



基于深度强化学习的微电网低碳优化运行方法

林文硕 李欣 周荣生 朱怡莹 彭依明

A Low-carbon Optimal Operation Method for Microgrids Based on Deep Reinforcement Learning

LIN Wenshuo, LI Xin, ZHOU Rongsheng, ZHU Yiying, PENG Yiming

引用本文:

林文硕, 李欣, 周荣生, 等. 基于深度强化学习的微电网低碳优化运行方法[J]. 现代电力, 2025, 42(6): 1131-1142. DOI: 10.19725/j.cnki.1007-2322.2023.0327

LIN Wenshuo, LI Xin, ZHOU Rongsheng, et al. A Low-carbon Optimal Operation Method for Microgrids Based on Deep Reinforcement Learning[J]. Modern Electric Power, 2025, 42(6): 1131-1142. DOI: 10.19725/j.cnki.1007-2322.2023.0327

在线阅读 View online: <https://doi.org/10.19725/j.cnki.1007-2322.2023.0327>

您可能感兴趣的其他文章

Articles you may be interested in

基于人工辅助深度强化学习的交直流混合微电网实时优化调度

Real-Time Optimal Scheduling of AC / DC Hybrid Microgrid Based on Artificial Auxiliary Deep Reinforcement Learning
现代电力. 2023, 40(4): 577-586 <https://doi.org/10.19725/j.cnki.1007-2322.2022.0032>

基于多智能体强化学习的多风氢系统联合优化运行

Joint Optimal Operation of Multi Wind-Hydrogen System Based on Multi-Agent Reinforcement Learning
现代电力. 2022, 39(4): 431-440 <https://doi.org/10.19725/j.cnki.1007-2322.2021.0197>

电力市场环境下的微电网双层经济运营优化模型

Optimization Model of Bi-level Economic Operation of Microgrid in Electricity Market Environment
现代电力. 2020, 37(4): 433-440 <https://doi.org/10.19725/j.cnki.1007-2322.2020.0102>

低碳形势下基于区块链技术的含微电网电力市场交易出清模型

Transaction Clearing Model in Electricity Market with Microgrids Based on Blockchain Technology Under Low-carbon Situation
现代电力. 2019, 36(1): 14-21 <http://xddl.ncepujournal.com/article/Y2019/I1/14>

多能源形式下商业区微网的方案设计与调度优化

Scheme Design and Dispatch Optimization of Microgrid in Business Area under Multi-Energy Sources
现代电力. 2021, 38(4): 402-411 <https://doi.org/10.19725/j.cnki.1007-2322.2020.0391>

考虑不确定价格型需求响应的多源微网运行优化

Multi-source Micro-grid Operation Optimization Considering Uncertain Electricity Price Demand Response
现代电力. 2020, 37(4): 425-432 <https://doi.org/10.19725/j.cnki.1007-2322.2019.0412>

基于深度强化学习的微电网低碳优化运行方法

林文硕, 李欣, 周荣生, 朱怡莹, 彭依明

(广东电网有限责任公司广州供电局, 广东省广州市 510620)

A Low-carbon Optimal Operation Method for Microgrids Based on Deep Reinforcement Learning

LIN Wenshuo, LI Xin, ZHOU Rongsheng, ZHU Yiyi, PENG Yiming

(Guangzhou Power Supply Bureau of Guangdong Power Grid, Guangzhou 510620, Guangdong Province, China)

摘要: 在建设新型电力系统的远景目标下, 为实现配电侧绿色低碳运行, 提出了一种基于深度强化学习的计及电转气和碳捕集的微电网低碳优化运行方法。首先, 考虑新能源发电设备、储能设备、电转气系统及碳捕集设备, 在发电侧碳捕集-电转气-燃气轮机同新能源共同形成了多类型供能的微电网系统。其次, 为实现所提微电网系统在源荷不确定性环境下的优化运行, 基于深度强化学习理论, 将多时段优化问题转化为马尔科夫决策问题, 并提出了一种融合知识的深度强化学习求解框架。在此基础上采用分布式近端策略优化算法实现了微电网系统多类电源的低碳优化运行。仿真结果证明了所提深度强化学习框架及算法的有效性和其制定的运行方案的经济性。

关键词: 电转气; 微电网; 深度强化学习; 近端策略优化; 优化运行

Abstract: In this paper we present a low-carbon optimization strategy for microgrids with the long-term goal of developing a new type of power system. This method, rooted in deep reinforcement learning, integrates the concepts of electricity-to-gas conversion and carbon capture to attain environmentally conscious operations. Primarily, by conducting an assessment of renewable energy generation and storage apparatus, as well as incorporating electricity-to-gas conversion and carbon capture systems, the integration of a carbon-capturing electricity-to-gas turbine within the power generation framework establishes a diverse and multi-source energy microgrid system. Subsequently, to achieve optimal operation of the proposed microgrid system in an environment of source-load uncertainty, the multi-period optimization problem is transformed into a Markov decision problem based on deep

基金项目: 中国南方电网有限责任公司科技项目 (080016KK52180005)。

Project Supported by China Southern Power Grid Science and Technology Project (080016KK52180005)。

reinforcement learning theory. Additionally, a knowledge fusion deep reinforcement learning framework is proposed. The utilization of the distributed proximal policy optimization algorithm facilitates the realization of optimal performance across diverse power sources within the microgrid system. The empirical findings from the simulations provide substantial evidence for both the efficacy of the envisaged deep reinforcement learning framework and algorithm, as well as the economic feasibility of the proposed operational strategy.

Keywords: power-to-gas; microgrid; deep reinforcement learning; proximal policy optimization; optimal operation

DOI: 10.19725/j.cnki.1007-2322.2023.0327

0 引言

建设新型电力系统, 圆满完成“双碳”目标是电力行业的一项重大且艰巨的任务。支持和发展新能源、碳捕集技术是实现碳中和目标的一项关键手段^[1]。在当前阶段, 分布式新能源的建设已如火如荼地展开, 可以预见的是, 分布式新能源将在新型电力系统中占据重要地位^[2]。在未来分布式新能源广泛接入的配电侧, 引入碳捕集技术, 更有益于实现新能源和碳捕集的协调优化运行, 获得经济和环保效益, 助力“双碳”目标的实现。

碳捕集技术主要目的是捕集 CO₂, 并经过封存达到减排 CO₂ 的目的^[3]。而电转气 (power-to-gas, P2G) 技术通过将不可控的风光新能源电制氢后, 氢气同 CO₂ 反应可转换成天然气, 实现了清洁能源的完全消纳^[4]。电转气和碳捕集技术相结合可为新能源转换、储存以及碳中和发展提供了新的途径。文献^[5-6]提出了电转气-碳捕集电

厂系统框架,该框架下碳捕集的CO₂作为P2G装置的电转气原料来源。文献[7]研究了电转气-碳捕集架构下的多能流间逻辑关系,分析了两者在节能降排方面的作用。文献[8]提出了电转气协同的含碳捕集与垃圾焚烧虚拟电厂架构的优化调度方法,证明了所提架构具备削峰填谷效用并促进新能源消纳。考虑到源荷的不确定性影响,文献[9]采用随机优化理论,文献[10]基于机会约束方法,文献[11]采用蒙特卡洛模拟的随机规划法以及文献[12]基于鲁棒优化思想,分别对综合能源系统不确定性优化问题进行了研究。随机优化和鲁棒优化理论应对不确定性时,需对源荷不确定性进行准确建模,增加了优化调度的复杂性。

随着人工智能技术的发展,以“数据驱动”为特征的深度学习、深度强化学习(deep reinforcement learning, DRL)方法已同最优化方法相结合,应用于电力系统的优化调度中,并在不确定性环境下保持了优异的调度性能[13-14]。文献[15]提出了基于交互环境的(deep Q-network, DQN)算法,学习微电网组件运行的最佳调度策略。文献[16]设计了一个完整的深度强化学习框架,并采用(dueling deep Q-network, DDQN)算法对动态多微电网问题进行实时计算,提高了系统的经济性和安全性。此外,深度强化学习方法在微电网储能设备调度[17]、家庭能量管理[18]、微电网点对点交易[19]等领域已进行了应用研究,但上述研究的不足是一方面未验证DRL方法对复杂的综合供能微电网的适应性,另一方面完全采用“数据驱动”寻优方式,忽略了模型优化的结论,造成算法训练效率低,寻优性能下降。

综上所述,本文面向考虑电转气和碳捕集的综合供能微电网,提出一种源荷不确定性条件下的微电网深度强化学习优化调度模型。首先,在微电网内建立了含风、光、小型燃气轮机、储能电池、碳捕集和P2G的综合供能架构及模型。其次,本文的创新之处是基于深度强化学习理论,提出一种融合知识的深度强化学习求解框架,提出并行智能体-分布式近端策略优化算法(parallel agent-distributed proximal policy optimization, PADPPO)学习不同电源在能量/功率上的互补性,实现微电网系统内多类电源的低碳协调优化运行。最后,采用仿真算例验证所提模型及深度强化学习方法的有效性。

1 计及电转气和碳捕集的微电网模型

1.1 微电网综合供能架构

典型微电网通常由新能源、负荷、燃气轮机、储能设备构成,是一种具备源-荷-储特性的小型电力系统。本文进一步将碳捕集设备、P2G设备和燃气机组聚合为碳捕集-电转气-燃气机组系统,形成多能互补的综合供能低碳微电网,其架构如图1所示。

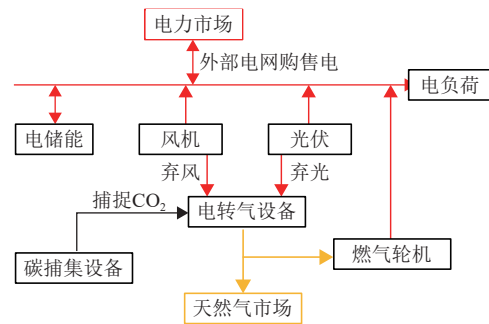


图1 综合供能微电网架构

Fig. 1 Architecture of integrated energy supply and microgrid

与传统微电网相比,本架构特点有:1)综合能源市场方面:捕集的CO₂作为原料,电转气接收CO₂和弃风弃光的能量生成天然气,一方面提供给燃气机组,另一方面参与天然气市场交易。碳捕集-电转气-燃气系统不仅减少捕集CO₂后的封存成本,甚至可以消耗CO₂,一定程度上实现碳中和;而且可将弃风弃光转化成天然气储存于天然气网络,减少燃气轮机机组的购气成本,成功将电力市场同天然气市场耦合,形成多能互补的综合能源市场,甚至在未来可同碳交易市场耦合。2)电力市场方面:电力市场中通常将储能作为调节单元,具有削峰填谷效应,碳捕集-电转气-燃气系统也同样具有削峰填谷效应,二者相互配合增强了电力调节潜力,更有助于实现负荷的时空转移。

1.2 设备数学模型

1.2.1 碳捕集-电转气系统模型

图2为本文研究的碳捕集-电转气系统结构图,在电能充沛时,在电解槽中电解水制取氢气,并且暂时储存在储氢罐中,然后结合捕捉的CO₂实现甲烷(CH₄)燃料的制备。

对于碳捕集系统,主要功能是捕集CO₂,并将作CO₂为制备甲烷的燃料。其捕集的CO₂量和




图 2 电转气系统架构

Fig. 2 Architecture of electricity-to-gas system

设备运行功率 P_{CCS} 关系可表示为

$$P_{CO_2} = \beta E_{CO_2} \quad (1)$$

$$P_{CCS} = P_{CO_2} + P_{CO_2}^0 \quad (2)$$

式中： β 为 CO_2 的捕集效率； E_{CO_2} 为捕集的 CO_2 量； P_{CO_2} 为碳捕集设备的运行能耗； $P_{CO_2}^0$ 为碳捕集的固定能耗。

电解槽能够将水电解为氢气和氧气，其输出功率可表示为

$$P_{EB} = P_{EB,in} \eta_{EB} \quad (3)$$

式中： $P_{EB,in}$ 为电解槽的输入功率； η_{EB} 为电解槽的效率。

考虑到氢气的配置比例、合成气的组成成分、化学反应的压力值和温度值等因素在氢气甲烷化过程中会影响化学反应的效率^[20]，因此，采用式 (4) 表示甲烷反应器生成的天然气体积：

$$V_{CH_4} = \frac{3.6 P_{CH_4} \eta_{ch_4}}{H_i} \quad (4)$$

式中： P_{CH_4} 为甲烷反应器的甲烷有功功率值； H_i 为甲烷低热值，为 39 MJ/m^3 ；3.6 为氢气合成天然气时摩尔质量折算系数； η_{ch_4} 为甲烷反应器的转换效率。

甲烷反应器的碳利用量 E_{CO_2} 可建模为

$$E_{CO_2} = \alpha_{CO_2} P_{CH_4} \quad (5)$$

式中 α_{CO_2} 为生成单位功率天然气时需要的 CO_2 量， $t(\text{MWh})$ 。

碳捕集-电转气系统应满足的运行约束有：

$$0 \leq P_{EB,in} \leq P_{EB,in,max} \quad (6)$$

$$0 \leq P_{CH_4} \leq P_{CH_4,max} \quad (7)$$

式中 $P_{EB,in,max}$ 和 $P_{CH_4,max}$ 分别为电解槽和甲烷反应器的最大功率。

1.2.2 燃气轮机系统模型

小型燃气机组的润滑油和气缸冷却释放的烟

气温度较低（通常不超过 $90 \text{ }^\circ\text{C}$ ），造成余热回收过程复杂且热能品质低，因此暂不考虑设置余热回收装置。同时对于小型燃气机组来说其发电效率随负载率的变化范围很小，因此可近似认为发电效率为定值，燃气机组发电功率 P_{MT} 与消耗燃气量 $V_{CH_4,mt}$ 的关系可建模为

$$P_{MT} = \eta_{mt} H_i V_{CH_4,mt} \quad (8)$$

式中 η_{mt} 是燃气轮机的发电效率。

燃气轮机运行时，应满足的运行约束有：

$$P_{MT,min} \leq P_{MT,t} \leq P_{MT,max} \quad (9)$$

$$-P_{MT,down} \leq P_{MT,t} - P_{MT,t-1} \leq P_{MT,up} \quad (10)$$

式中： $P_{MT,min}$ 和 $P_{MT,max}$ 为燃气轮机单时段最小和最大出力； $P_{MT,down}$ 和 $P_{MT,up}$ 为下、上机爬坡约束。

1.2.3 储能系统模型

储能系统通过充放电过程实现能量存储，其 $t+1$ 时段的储电量 $S_{soc,t+1}$ 可建模为

$$S_{soc,t+1} = S_{soc,t} + \frac{1}{E_{ES}} (-\eta_{ch} P_{ch,t} - P_{dis,t} / \eta_{dis}) \quad (11)$$

式中： E_{ES} 为储能系统容量； $P_{ch,t}$ 和 $P_{dis,t}$ 为储能充电和放电功率，充电为负，放电为正； η_{ch} 和 η_{dis} 为储能充电和放电效率。

此外储能系统的运行，还需满足以下约束：

$$-P_{ch,max} \leq P_{ch,t} \leq 0 \quad (12)$$

$$0 \leq P_{dis,t} \leq P_{dis,max} \quad (13)$$

$$S_{min} \leq S_{soc,t} \leq S_{max} \quad (14)$$

$$S_{soc,1} = S_{soc,24} \quad (15)$$

式中： $P_{ch,max}$ 是最大充电功率； $P_{dis,max}$ 是最大放电功率； S_{min} 和 S_{max} 是储能储电量的最小值和最大值。

1.3 微电网低碳运行优化模型

1.3.1 目标函数

微电网低碳运行优化模型以微电网总经济成本最小化为目标。其目标函数包含微电网购电成本 $C_{grid,t}$ 、燃气轮机机组运行成本 $C_{g,t}$ 、电转气系统损耗成本 $C_{p2g,t}$ 以及微电网同天然气市场的购售气成本 $C_{gas,t}$ 。

微电网购售电成本可建模为

$$C_{grid,t} = \lambda_{buy,t} P_{buy,t} - \lambda_{sell,t} P_{sell,t} \quad (16)$$

式中： $\lambda_{buy,t}$ 和 $\lambda_{sell,t}$ 为购售电价； $P_{buy,t}$ 和 $P_{sell,t}$ 为微电网同外部电网的购电量和售电量。

燃气轮机机组运行成本可建模为

$$C_g = \lambda_{CH_4} V_{CH_4,mt} \quad (17)$$

式中 λ_{CH_4} 为天然气市场价格。

电转气系统损耗成本可建模为

$$C_{p2g,t} = \lambda_{sell,t} [(1 - \eta_{EB}) P_{EB,in,t} + \frac{1 - \eta_{ch_4}}{\eta_{ch_4}} P_{CH_4,t}] \quad (18)$$

微电网同天然气市场的购售气成本可建模为

$$C_{gas,t} = -\lambda_{CH_4} V_{CH_4,market} \quad (19)$$

式中 $V_{CH_4,market}$ 为微电网同天然气市场的交易量，大于 0 表示微电网向天然气市场售气。

综上，目标函数可建模为

$$\min F_{MG} = \sum_{t=1}^T C_{grid,t} + C_{gas,t} + C_{g,t} + C_{p2g,t} \quad (20)$$

1.3.2 系统运行约束条件

除上述各设备的运行约束外，微电网运行过程中，系统层面应满足电功率、气功率平衡约束和购售电量约束。电功率平衡可建模为

$$P_{buy,t} + P_{pv,t} + P_{wt,t} + P_{MT,t} + P_{dis,t} + P_{ch,t} = P_{L,t} + P_{sell,t} + P_{pv,q,t} + P_{wt,q,t} \quad (21)$$

式中： $P_{pv,t}$ 和 $P_{wt,t}$ 为光伏和风机直接消纳量； $P_{pv,q,t}$ 和 $P_{wt,q,t}$ 为光伏和风机的转换量； $P_{L,t}$ 为微电网的实际负荷功率。

气功率平衡表征了电转气系统的生成量等于燃气轮机的消耗量同售气量之和，可建模为：

$$V_{CH_4} = V_{CH_4,mt} + V_{CH_4,market} \quad (22)$$

购售电量约束是考虑到微电网通过公共连接点接入大电网中，其交互电量不仅受到设备容量约束，也受到上级调度机构的约束，因此，购售电量不可能无限大，此功率约束可建模为：

$$0 \leq P_{buy,t} \leq \min(P_{pcc,t}^{\max}, P_{allow,t}) \quad (23)$$

$$0 \leq P_{sell,t} \leq \min(P_{pcc,t}^{\max}, P_{allow,t}) \quad (24)$$

式中： $P_{pcc,t}^{\max}$ 为并网点设备的最大容量； $P_{allow,t}$ 为上级调度机构允许的最大交互功率。

上述目标函数和约束条件共同构成了微电网优化运行的数学模型。

2 融合知识的深度强化学习优化方法

2.1 基于深度强化学习的微电网调度模型

深度强化学习是一种以“数据驱动”为特征

的人工智能方法，它融合了深度学习的感知能力和强化学习的决策能力，可应用于电网的调度过程，实现调度策略的探索和自更新。在本节中，通过将微电网优化调度问题转化为马尔科夫过程，即可采用深度强化学习算法获得调度策略。

马尔科夫过程定义为元组 $(S, A, P, r, \gamma, \pi)$ ，其中： S 为环境状态空间集合； A 为智能体动作空间集合； P 为环境中的状态转移概率； r 为智能体在环境状态下选择动作后的即时奖励； γ 为奖励的折扣因子，表征智能体的远视能力； π 为策略，即深度强化学习算法最终求解获得的调度策略。

调度问题转化为马尔科夫过程就是将 2.3 节模型同元组 $(S, A, P, r, \gamma, \pi)$ 中的各个属性对应转换的过程。此外，定义强化学习理论中的基本概念。

一般而言，给定一个策略时，其累积回报定义为 G_t ：

$$G_t = r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots \quad (25)$$

智能体策略具有随机性，累积回报 G_t 同样具有随机性，选择取其期望，定义为状态值函数 $V_{\pi}(s)$ ：

$$V_{\pi}(s) = \mathbb{E}_{\pi} \left[\sum_{k=0}^{\infty} \gamma^k r_{t+1+k} | s_t = s \right] \quad (26)$$

式中 \mathbb{E}_{π} 是求取策略 π 的期望。

同理，定义状态-行为值函数 $Q_{\pi}(s, a)$ ：

$$Q_{\pi}(s, a) = \mathbb{E}_{\pi} \left[\sum_{k=0}^{\infty} \gamma^k r_{t+1+k} | s_t = s, a_t = a \right] \quad (27)$$

2.1.1 状态输入空间

对于微电网调度者，状态输入空间包括天然气市场价格、电力市场价格、风机、光伏的预测出力、负荷功率和储能电池容量，如式 (29) 所示：

$$S_{agnet} = \{ \lambda_{CH_4}, \lambda_{buy,t}, \lambda_{sell,t}, P_{wt,t}^p, P_{pv,t}^p, P_{L,t}, S_{soc,t} \} \quad (28)$$

式中 $P_{wt,t}^p$ 和 $P_{pv,t}^p$ 为风机和光伏的预测量，预测量同实际消纳量及丢弃功率满足下式：

$$P_{wt,t}^p = P_{wt,t} + P_{wt,q,t} \quad (29)$$

$$P_{pv,t}^p = P_{pv,t} + P_{pv,q,t} \quad (30)$$

2.1.2 动作输入空间

对于微电网调度者，动作是微电网可以控制的各个设备出力，在式 (22) 的功率平衡约束下，选择的动作空间中包含燃气轮机动作 $a_{MT,t}$ 、储能动作 $a_{es,t}$ 、光伏动作 $a_{pv,t}$ 和风机动作 $a_{wt,t}$ ，如式 (32)

所示：

$$A_{\text{agnet}} = \{a_{\text{MT},t}, a_{\text{es},t}, a_{\text{pv},t}, a_{\text{wt},t}\} \quad (31)$$

其中，各个动作满足如下约束：

$$a_{\text{MT},t} = P_{\text{MT},t} \quad (32)$$

$$a_{\text{es},t} = P_{\text{ch},t} + P_{\text{dis},t} \quad (33)$$

$$a_{\text{pv},t} = P_{\text{pv},t} / P_{\text{pv},t}^{\text{p}} \quad (34)$$

$$a_{\text{wt},t} = P_{\text{wt},t} / P_{\text{wt},t}^{\text{p}} \quad (35)$$

2.1.3 奖励函数设计

奖励函数是引导 DRL 智能体探索策略、寻找策略的关键，随着训练的进行，DRL 智能体会逐步收敛到使奖励最大的策略。因此，把微电网目标函数的相反数作为智能体的奖励，如式 (37) 所示：

$$r = - \sum_{t=1}^T \alpha_1 C_{\text{grid},t} + \alpha_2 C_{\text{gas},t} + \alpha_3 C_{\text{g},t} + \alpha_4 C_{\text{p2g},t} \quad (36)$$

其中 α_1 、 α_2 、 α_3 、 α_4 系数是为了在训练过程中调节奖励，对各项奖励进行缩放。

2.2 分布式近端策略优化算法

近端策略优化 (proximal policy optimization, PPO) 是基于策略的强化学习算法。基于策略的算法特点是通过一组神经网络参数对策略参数化，并计算策略梯度 $\nabla_{\theta} J(\theta)$ ，利用随机梯度上升算法对梯度优化，从而直接学习到能使奖励最大化的策略本身。

根据推导，策略梯度近似表达式为：

$$\nabla_{\theta} J(\theta) = \frac{1}{n} \sum_{i=1}^n \nabla_{\theta} \log \pi_{\theta}(a_t | s_t) \hat{R}_{\theta}(s_t, a_t) \quad (37)$$

式中： π_{θ} 为关于参数 θ 的策略函数； $\nabla_{\theta} \log \pi_{\theta}(a_t | s_t)$ 为对策略 $\pi_{\theta}(a_t | s_t)$ 取对数后的求导结果； $\hat{R}_{\theta}(s_t, a_t)$ 为在 t 时刻状态 s_t 下的优势函数估计值。

此时，式 (38) 是完全可计算的，根据策略梯度更新规则式 (39) 对参数 θ 进行调整优化，从而不断迭代至最优策略。

$$\theta \leftarrow \theta + \alpha \nabla_{\theta} J(\theta) \quad (38)$$

上述公式是传统的策略梯度算法更新公式。PPO 的特点是基于重要性采样理论对策略梯度进行修正，从而提高交互经验的利用率。修正后的目标函数的梯度表达式为：

$$\nabla_{\theta} J'(\theta) = \frac{1}{n} \sum_{i=1}^n \left[\frac{\pi_{\theta}(a_t | s_t)}{\pi_{\theta'}(a_t | s_t)} \nabla_{\theta} \log \pi_{\theta}(a_t | s_t) \hat{R}'_{\theta}(s_t, a_t) \right] \quad (39)$$

式 (40) 可以理解为：PPO 算法是“在线”更新，即收集经验和策略更新同步进行。策略 π_{θ} 智能体与环境交互获得的经验可用于新策略 $\pi_{\theta'}$ 的更新，一次探索收集的样本能够多次更新目标策略，相较于传统策略梯度算法，提高了采样效率。

但是式 (40) 成立的前提条件是：满足策略 π_{θ} 和新策略 $\pi_{\theta'}$ 的分布相近，二者的期望才能近似相等。PPO 算法为约束旧策略和新策略分布接近，进一步对目标函数进行修正，截断目标函数表达式为：

$$J(\theta) = \mathbb{E} \left[\frac{\pi_{\theta}(a_t | s_t)}{\pi_{\theta'}(a_t | s_t)} R_{\theta'}(s_t, a_t), \right. \\ \left. \text{clip} \left(\frac{\pi_{\theta}(a_t | s_t)}{\pi_{\theta'}(a_t | s_t)}, 1 - \varepsilon, 1 + \varepsilon \right) R_{\theta'}(s_t, a_t) \right] \quad (40)$$

式中： \mathbb{E} 表示求取期望； ε 是一个较小的超参数。

PPO 算法相较于传统的策略梯度算法提高了采样效率，为了进一步提高采样效率，合理利用计算机资源，加快 DRL 智能体的训练过程，提出了分布式近端策略优化 (distributed proximal policy optimization, DPPO) 算法。

DPPO 利用计算机的多线程特点进行并行分布式学习，子进程接收主进程中的策略参数进行动作探索，获得经验样本，主进程收集子进程的经验样本进行策略的参数更新。这样一台计算机可以在同一时间对不同的动作进行探索，使得相同时间内 PPO 具有了更大的探索能力。DPPO 算法的框架如图 3 所示。

2.3 融合知识驱动的微电网智能体训练

2.1 节和 2.2 节共同构成了传统的以数据驱动为特征的深度强化学习应用框架及算法，但是，“数据驱动”的 DRL 算法在海量数据中随机探索学习，忽略了长久以来积累的电力系统知识，并非明智的选择。本节提出了先聚类-后训练的思想，实现知识驱动和数据驱动的有效融合。

2.3.1 基于 K-means 聚类算法的训练数据聚类

K-means 算法是一种常用的聚类算法，用于将数据集的样本划分为预先指定数量的簇。K-means 的目的是使每个样本与所属簇的中心之间的距离最小化，从而实现了簇内样本的相似性最大化。其主要步骤是：

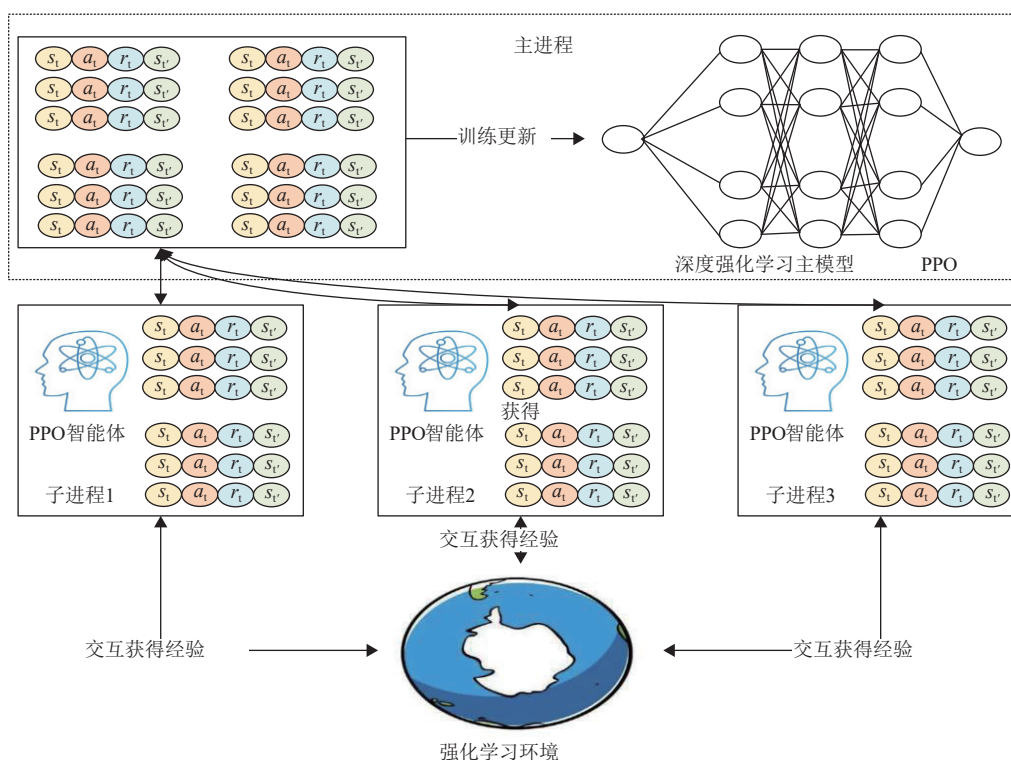


图3 分布式近端策略优化算法架构

Fig. 3 Architecture of the distributed proximal strategy optimization algorithm

1) 选择簇的数量 K : 确定数据划分为多少个簇。可根据面对问题的背景经验来决定。

2) 初始化质心: 随机选择 K 个样本作为初始质心, 每个样本代表一个簇的中心。

3) 分配样本到簇: 对于每个样本, 计算该样本与每个质心之间的距离, 然后将该样本分配给距离最近的质心所代表的簇。选择欧式距离衡量距离大小, 其公式为

$$L(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (41)$$

式中 x 和 y 代表两个点的位置坐标。

4) 更新质心: 计算簇内所有样本的平均值, 把平均值作为新的质心。

5) 重复步骤 3) 和 4): 直至相邻两次质心差值小于收敛阈值, 此时判断算法收敛, 得到每个样本所属的簇。

2.3.2 融合知识驱动的训练方式设计

深度强化学习的传统训练方式属于数据驱动, 可以理解为: 依靠历史大数据作为训练样本, DRL 智能体通过随机探索, 学习样本数据中的潜在规律, 逐渐优化动作, 使得学习到的策略面对

样本数据时呈现优越性。

知识驱动是指根据历史数据中负荷及新能源出力情况, 量化调度场景面对的源荷特征复杂度, 通过聚类算法划分源荷场景, 降低调度场景的复杂度, 以提高 DRL 的效率及寻优性能。

将知识驱动同数据驱动相结合, 先聚类-后训练, 可以实现不同类别场景下的 DRL 智能体训练, 从而构建适应多运行场景的强化学习模型。

融合知识驱动和数据驱动的训练方式结构如图 4 所示。

本文提出的融合知识驱动的训练架构及 DPPO 算法, 可用于训练 DRL 智能体, 以实现微电网系统内多类电源的低碳协调优化运行。本文所提算法描述如下。

第一步: 训练数据预处理, 确定样本簇个数 K ; 选择某一典型样本簇及其训练数据集; 设置子进程 worker 个数 M , 初始化 global 策略网络和价值网络参数, 初始化各个 worker 策略网络和价值网络; 初始化更新次数 $E=0$, 设置最大全局更新次数 E_{\max} ;

第二步: 每个子进程 worker, 启动微电网仿真环境加载该训练数据集并初始化, 智能体接收

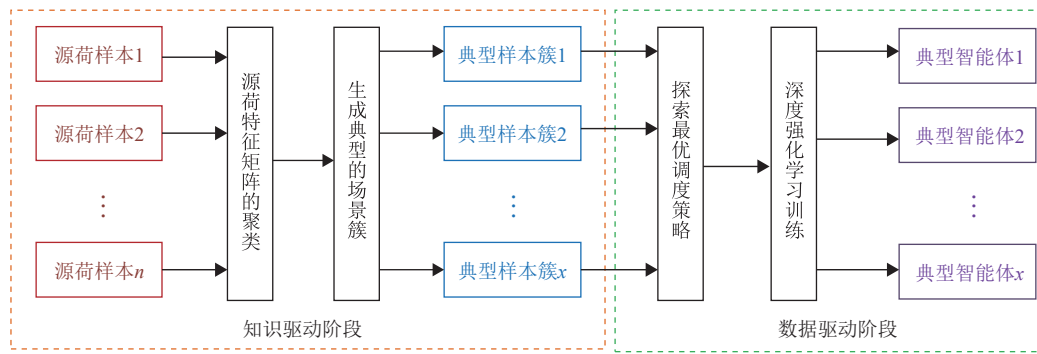


图 4 知识-数据驱动的训练结构

Fig. 4 Knowledge-data-driven training structure

初始状态，选择并执行动作，获得奖励和下一个状态；收集并储存当前策略下的交互经验，经验传递至主进程中，直到仿真环境结束运行；

第三步：主程序从经验池中随机抽取样，设置 $E=E+1$ ，以最小化损失函数 $loss = \text{mean}\{\sqrt{\hat{R}_\theta(s_t, a_t)}\}$ 为目标，更新 global 价值网络；

第四步：以最大化 PPO 智能体函数式 (41) 为目标，更新 global 策略网络；

第五步：主进程发送价值网络和策略网络参数至各个 worker，直到全局更新次数超过 E_{\max} ，此时结束训练过程。

2.3.3 微电网智能体在线应用

传统经过训练的 DRL 智能体本质上是一个神经网络，在线应用时，只需要加载保存好的神经网络参数，实时输入状态数据，则可输出对应的调度策略。在本节所提的知识-数据驱动的训练结构下，智能体应用过程存在不同，其流程图如图 5 所示。

3 算例分析

本节采用的微电网算例系统包括风电、光伏发电、1 台燃气轮机、1 个储能电池装置、1 个电解槽、1 个甲烷反应器以及负荷组成。每小时风电、光伏出力由历史数据构成。电力市场机制下的购售电价如表 1 所示；电解槽、甲烷反应器、储能的相关参数如表 2 所示；微电网与外部电网的交互功率上限设为 800 kW；源荷最大功率如附录表 A1—A2 所示；微电网内风、光、荷训练数据如附图 A1—A3 所示。

3.1 训练数据聚类分析

K-means 算法随机初始中心带来了不稳定问题，因此实验中对 K-means 算法重复运行，取其

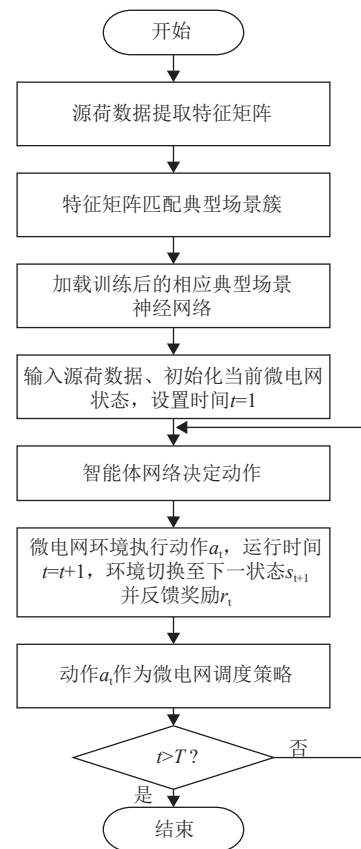


图 5 微电网智能体在线应用调度流程图

Fig. 5 Flow chart of online application dispatching of microgrid agents

表 1 微电网零售电价

Table 1 Retail electricity price of microgrid

时段	购电价/元	售电价/元
0—8	0.28	0.28
10—12、14—19	1.46	0.28
8—10、12—14、19—24	0.7	0.28

中较好的结果进行展示。聚类结果通过直观的聚类数目下的聚类类别图来反映，其中采用主成分

表2 各类设备参数
Table 2 Parameters of various equipment

设备	参数	数值
电解槽	电解槽效率	0.65
	电解槽功率上限/kW	1000
甲烷反应器	甲烷反应器效率	0.85
	甲烷反应器功率上限/kW	750
储能设备	容量/kW	1000
	最大充电功率/(kW/h)	200
	最大放电功率/(kW/h)	400

分析法 (principal component analysis, PCA) 对负荷、风机、光伏序列降维, 其聚类可视化图像如图6所示。




图6 基于PCA降维的可视化图像

Fig. 6 Visual images based on PCA dimension reduction

由图可知, 在对一年的数据进行聚类分析后, 负荷分为4大典型类, 光伏分为3大典型类, 而风机序列则分为4个典型类。基于聚类所获得的典型场景及源荷数据, 构成了48类潜在典型场景用于训练DRL智能体。

3.2 深度强化学习算法优化性能分析

深度强化学习的目标是使智能体学习策略并获得最大奖励值, 若智能体奖励值大小能够稳定在某一固定值附近, 说明算法具有收敛性; 智能体奖励值的大小表征了强化学习算法的寻优性能。本文选择了PPO算法作为基础算法, 并对PPO算法的训练框架进行改进, 形成了本文所提出的PA-DPPO算法。图7—8展示了PPO、PA-PPO、PA-DPPO 3种算法下的智能体训练过程。图中各训练曲线均采用平滑处理, 以更好比较其寻优性和收敛性。

图7中PA-PPO智能体和PPO智能体经过3000次以上的训练后均能收敛, PA-PPO智能体的奖励高于PPO智能体。二者的区别是PA-PPO智能体是采用了典型场景簇进行训练, 同一场景簇中源荷场景相似, 有助于智能体搜索最优策略;




图7 两类PPO算法奖励函数对比

Fig. 7 Reward function comparison of two types of PPO algorithms

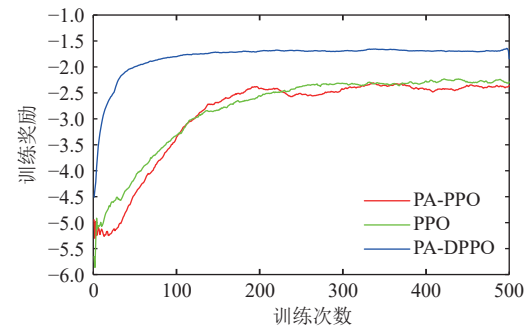


图8 三类算法奖励函数对比

Fig. 8 Reward function comparison of three types of algorithms

而 PPO 的训练数据集中源荷场景差异大，可能造成训练数据方差较大，因此会影响收敛奖励。

图 8 中，本文所提的 PA-DPPO 智能体获得了最高的奖励，且收敛速度最快，从图中看，经过 200 次训练后，PA-DPPO 已经快速稳定收敛。结合图 7 和图 8，PA-PPO 和 PPO 要 3000 次后才能收敛，可见本文所提算法的收敛速度相较于原始算法有了大幅提升。

当前已有各种 DRL 算法出现，为对比本文选择 PPO 类算法的合理性，选择深度确定性策略梯度算法 (deep deterministic policy gradient, DDPG) 和双延迟深度确定性策略梯度 (twin delayed deep deterministic policy gradient algorithm, TD3) 对比。如图 9 所示，DDPG 和 TD3 的训练奖励远低于 PA-DPPO，这主要是因为 DDPG 和 TD3 算法涉及大量的调参过程，经过大量实验仍未能找到最佳参数。虽然 DDPG 类收敛速度比 PA-DPPO 快，但是调参过程更加耗时，更依赖调参经验，整体而言，训练效率不及 PA-DPPO。




图 9 PPO 类算法同其他 DRL 算法奖励函数对比
Fig. 9 Comparison of PPO-type algorithm and reward function with other DRL algorithms

综上所述，本文提出的 PA-DPPO 算法在收敛速度、寻优性能上取得了优异的结果。PA-DPPO 能够训练智能体，并使智能体学习到微电网的调度策略。

3.3 优化调度方案分析

本节设置了如下 4 个运营模式，采用所提算法进行求解，并对某一日调度方案进行分析，以展示本文所提模型及运营模式的优越性。

模式 1：本文所提模型，碳捕集-电转气-燃气机组、储能与风光协调运行，微电网并网点容量受限。

模式 2：碳捕集-电转气-燃气机组、储能与风光协调运行，微电网并网点容量不受限。

模式 3：燃气机组、储能与风光协调运行，微电网并网点容量受限，电转气及碳捕集故障停运。

模式 4：燃气机组、储能与风光协调运行，微电网并网点容量不受限，电转气及碳捕集故障停运。

表 3 展示了 4 类运行模式中经济成本、风光转换率和碳捕集量的对比结果。

表 3 不同模式下运行成本对比
Table 3 Comparison of operating costs in different modes

模式	经济成本/元	风光转换率/%	碳捕集量/kg
1	1006.9	20.8	941.1
2	940.4	32.2	1460.9
3	1614.2	0	0
4	1090.7	0	0

由表可知，模式 2 经济成本最低，碳捕集量最高，风光转换率最高，风光转换率同碳捕集量呈现正相关关系，这是因为在模型中风光转换功率输入了电转气设备，生成甲烷的过程封存了相应的 CO_2 。模式 2 同模式 1 相比，在微电网并网点容量不受限制后，微电网加大了电价低谷时段同外部电网的购电量满足自身需求，从而凌晨时段一部分新能源功率用于电转气固化 CO_2 ，出现了风光转换率提高的局面；并网点容量受限时，微电网内功率则只能优先满足自身需求，两种情形下甲烷生成量对比如图 10 所示。两种模式对比说明了当前设备参数和低谷电价下，电转气制造甲烷并固碳有利可图。

模式 3 和模式 4 中电转气和碳捕集设备停运，模式 3 比模式 1 的经济成本高 60.3%，模式 4 比模式 2 的经济成本高 16.9%，这说明虽然表面上




图 10 不同模式下甲烷生成量对比
Fig. 10 Comparison of methane production in different modes

电转气设备是耗能设备，无法提供直接的经济价值，但是电转气的“削峰填谷”能力会改变供需关系，从而间接影响微电网内其他设备的运行计划，产生了间接的经济价值。因此，电转气和碳捕集设备的存在是必要的。

将风光并网功率同负荷功率的差值定义为等效负荷，图11中具体展示了模式1和模式3中的等效负荷曲线。




图 11 不同模式下等效负荷对比

Fig. 11 Comparison of equivalent load in different modes

图11柱状图中，等效负荷为正是指向主网倒送功率。图中可以看到：模式1的等效负荷的峰谷差更小，电转气起到了“削峰”作用，而在电网的低谷时段（23:00—4:00），模式1的等效负荷更大，起到了“填谷”作用；而模式3由于没有电转气这一“耗能”设备，在正午光伏出力最大时段，微电网内自身资源难以完全消纳，被迫向上级电网反送。在未来大量微电网接入10 kV配电网甚至更高等级电网后，大量的反送功率会使得原本的负荷节点成为电源节点，从而产生上级电网电压升高、继电保护误动等各种威胁，聚合各类资源的微电网能够本地管理，本地平衡更利于上级电网的管理和调度。因此，在经济性和固碳性以外，电转气的电力调节潜力同样不可忽视。针对某一日场景，微电网按照模式1方式制定的调度方案如图12所示。

分析调度方案，各设备有以下几个特点：1）正午时段，光伏出力最大，叠加风机功率后，微电网成为了“电源”，储能在正午时段（11:00—16:00）最大限度充电，不仅避免正午功率倒送，而且将新能源功率储存起来，在其他时段（17:00—24:00）放电，减少向电网的购电成本，储能发挥了削峰填谷和低吸高卖的作用。2）燃气轮机的运行时段大致在15:00—24:00（实际中

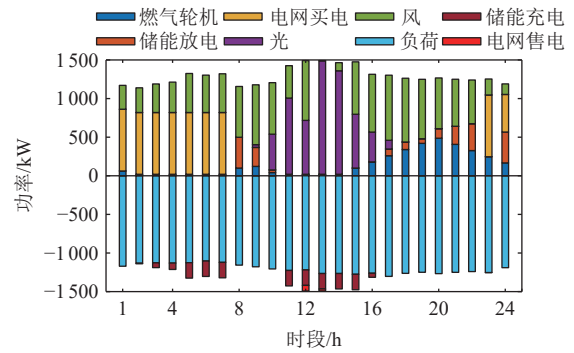


图 12 微电网各设备调度方案

Fig. 12 Dispatching scheme of each equipment of microgrid

燃气电厂的运行时段也多为晚峰），在凌晨和上午不会运行，主要原因是凌晨0:00—8:00是电价的低谷时段，微电网购电成本相较于燃气轮机运行成本更低，8:00—14:00光伏出力逐渐增大，光伏代替了电网购电成为了微电网内“电源”主力，因此也无需燃气轮机运行。3）微电网同电网的购售电情况，在一天中的电价低谷时段23:00—8:00，微电网大幅向主网购电，仅有正午12:00—13:00时段微电网内难以完全消纳新能源后，被迫向主网售电，图中看售电量也较低，其他时段会充分调节内部资源协调供电，实现功率角度的独立运行。图13展示了弃风弃光功率同电转气设备的运行关系。




图 13 微电网各设备调度方案

Fig. 13 Dispatching scheme of each equipment of microgrid

鉴于本文模型中，对风机和光伏的成本没有严格区分，认为二者成本相同，因此，弃风功率和弃光功率可以等同转换。图中明显指出：风光的丢弃功率均转换为了电解设备功率，从而用于电转气过程。明显的特点是正午12:00—16:00风光整体大发时段，电转气启动，消纳过剩的新能源功率，避免了微电网向主网大量反送。

4 结论

本文基于综合供能模型和深度强化学习理论,提出了一种融合知识的深度强化学习求解框架及并行智能体-分布式近端策略优化算法。在数据驱动的模式下训练智能体实现了微电网系统内多类电源的低碳协调优化运行。算例验证得到的结论如下:

1) 引入碳捕集和电转气设备,可同传统微电网中的储能设备配合,共同实现削峰填谷功能,增加了微电网调度的多样性。

2) 相比于深度强化学习的直接应用,本文所提的先聚类-后训练思想,将电力运行调度知识同数据驱动相结合,降低了深度强化学习训练集中调度场景的复杂度,提高了 DRL 的效率及寻优性能。

3) 在所提先聚类-后训练框架下,进一步提出的分布式近端策略优化算法,充分利用了多线程算力,能够快速且多样本范围内收集经验,同样能够提高训练效率和寻优性能。

但是本文也存在以下不足:缺乏当前微电网热功率的历史数据,因此在深度强化学习模型中忽视了燃气轮机的热电联产功能,一定程度上简化了燃气轮机的调节能力。在未来的研究中,可将热力市场和碳交易市场纳入研究,进一步完善综合供能微电网的优化调度问题。

(本刊附录请见网络版,印刷版略)

参考文献

- [1] 周任军,孙洪,唐夏菲,等.双碳量约束下风电-碳捕集虚拟电厂低碳经济调度[J].中国电机工程学报,2018,38(6):1675-1683.
ZHOU Renjun, SUN Hong, TANG Xiafei, *et al.* Low-carbon economic dispatch based on virtual power plant made up of carbon capture unit and wind power under double carbon constraint[J]. Proceedings of the CSEE, 2018, 38(6): 1675-1683(in Chinese).
- [2] 李海,张宁,康重庆,等.可再生能源消纳影响因素的贡献度分析方法[J].中国电机工程学报,2019,39(04):1009-1018.
LI Hai, ZHANG Ning, KANG Chongqing, *et al.* Analytics of contribution degree for renewable energy accommodation factors[J]. Proceedings of the CSEE, 2019, 39(04): 1009-1018(in Chinese).
- [3] 米剑锋,马晓芳.中国 CCUS 技术发展趋势分析[J].中国电机工程学报,2019,39(09):2537-2544.
MI Jianfeng, MA Xiaofang. Development trend analysis of carbon capture, utilization and storage technology in China[J]. Proceedings of the CSEE, 2019, 39(09): 2537-2544(in Chinese).
- [4] SCHIEBAHN S, GRUBE T, ROBINIUS M, *et al.* Power to gas: technological overview, systems analysis and economic assessment for a case study in Germany[J]. *International Journal of Hydrogen Energy*, 2015, 40(12): 4285-4294.
- [5] 周任军,肖钧文,唐夏菲,等.电转气消纳新能源与碳捕集电厂碳利用的协调优化[J].电力自动化设备,2018,38(7):61-67.
ZHOU Renjun, XIAO Junwen, TANG Xiafei, *et al.* Coordinated optimization of carbon utilization between power-to-gas renewable energy accommodation and carbon capture power plant[J]. Electric Power Automation Equipment, 2018, 38(7): 61-67(in Chinese).
- [6] 陈伯达,林楷东,张勇军,等.计及碳捕集和电转气协同的电气互联系统优化调度[J].南方电网技术,2019,13(11):9-17.
CHEN Boda, LIN Kaidong, ZHANG Yongjun, *et al.* Optimal dispatching of integrated electricity and natural gas energy systems considering the coordination of carbon capture system and power-to-gas[J]. Southern Power System Technology, 2019, 13(11): 9-17(in Chinese).
- [7] YANG J, ZHANG N, CHENG Y, *et al.* Modeling the operation mechanism of combined P2G and gas-fired plant with CO₂ recycling[J]. *IEEE Transactions on Smart Grid*, 2018, 10(1): 1111-1121.
- [8] 孙惠娟,刘响,彭春华,等.计及电转气协同的含碳捕集与垃圾焚烧虚拟电厂优化调度[J].电网技术,2021,45(9):3534-3545.
SUN Huijuan, LIU Yun, PENG Chunhua, *et al.* Optimization scheduling of virtual power plant with carbon capture and waste incineration considering power-to-gas coordination[J]. Power System Technology, 2021, 45(9): 3534-3545(in Chinese).
- [9] 田明,张海峰,刘坤.计及电转气和碳捕集的数据中心微电网“源-荷”低碳优化调度方法[J].电气工程学报,2022,17(03):85-94.
TIAN Ming, ZHANG Haifeng, LIU Kun. “Source-load” low-carbon optimal scheduling method for data center microgrids considering power to gas and carbon capture[J]. Journal of Electrical Engineering, 2022, 17(03): 85-94(in Chinese).
- [10] 高晗,李正烁.考虑电转气响应特性与风电出力不确定性

- 的电-气综合能源系统协调调度[J]. 电力自动化设备, 2021, 41(9): 24-30.
- GAO Han, LI Zhengshuo. Coordinated scheduling of integrated electricity-gas energy system considering response characteristic of power-to-gas and wind power uncertainty[J]. Electric Power Automation Equipment, 2021, 41(9): 24-30(in Chinese).
- [11] QADRAN M, WU J, JENKINS N, *et al.* Operating strategies for a GB integrated gas and electricity network considering the uncertainty in wind power forecasts[J]. *IEEE Transactions on Sustainable Energy*, 2014, 5(1): 128-138.
- [12] 姜明军, 黎启明, 赵苍禄, 等. 融合极限场景辨别算法的含碳捕集综合能源系统鲁棒调度模型研究[J]. *智慧电力*, 2023, 51(03): 17-24.
- JIANG Mingjun, LI Qiming, ZHAO Canglu, *et al.* Robust scheduling model of integrated energy system with carbon capture integrating extreme scenario discrimination algorithm[J]. *Smart Power*, 2023, 51(03): 17-24(in Chinese).
- [13] 胡维昊, 曹迪, 黄琦, 等. 深度强化学习在配电网优化运行中的应用[J]. *电力系统自动化*, 2023, 47(14): 174-191.
- HU Weihao, CAO Di, HUANG Qi, *et al.* Application of deep reinforcement learning in optimal operation of distribution network[J]. *Automation of Electric Power Systems*, 2023, 47(14): 174-191(in Chinese).
- [14] 张有兵, 林一航, 黄冠弘, 等. 深度强化学习在微电网系统调控中的应用综述[J]. *电网技术*, 2023, 47(07): 2774-2788.
- ZHANG Youbing, LIN Yihang, HUANG Guanhong, *et al.* Review on applications of deep reinforcement learning in regulation of microgrid systems[J]. *Power System Technology*, 2023, 47(07): 2774-2788(in Chinese).
- [15] DOMÍNGUEZ-BARBERO D, GARCÍA-GONZÁLEZ J, SANZ-BOBI M A, *et al.* Optimising a microgrid system by deep reinforcement learning techniques[J]. *Energies*, 2020, 13(11): 2830.
- [16] ZHAO Jin, LI Fangxing, MUKHERJEE S, *et al.* Deep reinforcement learning-based model-free on-line dynamic multi-microgrid formation to enhance resilience[J]. *IEEE Transactions on Smart Grid*, 2022, 13(4): 2557-2567.
- [17] 梁宏, 李鸿鑫, 张华赢, 等. 基于深度强化学习的微网储能系统控制策略研究[J]. *电网技术*, 2021, 45(10): 3869-3876.
- LIANG Hong, LI Hongxin, ZHANG Huaying, *et al.* Control strategy of microgrid energy storage system based on deep reinforcement learning[J]. *Power System Technology*, 2021, 45(10): 3869-3876(in Chinese).
- [18] YU Liang, XIE Weiwei, XIE Di, *et al.* Deep reinforcement learning for smart home energy management[J]. *IEEE Internet of Things Journal*, 2020, 7(4): 2751-2762.
- [19] LU Xiaozhen, XIAO Xingyu, XIAO Liang, *et al.* Reinforcement learning-based microgrid energy trading with a reduced power plant schedule[J]. *IEEE Internet of Things Journal*, 2019, 6(6): 10728-10737.
- [20] 崔帅, 唐晓宁, 张彬, 等. 合成气甲烷化过程热力学分析[J]. *计算机与应用化学*, 2015, 32(4): 419-425.
- CUI Shuai, TANG Xiaoning, ZHANG Bin, *et al.* Thermodynamic analysis for the synthesis process of methane[J]. *Computers & Applied Chemistry*, 2015, 32(4): 419-425(in Chinese).

收稿日期: 2023-09-28

作者简介:

林文硕(1989), 男, 本科, 工程师, 研究方向为电网调度运行, E-mail: linwenshuo@sina.com;

李欣(1981), 女, 硕士研究生, 高级工程师, 研究方向为电网调度运行, E-mail: xingladys@163.com;

周荣生(1986), 男, 本科, 高级工程师, 研究方向为电网调度运行, E-mail: 546696198@qq.com;

朱怡莹(1990), 女, 本科, 工程师, 研究方向为电网调度运行;

彭依明(1989), 女, 本科, 工程师, 研究方向为电气工程及其自动化。

附录 A

表 A1 源荷参数

Table A1 Parameters of source and load

类型	容量(最大功率)/kW
电负荷	1500
光伏	2000
风机	1000

表 A2 深度强化学习算法参数

Table A2 Parameters of DRL

参数类型	数值
批采样个数	128
经验池大小	4096
神经网络学习率	0.0001
神经网络层数	3
中间层神经元个数	256
ϵ	0.15




图 A1 负荷序列数据

Fig. A1 The data of load sequence




图 A2 光伏序列数据

Fig. A2 The data of PV sequence




图 A3 风机序列数据

Fig. A3 The data of WT sequence