710049, 西安; 3. 天津大学电气自动化与信息工程学院, 300072, 天津;
4. 四川大学电气工程学院, 610065, 成都)

摘要: 针对新能源大量接入和数据中心负载分布不均导致的配电网阻塞问题,提出了基于模型-数据混合驱动的两阶段分层阻塞管理方法。在第 1 阶段,考虑主动配电网中有载调压变压器和并联电容器组的调节能力,建立了基于直接资源控制的主动配电网长时间尺度阻塞管理方法,并采用数据驱动的深度强化学习算法优化其投切档位。在第 2 阶段,建立了基于数据中心集群负载灵活迁移特性的主动配电网短时间尺度阻塞管理方法,将数据中心动态频率调节技术和动态服务器配置技术与工作负载灵活迁移特性相结合,并采用模型驱动的二阶锥规划算法,对新能源逆变器和 workload 迁移进行优化。改进的 IEEE 33 节点系统测试结果表明:所提两阶段阻塞管理方法可有效解决系统线路阻塞问题,测试日最大支路负载率由 139.59% 降至 83.92%;与传统优化方法相比,所提方法将求解用时缩短至 18.73 s,成本仅增加 0.8%,具有更好的求解效率和鲁棒性,实现了数据中心集群与主动配电网的友好协同互动。

关键词: 主动配电网;数据中心;阻塞管理;模型-数据混合驱动

中图分类号: TM72 **文献标志码:** A

DOI: 10.7652/xjtuxb202602019 **文章编号:** 0253-987X(2026)02-0195-12

Active Distribution Network Congestion Management Considering Flexible Migration Characteristics of Data Center Workload

XUE Lin^{1,2}, ZHOU Yue³, WANG Jianxue^{1,2}, GU Chenjia⁴, HOU Guo^{1,2}, TIAN Zihao^{1,2}

(1. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. State Key Laboratory of
Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China; 3. School of
Electrical and Information Engineering, Tianjin University, Tianjin 300072, China; 4. College of
Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: To address the congestion problem in distribution networks caused by high penetration of renewable energy and uneven spatial distribution of data center workload, a two-stage hierarchical congestion management method based on a model-data hybrid-driven approach is proposed. In the first stage, considering the regulation capabilities of resources such as on-load tap changers and shunt capacitor banks in the active distribution network, a long-timescale congestion management method based on direct resource control is established and optimized using a data-driven deep reinforcement learning algorithm to adjust their switching positions. In

收稿日期: 2025-06-27。 作者简介: 薛霖(1997—),男,博士生;王建学(通信作者),男,教授,博士生导师。 基金
项目: 国家重点研发计划资助项目(2022YFB2403500)。

网络出版时间: 2025-09-25

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20250924.1358.004>

the second stage, a short-timescale congestion management method for the active distribution network is developed based on the flexible migration characteristics of data center cluster workload. This method integrates dynamic frequency regulation technology and dynamic server configuration technology of data centers with flexible workload migration characteristics, and employs a model-driven second-order cone programming algorithm to optimize renewable energy inverters and workload migration. Test results on a modified IEEE 33-node system show that the proposed two-stage congestion management method can effectively alleviate line congestion, reducing the maximum branch load ratio from 139.59% to 83.92% on the test day. Compared with traditional optimization methods, the proposed method shortens the solution time to 18.73 s with only a 0.8% cost increase, demonstrating better solution efficiency and robustness, and achieving friendly and coordinated interaction between data center clusters and the active distribution network.

Keywords: active distribution network; data center; congestion management; hybrid model-data method

随着分布式新能源在配电网中的大规模接入,传统配电网将逐渐向主动配电网转变^[1]。新能源的随机性和间歇性,严重影响着配电网的安全运行,极易引起线路阻塞、电压越限等问题。新型配电系统的负荷形态呈现多元化的发展趋势,规模化云数据中心(CDC)将逐步发展成为配电系统的新型负荷^[2]。数据中心能耗巨大,已经成为主要电力负荷之一,预计到2030年,其用电量将达到全社会用电量的8%^[3]。然而,高渗透率可再生能源的不确定性,以及数据中心工作负载的时段聚集和空间分布不均等现象,将会引起配电网发生线路过载、电压越限等问题^[4],严重影响配电网的安全、经济运行。

目前,针对配电网阻塞管理的研究大多考虑单一类型的灵活资源或控制手段,而配电网中的源荷侧资源丰富,有效利用各类灵活资源之间的协同与耦合效应,能够实现更好的阻塞管理效果。文献[5]将智能软开关和电动汽车充电站相结合,利用两阶段优化算法实现了交直流配电网的阻塞管理。文献[6]采用两阶段的调节方法,先通过直接控制有载调压变压器、网络重构等手段优化系统潮流,再通过引入市场电价进行阻塞管理。文献[7]将需求响应与阻塞管理相结合,综合考虑市场机制与移动式储能,实现了负荷用电功率的灵活调整。然而,数据中心作为一种负荷侧灵活性资源,目前鲜有研究将其应用于配电网阻塞管理当中。数据中心的能耗基于负载迁移策略,具有较高的调节灵活性^[8]。利用数据中心集群的灵活调节能力,采用高效合理的协调管理机制,可解决大规模分布式新能源接入和数据中心负载无序供电引起的线路阻塞及电压越限问题,

保障主动配电网的安全稳定运行^[9-10]。

此外,多数文献仅针对日前调度下的阻塞管理问题提出了解决方案。由于工作负载和新能源的不确定性,基于日前确定性潮流得到的阻塞管理策略,可能无法与系统实际运行状态相匹配。因此,研究不确定环境下主动配电网的实时阻塞管理非常必要。近年来,深度强化学习(DRL)因其在不确定环境中处理序列决策问题的能力而受到广泛关注^[11]。文献[12]采用约束马尔可夫决策过程对电动汽车用户的充电决策过程进行建模,并采用安全深度强化学习算法实现了阻塞管理。文献[13]在无需灵活负荷显式概率模型的情况下,利用强化学习算法确定了系统电价,实现了电力运行成本的降低和阻塞的缓解。然而,单纯依赖端到端的DRL方法在解决包含大量连续决策变量问题时,存在决策结果与最优值差距较大、训练易于陷入局部最优并产生不可行动作等缺陷。为解决上述问题,有研究提出了模型-数据混合驱动的求解思路,将数据驱动的策略学习与数学模型相结合,以提升样本效率、保证可行性并缩小与最优解的差距。文献[14]提出了一种结合物理建模与数据驱动的双时间尺度优化策略,解决了高比例间歇性分布式电源接入配电网带来的电压波动问题。文献[15]提出了一种双层调度方法,通过结合模型驱动的日前规划和数据驱动的日内实时决策,提升了区域综合能源系统调度问题的求解速度。

综上所述,目前关于如何利用数据中心作为负荷侧灵活性资源来缓解主动配电网的阻塞问题仍缺乏深入研究。因此,本文基于数据中心集群的负载迁移特性,结合主动配电网的潮流约束和数据中心

的负载需求约束,以最小化主动配电网综合运行成本为目标,提出了一种模型-数据混合驱动的两阶段实时分层阻塞管理方法(HCM)。该方法能在不同时间尺度上协调调度主动配电网的阻塞管理设备,并通过合理的补偿机制激励数据中心集群参与阻塞管理,从而提高系统的安全性和经济性。本文的主要贡献如下。

(1)提出了一种两阶段分层阻塞管理方法,在日内和实时两个时间尺度上分别优化离散控制设备和连续调节设备的协调运行。第1阶段采用深度强化学习优化离散控制的有载调压变压器(OLTC)和并联电容器组(SC)的投切策略,第2阶段采用二阶锥规划优化新能源逆变器和数据中心负载迁移策略。通过结合模型驱动和数据驱动的方法,实现了更加高效的阻塞管理,有效缓解了主动配电网中的电压越限和线路阻塞问题。

(2)构建了考虑数据中心负载迁移灵活性的配电网阻塞管理框架,并引入数据中心动态频率调节技术和动态服务器配置技术。通过动态调整服务器工作频率和在线服务器数量,使得数据中心工作负载迁移策略与配电网的阻塞管理需求相适应。该框架充分发挥了数据中心的灵活调节能力,实现了计算负载与电力负荷的耦合协同,增强了配电网运行的安全性和经济性。

1 两阶段分层阻塞管理框架

本文针对分布式可再生能源大量接入导致的配电网线路阻塞与电压波动问题,通过考虑不同灵活性资源在物理属性和调节时间尺度上的差异,建立了以主动配电网综合运行成本最小为目标的两阶段分层阻塞管理模型,通过多类型灵活资源的协同优化实现系统的安全经济运行。

在训练过程中,长时间尺度计及分布式光伏(PV)、风电(WT)和工作负载的时序波动性及不确定性,通过收集配电网的历史运行数据,搭建深度神经网络模型和强化学习仿真环境,采用数据驱动的深度强化学习算法对小时级离散控制设备(如有载调压变压器与并联电容器组)的投切档位进行决策。短时间尺度设置5 min滚动窗口,以上层投切动作为边界条件,结合配电网与数据中心集群的物理运行模型,采用二阶锥规划算法对新能源逆变器的无功出力和数据中心负载迁移进行精细优化。此外,在离线训练过程中,每一候选上层动作都会被送入下层,以检验短时可行性并计算相应的即时运行代

价;下层给出的可行性指示与运行成本被并入DRL的即时奖励中,从而使得上层策略在追求长期回报的同时,显式考虑短期潮流可行性和运行成本。基于下层最优潮流计算得到的系统运行结果,将作为训练样本和约束反馈,用于不断迭代及优化长时间尺度DRL智能体的训练参数,直至策略收敛,从而实现两阶段之间的闭环联动,并在目标函数层面趋于一致。

在实际应用中,训练完成的智能体可在实际运行时,根据系统状态快速生成离散控制的投切指令,并将该指令作为初始条件反馈给第2阶段,用于进一步优化逆变器出力和数据中心负载迁移策略,从而实现数据-模型联合驱动的协调控制目标。图1给出了本文所提两阶段阻塞管理模型的框架示意图。




图1 两阶段分层阻塞管理框架

Fig. 1 Two-stage hierarchical congestion management framework

2 基于数据中心负载迁移特性的短时间尺度阻塞管理模型

数据中心的计算负载按照对时延的敏感程度,可分为交互式负载和批处理负载^[16]。交互式负载要求在任务到达时实时响应,如金融交易、网页访问、在线支付等;而批处理负载对时延要求较低,仅需在规定时间内完成即可。

数据中心集群地理分散并通过光纤网络连接,凭借光纤网络带宽大、时延低的优异特性,交互式工作负载可在数据中心间完成快速迁移,表现为电力负荷在不同节点间的转移,如图2所示。而批处理负载的迁移通常受限于计算资源调度策略,难以实

现快速动态调整。因此,本文侧重于研究如何将交互式负载在不同算力节点间进行迁移,以实现电力系统主动支撑。




图 2 互联云数据中心示意图

Fig. 2 Schematic diagram of the interconnected cloud data centers

本文假设配电网运营商与云服务商协作,云服务商向配电网运营商提供工作负载等数据,配电网运营商以改善配电网运行为目标,在保证云服务商服务质量的前提下,确定数据中心集群工作负载的调度计划,并将决策结果提供给云服务商。

2.1 工作负载迁移模型

数据中心间通过光纤网络连接,因此必须保证工作负载在数据中心间迁移时均能得到处理,其平衡约束可表示为

$$\sum_i \omega_{ij,t,\tau} = \Lambda_{i,t,\tau} \quad (1)$$

式中: $\omega_{ij,t,\tau}$ 为数据中心 i 在 t 时段 τ 时间间隔迁移至数据中心 j 的工作负载量; $\Lambda_{i,t,\tau}$ 为数据中心 i 在 t 时段 τ 时间间隔初始分配的工作负载量。

数据中心单位时间处理的总工作负载量为

$$\lambda_{j,t,\tau} = \sum_i \omega_{ij,t,\tau} \quad (2)$$

由于工作负载迁移量不能超过链路带宽上限,因此带宽约束可表示为

$$0 \leq \omega_{ij,t,\tau} \leq \bar{W}_{ij} \quad (3)$$

式中: $\bar{W}_{ij}$ 为数据中心 i 和 j 之间链路带宽的上限。

2.2 数据中心能耗模型

数据中心通常由服务器、存储设备、网络设备、制冷设备和电源设备构成,其能耗主要由 IT 设备、制冷设备以及配电设备产生。总功耗的具体表达式可写为

$$P_{j,t,\tau}^{\text{CDC}} = P_{j,t,\tau}^{\text{IT}} + P_{j,t,\tau}^{\text{cool}} + P_{j,t,\tau}^{\text{elec}} \quad (4)$$

式中: $P_{j,t,\tau}^{\text{CDC}}$ 为数据中心 j 在 t 时段 τ 时间间隔的总功耗; $P_{j,t,\tau}^{\text{IT}}$ 、 $P_{j,t,\tau}^{\text{cool}}$ 、 $P_{j,t,\tau}^{\text{elec}}$ 分别为数据中心 j 在 t 时段 τ 时间间隔内 IT 设备、制冷设备和配电设备的功耗。

服务器是数据中心的主要用能单元,在 IT 设

备总能耗中占比最重,因此可用服务器能耗表示 IT 设备能耗^[17],写为固定功率和动态功率的叠加形式

$$P_{j,t,\tau}^{\text{IT}} = S_j^{\text{server}} P_{j,t,\tau}^{\text{server}} \quad (5)$$

$$P_{j,t,\tau}^{\text{server}} = P_{\text{server}, \text{fixed}} + P_{j,t,\tau}^{\text{server}, \text{dynamic}} \quad (6)$$

式中: S_j^{server} 为数据中心 j 的服务器个数; $P_{j,t,\tau}^{\text{server}}$ 为数据中心 j 在 t 时段 τ 时间间隔单台服务器的功耗; $P_{\text{server}, \text{fixed}}$ 为单台服务器开启后的静态功耗; $P_{j,t,\tau}^{\text{server}, \text{dynamic}}$ 为数据中心 j 在 t 时段 τ 时间间隔单台服务器开启后的动态功耗。

数据中心的总能耗常采用服务器设备的功耗来间接估算,其通常由绿色网格组织制定的电能利用效率^[18]计算得出,表达式为

$$P_{j,t,\tau}^{\text{CDC}} = \omega_j^{\text{PUE}} S_j^{\text{server}} P_{j,t,\tau}^{\text{server}} \quad (7)$$

式中: ω_j^{PUE} 为数据中心 j 的电能利用效率。

2.3 动态频率调节技术

动态频率调节技术通过离散调节 CPU 的工作频率,提高单个服务器的利用率,从而降低数据中心的功耗^[19]。为简化操作并提高模型实用性,仅考虑在若干预设的工作频率档位对 CPU 频率进行调节。定义 $f_{j,s,t,\tau}^{\text{CPU}}$ 为数据中心 j 中的服务器在 t 时段 τ 时间间隔处于 s 工作模式下的工作频率, f^{CPU} 为服务器在实际工作中可供选择的 CPU 工作频率, S 为服务器预设的工作频率档位数,则有 $f_{j,s,t,\tau}^{\text{CPU}} \in \{f_1^{\text{CPU}}, f_2^{\text{CPU}}, \dots, f_{S-1}^{\text{CPU}}, f_S^{\text{CPU}}\}$ 。

每个服务器的 CPU 工作频率都有与之对应的服务器处理容量,且处理容量与工作频率成正比,计算式写为

$$\mu_{j,s,t,\tau} = \alpha f_{j,s,t,\tau}^{\text{CPU}} \quad (8)$$

式中: $\mu_{j,s,t,\tau}$ 为数据中心 j 在 t 时段 τ 时间间隔处于 s 工作频率服务器的处理容量; α 为服务器的处理能力系数。

服务器的动态功率与 CPU 工作频率的 3 次方成正比, CPU 工作频率越高,其单位时间内处理任务的能力就越强,但能耗会大大增加。服务器动态功率的计算式如下

$$P_{j,s,t,\tau}^{\text{server}, \text{dynamic}} = \omega^{\text{dynamic}} (f_{j,s,t,\tau}^{\text{CPU}})^3 \rho_{j,s,t,\tau}^{\text{CPU}} \quad (9)$$

式中: $\rho_{j,s,t,\tau}^{\text{CPU}}$ 为数据中心 j 在 t 时段 τ 时间间隔处于 s 工作频率服务器的 CPU 利用率; ω^{dynamic} 为服务器动态功耗系数。

采用单位时间内服务器处理的平均工作负载与服务器处理容量的比值计算服务器 CPU 的利用率,表达式如下

$$\rho_{j,s,t,\tau}^{\text{CPU}} = \frac{\lambda_{j,s,t,\tau} / x_{j,s,t,\tau}^{\text{server}}}{\mu_{j,s,t,\tau}} \quad (10)$$

$$\lambda_{j,t,\tau} = \sum_s \lambda_{j,s,t,\tau} \quad (11)$$

式中: $\lambda_{j,s,t,\tau}$ 为数据中心 j 中工作在 s 工作频率的服务器在 t 时段 τ 时间间隔所需处理的工作负载量; $x_{j,s,t,\tau}^{\text{server}}$ 为数据中心 j 在 t 时段 τ 时间间隔工作在 s 工作频率的服务器开启个数; $\lambda_{j,t,\tau}$ 为数据中心 j 在 t 时段 τ 时间间隔所需处理的总工作负载量。

为了确保硬件稳定运行,在每种工作频率下,服务器 CPU 的利用率必须控制在预设上限以下,表达式为

$$\rho_{j,s,t,\tau}^{\text{CPU}} \leq \bar{\rho}^{\text{CPU}} \quad (12)$$

式中: $\bar{\rho}^{\text{CPU}}$ 为服务器 CPU 利用率上限。

2.4 动态服务器配置技术

动态服务器配置技术可将部分工作负载合并至少量服务器,并在负载较低时关闭闲置服务器,从而降低数据中心的总功耗^[20]。因此,数据中心总功耗可进一步表示为

$$P_{j,t,\tau}^{\text{CDC}} = w_j^{\text{PUE}} x_{j,t,\tau}^{\text{server}} P_{j,t,\tau}^{\text{server}} \quad (13)$$

式中: $x_{j,t,\tau}^{\text{server}}$ 为数据中心服务器开启个数。

根据式(6)和式(13),数据中心 j 在 t 时段 τ 时间间隔的总功耗可表示为

$$P_{j,t,\tau}^{\text{CDC}} = w_j^{\text{PUE}} \sum_s x_{j,s,t,\tau}^{\text{server}} (P_{j,s,t,\tau}^{\text{server, fixed}} + P_{j,s,t,\tau}^{\text{dynamic}}) \quad (14)$$

式(14)中,涉及到服务器动态功耗的部分 $w_j^{\text{PUE}} \sum_s x_{j,s,t,\tau}^{\text{server}} P_{j,s,t,\tau}^{\text{dynamic}}$ 可进一步表示为

$$w_j^{\text{PUE}} \sum_s x_{j,s,t,\tau}^{\text{server}} P_{j,s,t,\tau}^{\text{dynamic}} = w_j^{\text{PUE}} w^{\text{dynamic}} \sum_s (f_{j,s,t,\tau}^{\text{CPU}})^2 \frac{\lambda_{j,s,t,\tau}}{\alpha} \quad (15)$$

2.5 光网络功耗模型

数据中心互联通信网络一般由光纤网络构成,对于典型的光纤网络来说,其能耗可由源节点和目标节点共同承担。为简化光纤网络的功耗模型,可将其表示为静态功率与动态功率的叠加^[21],则光网络链路 (i, j) 的功耗和网元节点 i 的功耗可分别表示为

$$P_{ij,t,\tau}^{\text{net}} = P_{ij,t,\tau}^{\text{net, static}} + w_{ij,t,\tau} P_{ij,t,\tau}^{\text{net, dynamic}} \quad (16)$$

$$P_{i,t,\tau}^{\text{net}} = \frac{1}{2} \sum_j P_{ij,t,\tau}^{\text{net}} \quad (17)$$

式中: $P_{ij,t,\tau}^{\text{net}}$ 为光纤链路 (i, j) 的功耗; $P_{ij,t,\tau}^{\text{net, static}}$ 为光纤网络的静态功耗; $w_{ij,t,\tau}$ 为光纤链路 (i, j) 的传输工作负载量; $P_{ij,t,\tau}^{\text{net, dynamic}}$ 为光纤网络的动态功耗; $\sum_j P_{ij,t,\tau}^{\text{net}}$ 为所有与节点 i 相连链路的功耗之和。

2.6 主动配电网短时间尺度阻塞管理模型

2.6.1 短时间尺度阻塞管理目标函数

主动配电网短时间尺度阻塞管理的目标为综合

运行成本最小。考虑到改变云服务商独立运行模式下的最优负载策略可能会提高其运行成本,因此要实现配电网运行商与云服务商之间的协同优化,配电网运行商需为云服务商提供一定的激励或补偿。主动配电网的综合运行成本可表示为

$$\min C^{\text{total}} = C_{t,\tau}^{\text{loss}} + C_{t,\tau}^{\text{curt}} + C_{t,\tau}^{\text{cong}} + C_{t,\tau}^{\text{compen}} \quad (18)$$

$$C_{t,\tau}^{\text{loss}} = \sum_{i,j} \lambda^{\text{loss}} r_{ij} l_{ij,t,\tau} \quad (19)$$

$$C_{t,\tau}^{\text{curt}} = \sum_j \lambda^{\text{curt}} P_{j,t,\tau}^{\text{curt}} \quad (20)$$

$$C_{t,\tau}^{\text{cong}} = \sum_{i,j} \lambda^{\text{cong}} P_{ij,t,\tau}^{\text{cong}} \quad (21)$$

$$C_{t,\tau}^{\text{compen}} = \sum_j \sum_i \lambda^{\text{compen}} w_{ji,t,\tau} \quad (22)$$

式中: C^{total} 为主动配电网的综合运行成本; $C_{t,\tau}^{\text{loss}}$ 为网络损耗成本; $C_{t,\tau}^{\text{curt}}$ 为新能源削减成本; $C_{t,\tau}^{\text{cong}}$ 为线路阻塞成本; $C_{t,\tau}^{\text{compen}}$ 为对数据中心集群负载迁移的补偿成本; λ^{loss} 为网络损耗成本系数; r_{ij} 为线路 (i, j) 的电阻; $l_{ij,t,\tau}$ 为流过线路 (i, j) 电流幅值的平方; λ^{curt} 为新能源削减成本系数; $P_{j,t,\tau}^{\text{curt}}$ 为新能源削减功率; λ^{cong} 为线路阻塞成本系数; $P_{ij,t,\tau}^{\text{cong}}$ 为线路 (i, j) 超过安全阈值的传输功率; λ^{compen} 为负载迁移补偿成本系数。

为了保证主动配电网的安全运行,配电线路传输能力需要保留一定的安全裕度。当传输功率超过安全阈值时,认为该条线路过载,并对超过安全阈值的功率施加惩罚。考虑到反向功率的存在,线路过载功率约束可表示为

$$P_{ij,t,\tau}^{\text{cong}} \geq P_{ij,t,\tau}^{\text{line}} - P_{ij}^{\text{th}} \quad (23)$$

$$P_{ij,t,\tau}^{\text{cong}} \geq -P_{ij,t,\tau}^{\text{line}} - P_{ij}^{\text{th}} \quad (24)$$

$$P_{ij,t,\tau}^{\text{cong}} \geq 0 \quad (25)$$

式中: $P_{ij,t,\tau}^{\text{line}}$ 为线路 (i, j) 的传输功率; P_{ij}^{th} 为线路 (i, j) 传输功率的安全阈值, $P_{ij}^{\text{th}} = \beta \bar{P}_{ij}$, 其中 $\bar{P}_{ij}$ 为链路最大传输能力, β 为链路安全裕度。

2.6.2 约束条件

(1) 数据中心集群运行约束。数据中心集群运行约束见式(1)~式(17)。

(2) 配电网潮流约束。配电网一般为辐射型网络,采用相角松弛的支路潮流模型,仅需考虑电气量的幅值^[22]。

(3) 新能源运行约束。光伏机组的有功出力上限为实时采集出力,无功功率采用基于功率因数角的调节方式^[23]。受最大输出电流的限制,还需考虑视在功率的容量上限约束。基于上述运行特性,光伏机组的出力约束可表示为

$$0 \leq P_{j,t,\tau}^{\text{PV}} \leq \bar{P}_{j,t,\tau}^{\text{PV}} \quad (26)$$

$$\tan \varphi^{\min} P_{j,t,\tau}^{\text{PV}} \leq Q_{j,t,\tau}^{\text{PV}} \leq \tan \varphi^{\max} P_{j,t,\tau}^{\text{PV}} \quad (27)$$

$$(P_{j,t,\tau}^{\text{PV}})^2 + (Q_{j,t,\tau}^{\text{PV}})^2 \leq (S_{j,t,\tau}^{\text{PV}})^2 \quad (28)$$

式中: $P_{j,t,\tau}^{\text{PV}}$ 、 $Q_{j,t,\tau}^{\text{PV}}$ 分别为光伏机组的有功出力和无功出力; $\bar{P}_{j,t,\tau}^{\text{PV}}$ 为光伏机组的实时采集功率; $\varphi^{\max}$ 和 $\varphi^{\min}$ 分别为逆变器功率因数角的上、下限; $S_{j,t,\tau}^{\text{PV}}$ 为光伏机组的视在功率。

上述非线性容量约束可转化为二阶锥约束进行求解,风电机组的运行约束与光伏机组相同。

3 基于深度强化学习算法的长时间尺度阻塞管理模型

3.1 优化调度模型

在长时间尺度上,本文考虑有载调压变压器和并联电容器组的投切,在满足开关动作次数的条件下最小化综合运行成本,目标函数如式(18)所示。

由于设备的机械特性和使用寿命,有载调压变压器和并联电容器组的投切档位频繁变化会导致设备性能劣化,因此需要考虑其开关动作次数约束^[24]。开关全天动作次数限制约束可表示为

$$\sum_t n_{j,t}^{\text{OLTC}} \leq \bar{N}_j^{\text{OLTC}} \quad (29)$$

$$\sum_t n_{j,t}^{\text{SC}} \leq \bar{N}_j^{\text{SC}} \quad (30)$$

$$n_{j,t}^{\text{OLTC}} = \begin{cases} 1, & S_{j,t+1}^{\text{OLTC}} - S_{j,t}^{\text{OLTC}} \neq 0 \\ 0, & S_{j,t+1}^{\text{OLTC}} - S_{j,t}^{\text{OLTC}} = 0 \end{cases} \quad (31)$$

$$n_{j,t}^{\text{SC}} = \begin{cases} 1, & S_{j,t+1}^{\text{SC}} - S_{j,t}^{\text{SC}} \neq 0 \\ 0, & S_{j,t+1}^{\text{SC}} - S_{j,t}^{\text{SC}} = 0 \end{cases} \quad (32)$$

式中: $n_{j,t}^{\text{OLTC}}$ 表示 OLTC 档位是否改变的 0 或 1 变量; $\bar{N}_j^{\text{OLTC}}$ 为 OLTC 的动作次数上限; $n_{j,t}^{\text{SC}}$ 表示 SC 档位是否改变的 0 或 1 变量; $\bar{N}_j^{\text{SC}}$ 为 SC 的动作次数上限; $S_{j,t}^{\text{OLTC}}$ 为 OLTC 的调节档位; $S_{j,t}^{\text{SC}}$ 为 SC 的调节档位。

3.2 离散动作空间深度强化学习算法

基于数据驱动的 DRL 算法通过对外部环境不断地试错探索,并对当前决策的优劣做出判断,进而调整模型参数,以更高的概率输出能带来高回报的可行动作,直至自适应复杂环境^[25]。因此,本文将先进的离散动作空间 Rainbow 算法^[26]用于长时间尺度离散动作设备的调度。

(1)动作空间。在每个时间间隔,智能体需要与环境交互,并根据环境当前所处的状态选择这一时刻的动作。长时间尺度上智能体动作空间表示为 $A_t = \{S_t^{\text{OLTC}}, S_t^{\text{SC}}\}$,其中 S_t^{OLTC} 为有载调压变压器的投切档位集合, S_t^{SC} 为并联电容器组的投切档位集合。

(2)状态空间。智能体通过观测其当前所处环境状态,对设备的投切档位进行决策。观测状态包

括新能源出力、节点的有功和无功功率、数据中心工作负载量、上一时刻设备投切档位以及当前时段,表示为 $O_t = \{P_t^{\text{PV, real}}, P_t^{\text{WT, real}}, P_t^{\text{load}}, Q_t^{\text{load}}, \lambda_t, S_{t-1}^{\text{OLTC}}, S_{t-1}^{\text{SC}}, t\}$,其中 $P_t^{\text{PV, real}}$ 、 $P_t^{\text{WT, real}}$ 分别为光伏和风电的采集功率, P_t^{load} 、 Q_t^{load} 分别为节点的有功和无功负荷, λ_t 为数据中心到达的工作负载量, t 为系统当前运行时段。

(3)奖励函数。为同时反映长期运行目标与短时潮流可行性,长时间尺度阻塞管理的即时奖励将下层短时间尺度模型对候选上层动作返回的可行性指示和短期运行成本作为反馈并纳入奖励计算,从而在离线训练过程中实现上、下层目标与可行性的 consistency。具体地,定义 t 时刻的奖励函数

$$r_t(o_t, a_t) = - \sum_{\tau} (C_{t,\tau}^{\text{loss}} + C_{t,\tau}^{\text{curt}} + C_{t,\tau}^{\text{cong}} + C_{t,\tau}^{\text{compen}}) - \kappa \mathbb{I}\{f_{t,\tau}^{\text{feas}} = 0\} - C^{\text{penalty}}(C_t^{\text{OLTC}} + C_t^{\text{SC}} + \sum_{\tau} C_{t,\tau}^{\text{voltage}}) \quad (33)$$

$$C_t^{\text{OLTC}} = \max(\sum_t n_{j,t}^{\text{OLTC}} - \bar{N}_j^{\text{OLTC}}, 0) \quad (34)$$

$$C_t^{\text{SC}} = \max(\sum_t n_{j,t}^{\text{SC}} - \bar{N}_j^{\text{SC}}, 0) \quad (35)$$

$$C_{t,\tau}^{\text{voltage}} = \sum_j (\max(U_{j,t,\tau} - \bar{U}, 0) + \max(\underline{U} - U_{j,t,\tau}, 0)) \quad (36)$$

式中: o_t 和 a_t 为 t 时段智能体的观测状态和采取的离散动作; $\mathbb{I}\{\cdot\}$ 为指示函数,若下层对给定上层动作判定为不可行,则 $f_{t,\tau}^{\text{feas}} = 0$, 否则 $f_{t,\tau}^{\text{feas}} = 1$; κ 为不可行动作的高额惩罚系数,用以强烈抑制智能体学到不可行动作; C^{penalty} 为惩罚系数; C_t^{OLTC} 为有载调压变压器动作次数越界惩罚; C_t^{SC} 为并联电容器组动作次数越界惩罚; $C_{t,\tau}^{\text{voltage}}$ 为节点电压越限惩罚; $U_{i,t,\tau}$ 为节点 j 在 t 时段 τ 时间间隔的电压; $\bar{U}$ 、 $\underline{U}$ 分别为节点电压的上、下限。上述惩罚项通过 C^{penalty} 系数与主成本项共同构成即时奖励的约束惩罚机制。

4 算例分析

仿真环境基于改进的 IEEE 33 节点系统,结合配电网最优潮流计算模型,并在 Python 仿真平台上实现电压调节和阻塞管理的模拟。其中,光伏机组容量为 1.2 MW,接入节点 11、18、32;风电机组的容量为 0.6 MW,接入节点 9、14、30;逆变器的视在功率为装机容量的 1.05 倍。新能源出力数据采用西安某园区的实际发电数据,数据中心工作负载数据基于谷歌发布的典型负载曲线。OLTC 的变比调节范围为 0.95~1.05,分接头数为 ± 2 ,步进量为 0.025。SC 接

入节点 17 和 33,分为 4 组,每组 0.2 Mvar。OLTC 和 SC 的初始档位为 0,每日最大动作次数为 4。系统基准电压为 12.66 kV,节点电压的安全范围为标么值 $[0.95, 1.05]$,靠近根节点的线路传输容量高于远离根节点的线路,线路安全裕度 $\beta=0.8$ 。

4.1 系统调度结果分析

4.1.1 电气量调度结果分析

图 3 展示了有载调压变压器和并联电容器调整动作的运行结果。由图可见,OLTC 的投切档位和

净负荷具有明显的对应关系:当正午净负荷较低时,各支路的压降减少,OLTC 的开关档位会投切到低值以实现新能源的消纳;而当净负荷较高时,则会投切到最高档位以保证节点电压稳定在安全范围内。SC 的切换档位与支路净负荷有关,在晚间 18:00 新能源出力减少时,系统无功功率不足,此时会通过投切 SC 来满足支路末端节点的电压需求。而在时段 9:00~17:00,由于新能源功率较高,则会优先通过逆变器来为系统提供无功支撑。





图 3 有载调压变压器和并联电容器运行结果

Fig. 3 Operational results of OLTC and SC

4.1.2 负载迁移结果分析

图 4 为数据中心集群交互式工作负载的迁移结果,数据中心 1、2、3 分别位于新能源的匮乏区、密集区和适中区。从图中可以看到,在时段 10:00~18:00 新能源出力高峰期,数据中心 1 会将大部分多余的工作负载优先迁移至新能源资源最丰富的数据中心 2 进行处理,最大限度地实现可再生能源的消纳。受光纤链路最大传输容量的影响,数据中心 1 向数

据中心 2 的负载迁移量被限制为 8 000 Gbit/s,超出部分则继续分流至数据中心 3。当新能源功率降低时,数据中心 2 和 3 由于位于支路末端,会将工作负载迁移至数据中心 1 进行处理,从而降低线路阻塞成本。需要明确的是,负载迁移并不改变需处理的总负载量,因而在数据中心能耗层面,不同调度方案下的数据中心总体计算能耗差异通常较小,不同方案之间能耗的差异主要反映在迁移产生的光网络功耗上。



(a) 数据中心 1





图 4 数据中心工作负载迁移结果

Fig. 4 Data center workload migration results

4.1.3 阻塞管理结果分析

图 5 展示了阻塞管理前、后各线路的测试日最大负载率(以百分比表示)。图中,数字 1~33 表示节点编号,WT1~WT3、PV1~PV3、CDC1~CDC3 分别表示风电、光伏和数据中心的编号,黑色数值表示该线路始终未过载,红色数值表示该线路在阻塞管理前处于过载状态,绿色数值表示该线路的过载问题在阻塞管理后得到消除。由图 5 可见,当不考

虑系统中的灵活性调节资源时,系统存在严重的线路阻塞问题,节点 6 和 26 间的支路最大负载率达到 139.59%。而采用本文所提两阶段阻塞管理方法后,系统阻塞问题得到了有效缓解,该支路的最大负载率降低到了 83.92%。这是由于当该支路负荷过大时,利用数据中心集群的空间迁移能力,可将卸载至该节点数据中心的计算负载迁移至其他数据中心,以降低该节点的负荷功率,缓解系统供电压力。



(a) 阻塞管理前




图 5 阻塞管理前、后的线路最大负载率

Fig. 5 Maximum line load ratio before and after congestion management

图 6 以雷达图的形式展示了测试日系统初始运行状态,以及采用本文所提两阶段阻塞管理方法(下文简称本文方法)得到的归一化节点电压的最大值和最小值。由图可知,由于配电网支路末端无功供应不足,当没有离散无功补偿设备和逆

差。节点 31、32、33 位于支路末端,因此无功补偿能力不足,导致其电压幅值降至 0.9 倍标么值,不在系统的安全运行范围以内。而本文所采用的两阶段阻塞管理方法通过系统地协调不同的有功/无功设备,能够有效应对电压波动,将系统节点电压稳定在安全范围以内。




图 6 阻塞管理前、后的节点电压雷达图

Fig. 6 Nodal voltage radar diagram before and after congestion management

4.2 与传统算法的对比分析

4.2.1 求解有效性对比分析

表 1 列出了多个测试日运行成本的结果对比。基于本文建立的混合整数二阶锥规划(MISOCP)数学优化模型,同时对两阶段涉及到的离散和连续决策变量进行求解,实现了全局统一优化。由于假设未来新能源和负荷输出为给定值,MISOCP 方法所

得到的调度结果被认为是最优的,可作为基准算法评估其他算法的性能表现。

单阶段 MISOCP 为 MISOCP 方法的简化版本,其仅考虑短时间尺度新能源逆变器 and 数据中心负载迁移等连续调节资源。单阶段 MISOCP 方法能够得到近似最优的调度结果,所需计算时间为 79.36 s。然而,由于未将有载调压变压器和并联电

容器组等小时级离散控制纳入联合优化,其在新能源出力不足时难以满足节点电压约束,因此松弛后的节点电压范围为 $[0.93, 1.00]$,存在节点电压越限问题。

本文方法通过引入深度强化学习算法来优化离散控制设备的投切动作,并结合二阶锥规划算法对连续调节资源进行精细优化,采用离线训练和在线应用的实现路径,显著提升了计算效率,在线求解用时仅为 18.73 s。而基于数学优化的 MISOCP 和单阶段 MISOCP 方法则因模型中包含大量二元和整数变量,计算时间较长。此外,本文方法不依赖于精确的预测数据,在离线训练阶段将下层的可行性指示和短期运行成本并入上层的即时奖励,使得上、下

层在目标与可行性层面实现协同,从而在满足系统安全约束的前提下获得接近最优的调度结果,与基准结果仅相差 0.8%,适用于实际电力系统的实时应用场景。

双层 DRL 方法通过在两个时间尺度上使用两个 DRL 智能体进行交互训练和决策,适用于数据规模大、场景复杂的问题,其显著优点是求解速度快。然而,这类方法在训练过程中容易陷入局部最优,尤其是在处理连续型动作时,决策结果与最优值存在显著偏差。相比之下,本文方法在第 2 阶段引入了基于模型驱动和优化方法,能够有效修正智能体的动作策略,从而显著提高决策的准确性。

表 1 不同方法的日运行成本结果对比

Table 1 Comparison of daily operating cost results for different methods

方法	网损成本/元	削减成本/元	阻塞成本/元	补偿成本/元	总成本/元	计算时间/s
本文	288.51	1 736.97	1 807.28	1 237.05	5 069.81	18.730
MISOCP	290.14	1 732.36	1 812.56	1 192.80	5 027.86	243.200
单阶段 MISOCP	309.73	1 738.32	1 886.14	1 214.57	5 148.76	79.360
双层 DRL	318.40	1 732.65	1 927.30	1 277.36	5 255.71	0.734

4.2.2 求解鲁棒性对比分析

在配电网阻塞管理问题中,源荷不确定性直接影响系统的潮流分布,使得基于确定性预测的调度方案在实际运行中出现不可行或高成本情形。为验证所提方法在源荷不确定性下的鲁棒性,设计了 3 种典型的预测偏差场景,分别为 10%、20% 和 30%。表 2 对比了本文方法和传统方法的调度结果与无预测偏差下基准值之间的相对偏差。

表 2 不同预测偏差下 4 种方法结果相对偏差的对比

Table 2 Comparison of results between four methods under different prediction deviations

预测 偏差/%	与无偏差基准值之间的相对偏差/%			
	本文 方法	MISOCP 方法	单阶段 MISOCP 方法	双层 DRL 方法
10	4.58	41.37	40.97	9.33
20	9.70	44.17	44.04	16.48
30	16.67	53.40	53.57	18.23

由表 2 可知,各方法在不同预测偏差下的鲁棒性差异显著。基于确定性数学优化的 MISOCP 及其变体单阶段 MISOCP 方法在存在较大预测误差时性能显著下降,在预测偏差达到 30% 时, MISOCP 方法的调度结果与无偏差基准值之间的相对误差达到 53.40%,表明其对预测不确定性的

敏感性较强。相比之下,基于数据驱动的双层 DRL 方法在不确定环境下具有一定鲁棒性。本文方法表现出更显著优势,其在离线训练阶段采用历史数据并添加随机扰动来构建训练样本,在在线应用阶段将数据驱动的策略学习与模型驱动的精确调整相结合,使得训练后的智能体能够有效应对预测误差,从而在不确定环境下具有更高的鲁棒性。

5 结 论

本文针对高比例新能源接入与数据中心负载分布不均引发的配电网阻塞问题,提出了一种模型-数据混合驱动的两阶段分层阻塞管理方法,通过协调离散控制设备与连续调节资源,实现了系统线路阻塞的高效、经济缓解。通过在改进的 IEEE 33 节点系统进行测试,得到以下主要结论。

(1)所提两阶段阻塞管理方法通过引入数据中心的动态频率调节技术与动态服务器配置技术,充分发挥了其负载迁移的灵活性,能够显著缓解线路过载,提升系统安全运行水平。测试日最大支路负载率从 139.59%降至 83.92%,且节点电压稳定在安全范围内,验证了该方法在阻塞管理方面的有效性。

(2)所构建的混合驱动优化框架在保证经济性的同时大幅提升了求解效率。与传统优化方法相比,所提方法将求解用时缩短至 18.73 s,成本仅增

加0.8%。同时,该方法融合了数据驱动的强化学习算法,有效应对了新能源与工作负载的不确定性,增强了系统运行的鲁棒性。

参考文献:

- [1] 李鹏,钟瀚明,马红伟,等. 基于深度强化学习的有源配电网多时间尺度源荷储协同优化调控[J]. 电工技术学报, 2025, 40(5): 1487-1502.
LI Peng, ZHONG Hanming, MA Hongwei, et al. Multi-timescale optimal dispatch of source-load-storage coordination in active distribution network based on deep reinforcement learning [J]. Transactions of China Electrotechnical Society, 2025, 40(5): 1487-1502.
- [2] LIANG Yaran, LI Peng, SU Wen, et al. Development of green data center by configuring photovoltaic power generation and compressed air energy storage systems [J]. Energy, 2024, 292: 130516.
- [3] DING Zhaohao, XIE Liye, LU Ying, et al. Emission-aware stochastic resource planning scheme for data center microgrid considering batch workload scheduling and risk management [J]. IEEE Transactions on Industry Applications, 2018, 54(6): 5599-5608.
- [4] LU Yu, XIANG Yue, HUANG Yuan, et al. Deep reinforcement learning based optimal scheduling of active distribution system considering distributed generation, energy storage and flexible load [J]. Energy, 2023, 271: 127087.
- [5] 丛鹏伟,胡泽春. 基于 SOP 和 VSC 的交直流混合配电网两阶段阻塞管理[J]. 供用电, 2020, 37(10): 22-28.
CONG Pengwei, HU Zechun. Two-stage congestion management in AC/DC hybrid distribution network based on SOP and VSC [J]. Distribution & Utilization, 2020, 37(10): 22-28.
- [6] 李鹏,张培深,王成山,等. 基于智能软开关与市场机制的有源配电网阻塞管理方法[J]. 电力系统自动化, 2017, 41(20): 9-16.
LI Peng, ZHANG Peishen, WANG Chengshan, et al. Congestion management method for active distribution networks based on soft open point and market mechanism [J]. Automation of Electric Power Systems, 2017, 41(20): 9-16.
- [7] 王育飞,李可铭,陈强,等. 基于市场机制与移动式储能的有源配电网阻塞管理方法[J]. 现代电力, 2024, 41(6): 1138-1147.
WANG Yufei, LI Keming, CHEN Qiang, et al. Congestion management method for active distribution network based on market mechanism and mobile energy storage system [J]. Modern Electric Power, 2024, 41(6): 1138-1147.
- [8] XU Da, XIANG Shizhe, BAI Ziyi, et al. Optimal multi-energy portfolio towards zero carbon data center buildings in the presence of proactive demand response programs [J]. Applied Energy, 2023, 350: 121806.
- [9] 周世博,周明,孙黎滢,等. 激发多元灵活性的数据中心协同优化运行方法[J]. 电网技术, 2024, 48(11): 4417-4426.
ZHOU Shibo, ZHOU Ming, SUN Liying, et al. Optimal synergistic operation method for data center by activating multiple flexibilities [J]. Power System Technology, 2024, 48(11): 4417-4426.
- [10] 张镭,王旭,杨宏坤,等. 数据中心集群灵活边界下电力系统分布鲁棒优化调度方法[J]. 电力系统自动化, 2024, 48(7): 235-247.
ZHANG Ke, WANG Xu, YANG Hongkun, et al. Distributionally robust optimal scheduling method for power system under flexibility boundaries of data center clusters [J]. Automation of Electric Power Systems, 2024, 48(7): 235-247.
- [11] 董雷,杨子民,乔骥,等. 基于分层约束强化学习的综合能源多微网系统优化调度[J]. 电工技术学报, 2024, 39(5): 1436-1453.
DONG Lei, YANG Zimin, QIAO Ji, et al. Optimal scheduling of integrated energy multi-microgrid system based on hierarchical constraint reinforcement learning [J]. Transactions of China Electrotechnical Society, 2024, 39(5): 1436-1453.
- [12] YANG Hongrong, XU Yinliang, GUO Qinglai. Dynamic incentive pricing on charging stations for real-time congestion management in distribution network: an adaptive model-based safe deep reinforcement learning method [J]. IEEE Transactions on Sustainable Energy, 2024, 15(2): 1100-1113.
- [13] KHAN O G M, YOUSSEF A, SALAMA M, et al. Management of congestion in distribution networks utilizing demand side management and reinforcement learning [J]. IEEE Systems Journal, 2023, 17(3): 4452-4463.
- [14] 张剑,崔明建,姚潇毅,等. 基于数据驱动与物理模型的主动配电网双时间尺度协调优化[J]. 电力系统自动化, 2023, 47(20): 64-71.
ZHANG Jian, CUI Mingjian, YAO Xiaoyi, et al. Dual-timescale active and reactive power coordinated optimization for active distribution network based on data-driven and physical model [J]. Automation of Electric Power Systems, 2023, 47(20): 64-71.
- [15] 王志杨,张靖,何宇,等. 数据与模型混合驱动的区域

- 域综合能源系统双层优化调度决策方法[J]. 电网技术, 2022, 46(10): 3797-3809.
- WANG Zhiyang, ZHANG Jing, HE Yu, et al. Hybrid data-driven and model-driven bi-level optimal scheduling decision for regional integrated energy systems [J]. Power System Technology, 2022, 46(10): 3797-3809.
- [16] 张玉莹, 曾博, 周吟雨, 等. 碳减排驱动下的数据中心与配电网交互式集成规划研究[J]. 电工技术学报, 2023, 38(23): 6433-6450.
- ZHANG Yuying, ZENG Bo, ZHOU Yinyu, et al. Research on interactive integration planning of data centers and distribution network driven by carbon emission reduction [J]. Transactions of China Electrotechnical Society, 2023, 38(23): 6433-6450.
- [17] JIN Chaoqiang, BAI Xuelian, YANG Chao, et al. A review of power consumption models of servers in data centers [J]. Applied Energy, 2020, 265: 114806.
- [18] CHO J, PARK B, JANG S. Development of an independent modular air containment system for high-density data centers: experimental investigation of row-based cooling performance and PUE [J]. Energy, 2022, 258: 124787.
- [19] 王天琪, 于浩, 赵金利, 等. 算力-热力灵活性协同的数据中心能量管理方法[J]. 高电压技术, 2024, 50(9): 4069-4079.
- WANG Tianqi, YU Hao, ZHAO Jinli, et al. Optimal energy management of data centers considering the synergy of computing power and thermal power flexibility [J]. High Voltage Engineering, 2024, 50(9): 4069-4079.
- [20] LIU Yang, LEI Shunbo, HOU Yunhe. Restoration of power distribution systems with multiple data centers as critical loads [J]. IEEE Transactions on Smart Grid, 2019, 10(5): 5294-5307.
- [21] SUN Gang, ANAND V, LIAO Dan, et al. Power-efficient provisioning for online virtual network requests in cloud-based data centers [J]. IEEE Systems Journal, 2015, 9(2): 427-441.
- [22] 张剑, 崔明建, 何怡刚. 结合数据驱动与物理模型的主动配电网双时间尺度电压协调优化控制[J]. 电工技术学报, 2024, 39(5): 1327-1339.
- ZHANG Jian, CUI Mingjian, HE Yigang. Dual time-scales coordinated and optimal voltages control in distribution systems using data-driven and physical optimization [J]. Transactions of China Electrotechnical Society, 2024, 39(5): 1327-1339.
- [23] XU Xiaoyuan, LI Yunhong, YAN Zheng, et al. Hierarchical central-local inverter-based voltage control in distribution networks considering stochastic PV power admissible range [J]. IEEE Transactions on Smart Grid, 2023, 14(3): 1868-1879.
- [24] 李鹏, 姜磊, 王加浩, 等. 基于深度强化学习的新能源配电网双时间尺度无功电压优化[J]. 中国电机工程学报, 2023, 43(16): 6255-6265.
- LI Peng, JIANG Lei, WANG Jiahao, et al. Optimization of dual-time scale reactive voltage for distribution network with renewable energy based on deep reinforcement learning [J]. Proceedings of the CSEE, 2023, 43(16): 6255-6265.
- [25] 马庆, 邓长虹. 基于单/多智能体简化强化学习的电力系统无功电压控制[J]. 电工技术学报, 2024, 39(5): 1300-1312.
- MA Qing, DENG Changhong. Single/multi agent simplified deep reinforcement learning based volt-var control of power system [J]. Transactions of China Electrotechnical Society, 2024, 39(5): 1300-1312.
- [26] HAN G, JOO H J, LIM H W, et al. Data-driven heat pump operation strategy using rainbow deep reinforcement learning for significant reduction of electricity cost [J]. Energy, 2023, 270: 126913.

(编辑 李慧敏)