

doi:10.3969/j.issn.1000-2162.2024.02.008

# 基于 MD3QN 算法的微电网能量协调优化

李小豹<sup>1</sup>, 赵婵娟<sup>1\*</sup>, 程志友<sup>1</sup>, 徐 恒<sup>2</sup>

(1. 安徽大学 互联网学院, 安徽 合肥 230039; 2. 安徽建筑大学 电子与信息工程学院, 安徽 合肥 230601)

**摘 要:** 可再生能源出力的波动性、间歇性、用户电力负荷的随机不确定性, 使微电网的能量调度极具挑战性. 为此, 该文提出激励竞争双深度 Q 网络 (motivation dueling double deep Q-network, 简称 MD3QN) 算法, 对微电网能量进行协调优化. 仿真分析结果表明: 采用 MD3QN 算法对微电网进行能量调度, 能实现削峰填谷, 使微电网的经济效益最大化; 相对于其他 4 种算法, MD3QN 算法具有更高的综合性能. 因此, MD3QN 算法具有有效性.

**关键词:** 并网型微电网; 能量管理; MD3QN; 实时电价激励机制

**中图分类号:** TM734

**文献标志码:** A

**文章编号:** 1000-2162(2024)02-0046-07

## Microgrid energy coordination optimization based on MD3QN algorithm

LI Xiaobao<sup>1</sup>, ZHAO Chanjuan<sup>1\*</sup>, CHENG Zhiyou<sup>1</sup>, XU Heng<sup>2</sup>

(1. School of Internet, Anhui University, Hefei 230039, China;

2. School of Electronic and Information Engineering, Anhui Jianzhu University, Hefei 230601, China)

**Abstract:** The volatility and intermittency of renewable energy output, and the stochastic uncertainty of customer power loads make energy scheduling for microgrids very challenging. Thus, to coordinate and optimize microgrid energy scheduling, a motivation dueling double deep Q-network (MD3QN) algorithm was proposed in this paper. Simulation analysis results demonstrated that the MD3QN algorithm for microgrids energy scheduling could obtain maximum economic benefit, and the peak shaving and valley filling of microgrids was achieved. Compared with the other four algorithms, the MD3QN algorithm had a higher composite performance. Therefore, the MD3QN algorithm was effective.

**Keywords:** grid-connected microgrid; energy management; MD3QN; real-time electricity price incentive mechanism

随着传统化石能源日益枯竭, 开发新能源、加强可再生能源的综合利用、提高能源利用效率成为解决能源紧缺问题的必然选择<sup>[1]</sup>. 微电网<sup>[2]</sup>是一种小型发配电系统, 包括分布式发电 (distributed generation, 简称 DG)、储能 (energy storage, 简称 ES) 和负荷等单元. 在微电网中, 可再生能源出力的间

**收稿日期:** 2023-05-10

**基金项目:** 安徽省自然科学基金资助项目 (2108085QE237, 2208085UD01); 安徽省教育厅自然科学重点项目 (2023AH050104); 安徽建筑大学安徽省古建筑智能感知与高维建模国际联合研究中心开放课题基金资助项目 (GJZZX2021KF03)

**作者简介:** 李小豹 (1998—), 男, 安徽宿州人, 安徽大学硕士研究生, E-mail: lixiaobao\_boss@163.com; \* 赵婵娟 (通信作者), 安徽大学讲师, 硕士生导师, 博士, E-mail: chanjuanzhao@ahu.edu.cn.

歇性、负荷本身的随机不确定性等,使微电网的优化运行面临挑战. 建立高效可靠的微电网能量管理系统(energy management system,简称 EMS),优化调度微电网的可控单元(DG, ES 和可控负荷),对保证微电网经济可靠运行具有重要意义<sup>[3-4]</sup>.

为实现微电网能量的最优调度,很多学者展开了相关研究. 文献[5]针对风电接入的电力系统,提出一种随机规划算法,实现了风电系统多目标随机动态最优经济调度. 文献[6]以微电网经济效益和清洁能源自洽率双提升为目标,提出一种改进的多目标量子遗传算法,对微电网能量进行调度. 文献[7]基于改进的粒子群算法对微电网进行优化控制,提高了微电网运行的经济效益. 但是,上述算法均需对微电网建立精确模型,但分布式发电和负荷的不确定性给精确建模带来困难. 因此,设计微电网能量管理的无模型优化算法,对实现微电网能量优化调度至关重要.

随着人工智能技术的发展,具有无模型优化能力的强化学习算法应用于能量管理成为研究热点. 文献[8]提出了一种基于 Nash 博弈和强化学习的并网型微电网能量协调优化调度策略,不用对微电网运行的不确定性进行建模,但该算法对微电网状态和决策动作均进行了离散化,在复杂环境下可能会出现维数灾难,导致算法优化效果减弱. 文献[9]提出一种深度 Q 网络(deep Q-network,简称 DQN)算法,通过深度神经网络存储策略,解决了传统 Q 学习算法的维数灾难问题,但该算法在同一 Q 网络上进行动作的选择和评估,存在“过估计”风险,该算法稳定性仍有待提高. 文献[10]提出深度确定性策略梯度(deep deterministic policy gradient,简称 DDPG)算法,引入经验回放机制和调整感知学习比例,有效提高了算法稳定性,实现了电力系统能量动态调度,但该算法存在训练缓慢、学习效率低、参数调整难度大的问题. 此外,双深度 Q 网络(double deep Q-network,简称 Double-DQN)算法<sup>[11]</sup>、竞争深度 Q 网络(dueling deep Q-network,简称 Dueling-DQN)算法<sup>[12]</sup>和 Rainbow 算法<sup>[13]</sup>均已应用于微电网的优化调度. 该文研究不确定环境下微电网能量调度的深度强化学习算法,提出一种激励竞争双深度 Q 网络(motivation dueling double deep Q-network,简称 MD3QN)算法,以适应微电网源荷供需互动. 通过仿真分析验证所提算法的有效性.

## 1 微电网

该文研究一类具有独立供需基础设施的并网型微电网能量管理问题. 该微电网由储能电池、分布式发电能源及电力负荷组件组成. 微电网可连接主电网,与主电网进行能量交互. 微电网中各组件信息均可通过通信网络在各组件间传输.

### 1.1 储能电池组件

由于光伏、风力等分布式发电能源的出力具有不确定性、间歇性,一般可通过储能电池平抑功率波动. 该文以蓄电池为例构建储能电池组件模型.

蓄电池时刻  $t$  的储能为

$$B_t = B_{t-1} + \eta_c c_t - \frac{D_t}{\eta_d}, \quad (1)$$

其中:  $B_t \in (0, B_{\max})$ ,  $B_{\max}$  为蓄电池的最大储能;  $\eta_c$  和  $\eta_d$  分别为蓄电池的充电效率和放电效率;  $c_t$  和  $D_t$  分别为蓄电池时刻  $t$  的充电功率和放电功率,  $c_t \in (0, c_{\max})$ ,  $D_t \in (0, D_{\max})$ ,  $c_{\max}$  和  $D_{\max}$  分别为蓄电池的最大充电功率和最大放电功率. 蓄电池时刻  $t$  的荷电状态为

$$B_{sc} = \frac{B_t}{B_{\max}}. \quad (2)$$

蓄电池储能约束为

$$B_{sc, \min} \leq B_{sc} \leq B_{sc, \max}, \quad (3)$$

其中:  $B_{sc, \min}$  为蓄电池的最小荷电状态,  $B_{sc, \max}$  为蓄电池的最大荷电状态.

蓄电池的功率约束为

$$-50\%B_{\max}\eta_c \leq P_B(t)\Delta t \leq 50\%B_{\max}\eta_d, \quad (4)$$

其中:  $P_B(t)$  为蓄电池时刻  $t$  的功率.

## 1.2 分布式发电能源组件

分布式发电能源组件是微电网的核心部分. 随着可再生能源发电在微电网中的渗透率不断提高, 其发电出力的不确定性和时变性, 给微电网的运行带来挑战.

## 1.3 电力负荷组件

### 1.3.1 恒温控制负荷

恒温控制负荷是能被直接控制且有恒温要求的负荷. 恒温控制负荷通常采用开关动作进行控制. 为满足用户要求, 需对恒温控制负荷进行温度约束. 恒温控制负荷  $i$  时刻  $t$  的功率为

$$u_{b,t}^i = \begin{cases} 0, & T_t^i > T_{\max}^i, \\ u_t^i, & T_{\min}^i \leq T_t^i \leq T_{\max}^i, \\ 1, & T_t^i < T_{\min}^i, \end{cases} \quad (5)$$

其中:  $T_t^i$  为时刻  $t$  恒温控制负荷  $i$  的工作温度;  $T_{\min}^i$  和  $T_{\max}^i$  分别为恒温控制负荷  $i$  的温度下限和上限; 0 表示不给恒温控制负荷供电; 1 表示恒温控制负荷以标称功率  $\omega_{\text{icl}}^i$  运行;  $u_t^i$  表示智能体对恒温控制负荷  $i$  可能选择的动作.

恒温控制负荷  $i$  的温度动力学 2 阶模型<sup>[14]</sup> 为

$$\dot{T}_t^i = \frac{1}{C_a^i}(T_t^0 - \hat{T}_t^i) + \frac{1}{C_m^i}(T_{m,t}^i - \hat{T}_t^i) + \omega_{\text{icl}}^i u_{b,t}^i + q^i, \quad (6)$$

$$\dot{T}_{m,t}^i = \frac{1}{C_m^i}(\hat{T}_t^i - T_{m,t}^i), \quad (7)$$

其中:  $\hat{T}_t^i$  为室内温度;  $T_{m,t}^i$  为建筑物温度;  $T_t^0$  为室外温度;  $C_a^i$  和  $C_m^i$  分别为空气和建筑物的热容;  $q^i$  为建筑内部的供暖热量;  $\omega_{\text{icl}}^i$  为恒温控制负荷的标称功率.

### 1.3.2 价格响应负荷

价格响应负荷为通过电力价格无法被直接控制的负荷. 价格响应负荷  $i$  时刻  $t$  的电力负荷为

$$L_{\text{load}}^{i,t} = L_{b,t} - O_t^i + F_t^i, \quad (8)$$

其中:  $L_{b,t}$  为基础负荷; 恒温控制负荷  $i$  的转移负荷  $O_t^i = L_{b,t}\beta_i\sigma_t$ ,  $\beta_i$  为价格变化导致的价格响应负荷变化量占总价格响应负荷的比值,  $\sigma_t$  为时刻  $t$  价格响应负荷的电价;  $F_t^i$  为价格响应负荷  $i$  任意时刻至时刻  $t$  时段转移的负荷总数.

## 2 基于强化学习的微电网能量管理系统

强化学习以预期回报最大化为目标, 智能体根据环境状态选取奖励最大时动作. 基于微电网各组件, 建立微电网能量管理强化学习模型. 为了实现微电网的优化运行, 该文以微电网日运行利润最高作为目标函数. 日运行利润的最大值为

$$\max \sum_{t=1}^T (\tau_t + (p_t^s - C_{\text{ex}})E_t^s - v_t - (p_t^b + C_{\text{im}})E_t^b), \quad (9)$$

其中:  $T$  为调度时段数;  $\tau_t$  为时段  $t$  各类电力负荷的盈利;  $v_t$  为时段  $t$  的风力发电成本;  $p_t^s$  为向主电网售电的价格;  $p_t^b$  为从主电网买电的价格;  $E_t^s$  为向主电网售电的电量;  $E_t^b$  为从主电网买电的电量;  $C_{\text{ex}}$  和  $C_{\text{im}}$  分别是向主电网售电和从主电网买电的输电成本.

微电网中各组件的基本信息构成状态空间  $S$ , 包含恒温控制负荷组件的功率、分布式发电组件的发电功率、储能组件的荷电状态、价格响应负荷的总功率、买电价、售电价及时间.

智能体学习微电网环境状态信息后进行对应动作, 对应动作空间  $A$  包括温控制负荷动作空间  $a_{\text{icl}}$ 、

价格响应负荷动作空间  $a_{\text{load}}$ 、系统电力不足动作空间  $a_e$  和系统电力过剩动作空间  $a_d$ , 即  $A = (a_{\text{tcl}}, a_{\text{load}}, a_e, a_d)$ 。

强化学习将优化目标映射为奖励函数. 时刻  $t$  的奖励函数为

$$r_t = p_{\text{load}} \sum_{i=0}^{N_{\text{load}}} L_{\text{load}}^{i,t} + p_{\text{tcl}} \sum_{i=0}^{N_{\text{tcl}}} L_{\text{tcl}}^{i,t} + p_t^s E_t^s - [p_{\text{cost}} G_t + (p_t^b + C_{\text{im}}) E_t^b + C_{\text{ex}} E_t^s], \quad (10)$$

其中:  $p_{\text{load}} = p_{\text{market}} + \sigma_t f_{\text{cst}}$ ,  $p_{\text{market}}$  为市场电价,  $f_{\text{cst}}$  为调节参数;  $N_{\text{load}}$  为价格响应负荷的数量;  $L_{\text{load}}^{i,t}$  为时刻  $t$  价格响应负荷  $i$  的用电功率;  $L_{\text{tcl}}^{i,t}$  为时刻  $t$  恒温控制负荷  $i$  的用电功率;  $p_{\text{tcl}}$  为恒温控制负荷的电价;  $N_{\text{tcl}}$  为恒温控制负荷的数量;  $p_{\text{cost}}$  为分布式发电能源组件的发电成本;  $G_t$  为分布式发电组件的发电功率. 基于强化学习的微电网能量管理系统如图 1 所示.

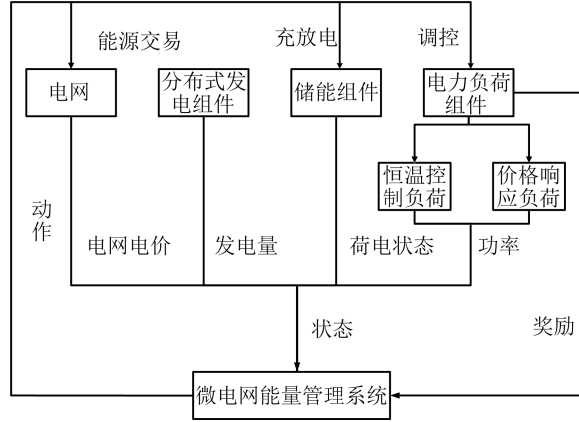


图 1 基于强化学习的微电网能量管理系统

### 3 基于 MD3QN 算法的微电网能量协调优化

针对传统 DQN 算法存在“过估计”、动作探索精度不高和稳定性差等问题, 该文提出 MD3QN 算法. 该文 MD3QN 算法在以下 3 方面进行了改进.

#### (1) Q 值的改进

DQN 算法 Q 值表达式为

$$Q(s_t, a_t) = E[G_t | S = s_t, A = a_t], \quad (11)$$

其中:  $G_t$  为时刻  $t$  智能体得到的长期累积折扣奖励最大值; 时刻  $t$  智能体选取的状态  $S = s_t$ , 时刻  $t$  智能体选取的动作  $A = a_t$ ;  $E[\cdot]$  表示取平均值. DQN 算法的 Q 值导致无法区分目前奖励是由状态本身引起的还是动作引起的. 针对该问题, MD3QN 算法采用一种竞争架构, 将 Q 值表达式改进为

$$Q(s_t, a_t; \theta, \theta_v, \theta_A) = V(s_t; \theta, \theta_v) + (A(s_t, a_t; \theta, \theta_A) - \frac{1}{|A(s_t, a_t; \theta, \theta_A)|} A(s_t, a_{t+1}; \theta, \theta_A)), \quad (12)$$

其中:  $V(\cdot)$  为状态价值函数;  $A(s_t, a_t; \theta, \theta_A)$  为时刻  $t$  的动作优势函数;  $\theta$  为共享网络参数;  $\theta_v$  和  $\theta_A$  为主网络网络参数. 通过 Q 值的改进, 使智能体较快探索到最佳动作.

#### (2) 目标网络估值的改进

DQN 算法的主网络和目标网络是 2 个结构相同但参数不同的神经网络. DQN 算法的目标网络估值为

$$y_t^{\text{DQN}} = r_{t+1} + \gamma \max Q(s_{t+1}, a_{t+1}; \theta'), \quad (13)$$

其中:  $r_{t+1}$  为时刻  $t+1$  智能体得到的奖励;  $s_{t+1}$  为时刻  $t+1$  的状态;  $\gamma$  为折扣因子;  $\theta'$  为目标网络的参数. DQN 算法估计 Q 值时, 选取最大化 Q 值的动作, 同时用这个最大 Q 值更新目标网络估值, 这就导致了 Q 值高估, 即存在“过估计”的问题. 针对该问题, MD3QN 算法将目标网络估值改进为

$$y_t^{\text{MD3QN}} = r_{t+1} + \gamma Q(s_{t+1}, \arg\max Q(s_{t+1}, a_{t+1}; \theta, \theta_v, \theta_A); \theta', \theta'_v, \theta'_A), \quad (14)$$

其中:  $\theta'_v$  和  $\theta'_A$  为目标网络参数. 通过目标网络估值的改进, 主网络可进行当前状态下的最优动作, 然后利用目标网络计算该动作的  $Q$  值, 进而得到估值. 同时, 在双重学习的过程中, 主网络和目标网络均能更新网络参数, 有效解决了 DQN 算法的“过估计”问题.

### (3) $\epsilon$ -greedy 策略的改进

DQN 算法通过  $\epsilon$ -greedy 策略选取最优动作, 采用  $\epsilon$ -greedy 策略的智能体以概率  $\epsilon$  选取  $Q$  值最大的动作, 以  $1-\epsilon$  概率选取随机动作. 如果探索率一直很高, 会陷入无休止的探索, 导致探索效率低下; 如果探索率一直很低, 会错过一些有利的探索机会, 同样导致探索效率低下. 针对 DQN 算法动作探索效率不高问题, MD3QN 算法在设置动态探索率  $\epsilon$  的前提下, 考虑并网型微电网对交易电价的敏感性, 将实时电价激励机制与  $\epsilon$ -greedy 策略相结合, 以平衡动作探索. MD3QN 算法以概率  $\epsilon$  选取  $Q$  值最大的动作, 先以  $1-\epsilon$  概率将系统电力不足动作空间  $a_e$  与时刻  $t$  实时电价激励指令  $\eta_t$  进行逻辑“与”运算, 后以  $1-\epsilon$  概率将系统电力过剩动作空间  $a_d$  与时刻  $t$  实时电价激励指令  $\eta_t$  进行逻辑“或”运算, 其中  $\eta_t$  的表达式为

$$\eta_t = \begin{cases} 0, & p_t^b - p_t^s < p_{th}, \\ 1, & p_t^b - p_t^s \geq p_{th}, \end{cases} \quad (15)$$

其中:  $p_t^s$  为时刻  $t$  电力市场售电价,  $p_t^b$  为时刻  $t$  电力市场买电价,  $p_{th}$  为设定的电价差阈值.

实时电价激励机制, 在考虑储能组件参与电力交易的基础上, 利用峰谷价差赚取收益. 在电价低谷时段, 负向输出功率, 微电网及时对储能电池组件充电; 在电价高峰时段, 正向输出功率, 储能电池组件及时向微电网放电. 通过这种方式, 在满足用电负荷需求情况下智能体尽可能保持经济效益最优. 通过实时电价激励机制, 降低了智能体训练阶段动作探索的盲目性, 减少了无效探索的次数, 增加了经验池中的样本数量, 进而提高了微电网能量调度的动作探索效率.

图 2 为基于 MD3QN 算法的微电网能量协调优化流程.

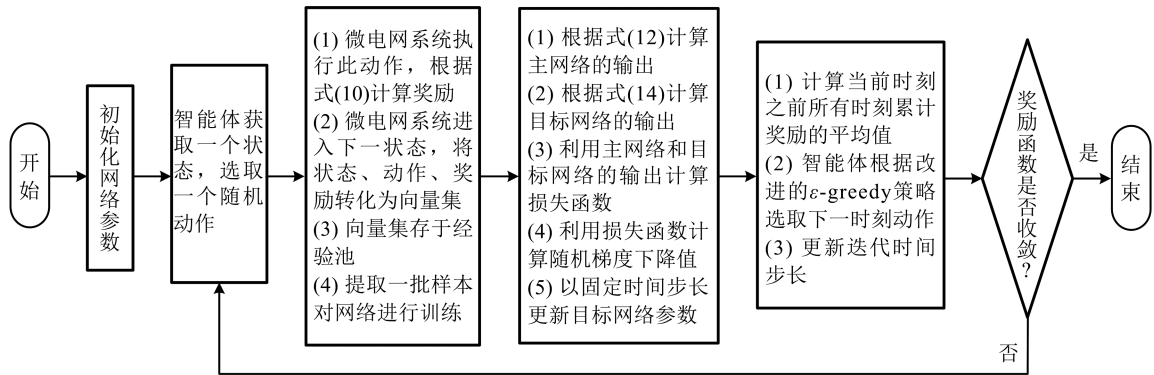


图 2 基于 MD3QN 算法的微电网能量协调优化流程

## 4 仿真分析

### 4.1 仿真场景

该文分布式发电能源组件的发电功率、输电成本和气象信息等数据, 均源自芬兰国家电网公开的数据库<sup>[15]</sup>. 1 h 采集 1 次微电网的样本数据. 微电网环境主要参数设置如下: 蓄电池最大储能  $B_{\max} = 500$  kW, 蓄电池最大充电功率  $c_{\max} = 250$  kW, 蓄电池最大放电功率  $D_{\max} = 500$  kW, 价格响应负荷的数量  $N_{\text{load}} = 150$ , 恒温控制负荷的数量  $N_{\text{tcl}} = 100$ , 分布式发电能源组件的发电成本  $P_{\text{cost}} = 32$  欧元/MW.

### 4.2 性能分析

图 3 为风力发电功率. 图 4 为储能电池组件的荷电状态. 图 5 为价格响应负荷的功率. 图 6 为恒温控制负荷的功率. 图 7 为电量和电价.






图 3 风力发电功率




图 4 储能电池组件的荷电状态




图 5 价格响应负荷的功率




图 6 恒温控制负荷的功率




图 7 电量和电价

由图 3~4、7 可知,在向主电网售电的价格较低的 0:00—3:00,应对储能蓄电池充电;在售电价较高的 4:00—12:00,应将多余电量出售给主电网;在 13:00—23:00,风电场发电功率不足,储能蓄电池应及时放电,向主电网购买电量,以满足微电网的电力负荷需求. 由图 5~6 可知,微电网能量管理系统应在一天中风电场发电量较多时段给恒温控制负荷分配足够的电量,以便在一天中剩下的时间保持舒适的温度而不需要更多的电量,以缓解价格响应负荷的需求. 综上,采用 MD3QN 算法对微电网进行能量调度,能避免在高需求和低发电时购买大量的电力,由此实现削峰填谷,提高微电网的日间总体收益,使微电网的经济效益最大化.

4.3 性能对比

为了验证该文提出的 MD3QN 算法的有效性,将其调度结果与 DQN、Double-DQN、Dueling-DQN 及 Rainbow 算法的调度结果进行对比. 表 1 为不同算法的训练时间及连续 10 d 的平均奖励.

表 1 不同算法的训练时间及连续 10 d 的平均奖励

算法	训练时间/ min	平均奖励/欧元
DQN	11. 44	-138. 25
Double-DQN	16. 07	190. 49
Dueling-DQN	16. 37	229. 11
Rainbow	57. 15	-384. 13
MD3QN	15. 73	279. 25

由表 1 可知,5 种算法中,该文提出的 MD3QN 算法的训练时间仅长于 DQN 算法的训练时间,MD3QN 算法平均奖励最高,表明 MD3QN 算法具有更高的综合性能.这是因为 MD3QN 算法融合了双重 Q 学习理论、竞争架构和实时电价激励机制,能提高智能体动作探索质量,进而优化能量调度.

## 5 结束语

微电网的能量协调优化是实现能源高效灵活利用的前提.该文针对传统 DQN 算法存在“过估计”、动作探索精度不高和稳定性差等问题,提出 MD3QN 算法,用于微电网能量协调优化.仿真分析结果表明:采用 MD3QN 算法对微电网进行能量调度,能实现削峰填谷,提高微电网的日间总体收益;相对于 DQN 算法、Double-DQN、Dueling-DQN 和 Rainbow 算法,该文提出的 MD3QN 算法的训练时间仅长于 DQN 算法的训练时间,MD3QN 算法平均奖励最高.因此,MD3QN 算法具有更高的综合性能.

## 参考文献:

- [1] 张政林,张惠娟,孙文治,等.基于改进旗鱼算法的综合能源系统能量管理[J].电力系统保护与控制,2022,50(22):142-151.
- [2] 张志文,李华强.考虑灵活性的孤岛微电网群分层能量管理策略[J].电力系统保护与控制,2020,48(20):97-105.
- [3] 杜祥伟,沈艳霞,李静.基于模型预测控制的直流微网混合储能能量管理策略[J].电力系统保护与控制,2020,48(16):69-75.
- [4] 艾芊,郝然.多能互补、集成优化能源系统关键技术及挑战[J].电力系统自动化,2018,42(4):2-10.
- [5] 付一木,刘明波.求解多目标随机动态经济调度问题的场景解耦方法[J].电力系统自动化,2014,38(9):34-40.
- [6] 王飏,赵微微,林少军,等.基于改进的多目标量子遗传算法的高速服务区综合能源管理[J].电网技术,2022,46(5):1742-1751.
- [7] 雷何,方仍存,杨东俊,等.基于改进二阶粒子群算法的微电网群优化调度[J].武汉大学学报(工学版),2022,55(9):894-900.
- [8] 刘洪,李吉峰,葛少云,等.基于多主体博弈与强化学习的并网型综合能源微网协调调度[J].电力系统自动化,2019,43(1):40-48.
- [9] 刘俊峰,陈剑龙,王小生.基于深度强化学习的微能源网能量管理与优化策略研究[J].电网技术,2020,44(10):3794-3803.
- [10] 彭刘阳,孙元章,徐箭,等.基于深度强化学习的自适应不确定性经济调度[J].电力系统自动化,2020,44(9):33-42.
- [11] YANG Q L, WANG G, SADEGHI A, et al. Two-time scale voltage control in distribution grids using deep reinforcement learning[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2313-2323.
- [12] WANG B, LI Y, MING W Y, et al. Deep reinforcement learning method for demand response management of interruptible load[J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3146-3155.
- [13] SAMADI E, BADRI A, EBRAHIMPOUR R. Decentralized multi-agent based energy management of microgrid using reinforcement learning[J]. International Journal of Electrical Power & Energy Systems, 2020, 122: 106211.
- [14] CLAESSENS B J, VRANCX P, RUELENS F. Convolutional neural networks for automatic state-time feature extraction in reinforcement learning applied to residential load control[J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3259-3269.
- [15] Suomi National Grid. Fingrid open datasets[EB/OL]. [2023-03-09]. <https://data.fingrid.fi/en/dataset>.

(责任编辑 郑小虎)