

DOI: 10.19783/j.cnki.pspc.231371

考虑 SOC 优化设定的电-氢混合储能系统的运行优化

姜智霖¹, 郝峰杰², 袁志昌¹, 朱小毅², 郭佩乾¹, 潘海宁², 项淼毅¹, 贺宁怡¹

(1. 清华大学电机工程与应用电子技术系, 北京 100084; 2. 中国长江三峡集团有限公司, 北京 100038)

摘要: 针对含电-氢混合储能的源网荷储系统, 为提高新能源的消纳水平并降低系统运行成本, 提出了考虑 SOC 优化设定的电-氢混合储能系统的运行优化方法, 实现系统的日前-实时优化调度。首先提出了大容量储能系统 SOC 优化设定的方法, 以确定储能系统日前的始末 SOC 优化设定值。随后, 基于双延迟深度确定性策略梯度算法, 提出了一种日前-实时优化调度模型训练方法。结合储能 SOC 的优化设定值和日前运行数据, 建立了源-网-荷-储系统的实时优化调度模型, 实现日前和实时综合优化调度。最后, 通过算例分析验证了所提运行优化方法的有效性。结果表明, 大容量储能系统的 SOC 优化设定方法可以有效提高系统收益, 日前-实时优化调度模型则在日前优化调度的基础上减少了预测误差带来的影响。

关键词: 混合储能; 氢储能系统; SOC 优化设定; 深度强化学习; 日前-实时调度

Optimal operation of an electro-hydrogen hybrid energy storage system considering SOC optimization setting

JIANG Zhilin¹, HAO Fengjie², YUAN Zhichang¹, ZHU Xiaoyi², GUO Peiqian¹, PAN Haining², XIANG Miaoyi¹, HE Ningyi¹

(1. Department of Electrical Engineering, Tsinghua University, Beijing 100084, China;

2. China Three Gorges Corporation, Beijing 100038, China)

Abstract: To enhance the efficiency of renewable energy utilization and minimize operational costs within the source-grid-load-storage system with electro-hydrogen hybrid energy storage, this paper presents an optimal operation method of electro-hydrogen hybrid energy storage system considering an SOC optimization setting to realize the day-ahead real-time optimal scheduling of the system. First, a method for SOC optimization setting of high-capacity energy storage systems is proposed to determine the day-ahead SOC optimization settings at the start and end of each day for the energy storage system. Subsequently, based on a twin delayed deep deterministic policy gradient algorithm, a day-ahead real-time optimal scheduling model training method is proposed. A real-time model for source-network-load energy storage system is established based on the optimized set points of energy storage SOC and day-ahead operation data to achieve day-ahead real-time integrated optimal scheduling. Finally, the effectiveness of the proposed method is validated through case study results. The result indicates that the method proves to be efficient in enhancing system revenue, while the day-ahead real-time optimal scheduling model mitigates the impact of prediction errors.

This work is supported by the Special Fund of National Natural Science Foundation of China (No. 52241701).

Key words: hybrid energy storage; hydrogen energy storage system; SOC optimization setting; deep reinforcement learning; day-ahead real-time scheduling

0 引言

提高新能源发电比例以及新能源消纳能力是实

现“碳达峰, 碳中和”目标的重要途径。然而, 尽管新能源发电为降低能源系统碳排放提供了有效的手段, 但其固有的不确定性和波动性也为新型电力系统的可靠、经济和高效运行带来了新的挑战^[1-3]。配置储能可以减少新能源波动带来的影响, 提高新能源发电的消纳与供电的可靠性。

基金项目: 国家自然科学基金专项项目资助(52241701); 中国长江三峡集团有限公司科研项目资助(202103417)

储能类型丰富,应用场景广泛,然而,单一类型储能已经难以同时满足新型电网对高功率、大容量、高频充放电以及经济效益的要求^[4]。《“十四五”新型储能发展实施方案》强调了加速多元储能技术的应用,推动多时间尺度新型储能技术的发展。在各类储能中,以锂电池为代表的电化学储能具有响应速度快的优势,但其成本较高,使用寿命较短,因此不适合用于大容量配置^[5]。随着电转氢(power to hydrogen, P2H)技术的发展^[6],考虑当地可再生能源资源,并结合电-氢混合储能系统,可以实现储能的优势互补效应,从而有效提升新能源电站的消纳能力,并提高其运行效率^[7-8]。

已有学者对含有氢储的混合储能系统进行了运行优化相关的研究。文献[9]针对电-氢混合储能进行了优化配置,论证了含氢储能的混合储能平抑风电波动的效果。文献[10]采用一种深度强化学习算法解决了电解槽与蓄电池储能之间的能量协调问题,实现光伏的消纳与电负荷、氢负荷的供给。进一步地,文献[11]采用鲁棒优化方法对氢储能和电储能的混合储能进行长短周期的优化调度。结合目前的研究,混合储能的应用确实可以弥补单一储能系统存在的缺陷,实现并网功率的平滑调节、调度时段内电能的优化调度等。然而,现有的关于混合储能的优化调度研究成果虽丰,但还存在两方面的局限性可作进一步改进。

1) 大容量储能的运行策略不够完善,针对大容量储能系统的日终的荷电状态(state of charge, SOC)设定值还存在优化的空间。现有研究在大容量储能的调度过程中,大多未考虑 SOC 设定优化问题。储能的 SOC 通常有两种设定方法:(1) 设定日初和日终 SOC 相等,以确保每天开始时储能处于安全状态。然而,考虑到每天新能源发电和负荷需求的变化,系统对储能的需求也随之变化,该方法无法充分发挥储能的效益。(2) 设定储能 SOC 安全范围,该方法不考虑储能 SOC 的恢复,在保证储能处于 SOC 安全状态的前提下实现一天的优化调度。然而,这种方法可能无法满足系统对储能的灵活性需求,导致在一天调度结束时,储能可能接近过充或过放状态^[12]。

2) 在计及大容量储能 SOC 优化设定策略的情况下,选择合适的日前-实时运行优化方案。目前部分研究采用日前与实时相结合的方法实现优化调度,通过日前的优化调度获取各部分的出力计划,考虑到预测误差的存在,通过实时调度来调整日前的运行计划,从而实现系统的优化运行。这些优化方案包括鲁棒优化算法、模型预测控制方法(model predictive

control, MPC)以及以强化学习(reinforcement learning, RL)为代表的基于数据驱动的实时优化方法。文献[11-13]均采用日前与实时调度相结合的方式,采用分布鲁棒优化对电-氢融合的系统进行能量调度。文献[14]将广义储能与火电联合调峰,并设置了两阶段的滚动优化调度。此外,文献[15-16]采用了基于 MPC 的方法实现日内调度的滚动优化,从而解决由预测误差引起的问题。然而,基于鲁棒优化和 MPC 的实时调度方法存在一些固有的缺陷。鲁棒优化需要对系统的不确定性进行精准的描述,因此通常结果较为保守^[17]。而 MPC 的有效性高度依赖于系统模型的准确性,否则随着时间推移,模型的准确性会降低,在最坏情况下可能无法实现优化^[18]。采用强化学习的优化方法可充分利用历史数据价值,且优化调度问题具有马尔可夫决策过程(markov decision process, MDP)的性质^[19]。基于强化学习的深度强化学习(deep reinforcement learning, DRL)采用深度神经网络替代策略函数,更容易处理高维、动作空间连续的优化问题。文献[20]采用改进的深度 Q 网络方法实现多能源微电网的能量优化,但是深度 Q 网络的动作空间离散,在高维、多动作的情况下难以进一步细化。为了解决动作空间离散的问题,文献[21]采用深度确定性策略(deep deterministic policy gradient, DDPG)实现风储系统的实时调度,可以获得连续的动作空间。然而,DDPG 算法虽然更适用于实时调度,但是该算法的训练难度较大,对初始经验池非常敏感,并容易导致 Q 值高估,因此容易收敛到边界值^[22]。双重延迟深度确定性策略梯度(twin delayed deep deterministic policy gradient, TD3)算法是一种对 DDPG 的改进算法,能在一定程度上解决 DDPG 高估导致智能体动作易收敛到边界的问题,从而降低训练难度^[23]。

结合以上两方面的问题,本文提出一种考虑混合储能 SOC 设定的日前-实时两阶段优化调度方法。采用混合储能将大容量储能(氢储能)与短时储能(电化学储能)相结合,以电能供应商最大收益为目标,实现新能源的高效消纳、负荷可靠供给以及上网功率的平滑调节。为解决大容量储能每日初始 SOC 设定的问题,构建了日前优化调度模型,运用基于深度时间聚类的方法实现储能日前 SOC 设定策略,并获取日初 SOC 设定策略以及日前的调度数据集。随后,基于该日前运行策略,采用 TD3 算法,通过学习历史数据和由历史数据获得的日前调度策略,得到了实时的调度模型,实现了考虑 SOC 优化设定的日前-实时两阶段优化调度。

1 源网荷储系统的建模

1.1 源网荷储系统的结构

含混合储能的源网荷储系统结构如图 1 所示, 新能源电站配置了氢储能与电化学储能系统, 用电负荷则由新能源电站供电。在满足并网条件的情况下, 新能源电站可实现余电上网^[24]。

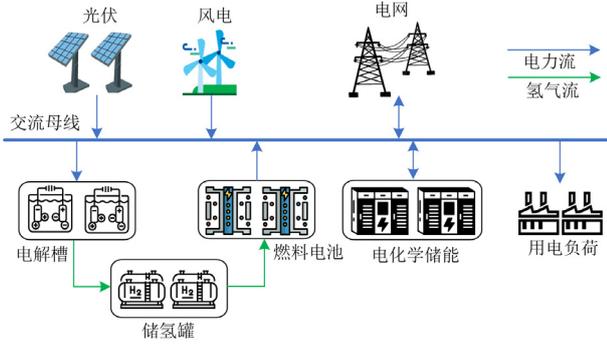


图 1 源网荷储系统结构图

Fig. 1 Structure of the source-grid-load-storage system

1.2 源网荷储系统中混合储能模型

本文研究的混合储能系统包括氢储能和电化学储能两部分。氢储能部分由碱性电解槽、储氢罐以及氢燃料电池组成, 而电化学储能则由锂电池组构成。

1) 氢储能模型

氢储能的关键设备是碱性电解槽, 其运行工况可以划分为 3 类: (1) 正常运行工况。在非极端条件下, 碱性电解槽可实现灵活的调节, 根据运行状态调节速度可以达到分钟级, 运行效率也随着输出功率呈现一定的非线性变化^[25]。(2) 高功率运行模式。碱性电解槽可在高于额定功率工况下短时运行(避免运行温度过高导致设备损坏)。通常最大运行功率可超额定功率 20%^[26]。(3) 低功率运行模式。当碱性电解槽运行功率低于 30% 额定功率时, 会面临发热严重和运行效率降低等问题^[27]。因此, 需要电解槽运行功率尽量维持在 30% 及以上, 或者将其置于停机状态。

据此, 氢储能出力约束可表示为

$$\lambda_{EL}^{\text{low}} P_{EL}^{\text{rate}} \leq P_{EL,t} \leq (1 + \lambda_{EL}^{\text{over}}) P_{EL}^{\text{rate}} \quad (1)$$

式中: $\lambda_{EL}^{\text{low}}$ 为电解槽功率下限占额定功率的百分比; $\lambda_{EL}^{\text{over}}$ 为电解槽过载运行的百分比; $P_{EL,t}$ 为电解槽在 t 时刻的功率; P_{EL}^{rate} 为电解槽的额定功率。

$$-P_{EL}^{\text{pp}} \leq m_t P_{EL,t} - m_{t-1} P_{EL,t-1} \leq P_{EL}^{\text{pp}} \quad (2)$$

$$H_{EL,t} = m_t P_{EL,t} \eta \Delta t / H_{HV} \quad (3)$$

式中: m_t 为电解槽启停的辅助参数, 为 1 时表示电解槽启动, 为 0 时表示电解槽关机; P_{EL}^{pp} 为电解槽的爬坡功率; $H_{EL,t}$ 为 t 时刻的产氢量; Δt 为单个调度时间长度; H_{HV} 为氢气的高热值, 取值为 39.89 kWh/kg; η 为电解槽的效率, 电解槽效率随着电解槽的功率变化呈现出先上升后下降的趋势^[25], 在本文设定的运行区间内, 电解槽的效率基本为线性的, 效率公式为

$$\eta = -0.18 P_{EL,t} / P_{EL}^{\text{rate}} + 0.926 \quad (4)$$

燃料电池的运行约束条件为

$$0 \leq P_{FC,t} \leq P_{FC}^{\text{max}} \quad (5)$$

$$-P_{FC}^{\text{pp}} \leq P_{FC,t} - P_{FC,t-1} \leq P_{FC}^{\text{pp}} \quad (6)$$

$$P_{FC,t} = H_{FC,t} k_{FC} \Delta t \quad (7)$$

式中: $P_{FC,t}$ 为 t 时刻氢燃料电池的功率; P_{FC}^{max} 为氢燃料电池的最大输出功率; P_{FC}^{pp} 为燃料电池的爬坡功率; $H_{FC,t}$ 为 t 时刻氢燃料电池消耗的氢气; k_{FC} 为燃料电池的氢电转换系数, 设定为 28.30 kWh/kg。

电解槽与氢燃料电池通过储氢罐进行交互, 储氢罐的约束条件为

$$S_{H_2,t} = (H_{EL,t-1} \eta_{CH} - H_{FC,t-1}) / H_{STO} + S_{H_2,t-1} \quad (8)$$

$$S_{H_2}^{\text{min}} \leq S_{H_2,t} \leq S_{H_2}^{\text{max}} \quad (9)$$

$$S_{H_2,1} = S_{H_2}^{\text{start}} \quad (10)$$

$$S_{H_2,N} = S_{H_2}^{\text{end}} \quad (11)$$

式中: $S_{H_2,t}$ 为 t 时刻储氢罐的百分比容量, 记作氢储能的 SOC; η_{CH} 为氢储能装置储氢的效率; H_{STO} 为储氢罐容量; $S_{H_2}^{\text{max}}$ 、 $S_{H_2}^{\text{min}}$ 分别为氢储能的 SOC 上下限; $S_{H_2}^{\text{start}}$ 、 $S_{H_2}^{\text{end}}$ 分别为氢储能在一天的开始与结束时的 SOC; N 为每天的调度时段总数。

电解槽启动次数约束与过载运行约束表示为

$$\sum_{t=1}^{N-1} |m_{t+1} - m_t| / 2 \leq I \quad (12)$$

$$m_t P_{EL,t} \leq (x_t + 1) P_{EL}^{\text{rate}} \quad (13)$$

$$\sum_{t=1}^{N-23} \sum_{j=1}^{24} x_{t+j} \leq 23 \quad (14)$$

式中: I 为每日限制电解槽的启停次数; x_t 为判断电解槽是否过载运行的辅助 0-1 参数。本文每 5 min 执行一次调度指令, 设定电解槽连续过载运行时间不超过 2 h。

2) 电化学储能模型

$$0 \leq P_{BAT,t}^{\text{dis}} \leq u_t^- P_{dis}^{\text{max}} \quad (15)$$

$$-u_t^+ P_{ch}^{\text{max}} \leq P_{BAT,t}^{\text{ch}} \leq 0 \quad (16)$$

$$u_t^- + u_t^+ \leq 1 \quad (17)$$

式中: u_t^+ 、 u_t^- 分别为电化学储能的充放电信号, 为 0-1 变量; $P_{\text{ch}}^{\text{max}}$ 为储能充电的最大功率; $P_{\text{dis}}^{\text{max}}$ 为电化学储能放电的最大功率; $P_{\text{BAT},t}^{\text{ch}}$ 和 $P_{\text{BAT},t}^{\text{dis}}$ 分别为 t 时刻电化学储能的充放电功率。

电化学储能 SOC 约束为

$$S_{\text{BAT},t+1} = S_{\text{BAT},t} - (P_{\text{BAT},t}^{\text{dis}}/\eta^- + P_{\text{BAT},t}^{\text{ch}}\eta^+)\Delta t/S \quad (18)$$

$$S_{\text{BAT}}^{\text{min}} \leq S_{\text{BAT},t} \leq S_{\text{BAT}}^{\text{max}} \quad (19)$$

$$S_{\text{BAT},1} = S_{\text{BAT},N} \quad (20)$$

式中: $S_{\text{BAT},t}$ 为 t 时刻电化学储能的 SOC; S 为电化学储能的容量; η^+ 和 η^- 分别为电化学储能的充放电效率; $S_{\text{BAT}}^{\text{max}}$ 、 $S_{\text{BAT}}^{\text{min}}$ 分别为电化学储能的 SOC 上下限。

3) 其他约束条件

源网荷储系统中需要考虑功率平衡, 上网功率变化率限制以及风、光出力限制, 约束条件为

$$P_{W,t} + P_{PV,t} + P_{G,t} + P_{\text{BAT},t}^{\text{dis}} + P_{\text{BAT},t}^{\text{ch}} + P_{\text{FC},t} = \quad (21)$$

$$P_{L,t} + m_t P_{\text{EL},t} \quad (21)$$

$$0 \leq P_{W,t} \leq P_{\text{WG},t} \quad (22)$$

$$0 \leq P_{PV,t} \leq P_{\text{PVG},t} \quad (23)$$

$$P_{G,t} - P_{G,t-2} \leq \Delta P_G \quad (24)$$

$$-P_G^{\text{max}} \leq P_{G,t} \leq P_G^{\text{max}} \quad (25)$$

式中: $P_{W,t}$ 、 $P_{PV,t}$ 、 $P_{G,t}$ 、 $P_{L,t}$ 分别为风电、光伏、电网出力和负荷大小; $P_{\text{WG},t}$ 、 $P_{\text{PVG},t}$ 分别为风电、光伏最大允许出力; P_G^{max} 为上网功率限制; ΔP_G 为上网功率变化率限制。

4) 目标函数

本文以日运行成本最小为目标, 运行成本包括买电成本 C_{BE} 、运维成本 C_{OP} 、弃风弃光成本 C_{AB} 、售电收益 C_{SE} 。

$$F = \min(C_{\text{BE}} + C_{\text{OP}} + C_{\text{AB}} - C_{\text{SE}}) \quad (26)$$

其中:

$$C_{\text{BE}} = \sum c_{B,t} P_{G,t} \Delta t \quad P_{G,t} > 0 \quad (27)$$

$$C_{\text{SE}} = \begin{cases} \sum (-P_{G,t} c_{S,t} + P_{L,t} c_{\text{SU},t}) \Delta t & P_{G,t} < 0 \\ \sum (P_{L,t} c_{\text{SU},t}) \Delta t & P_{G,t} \geq 0 \end{cases} \quad (28)$$

$$C_{\text{OP}} = \Delta t \sum [c_{\text{FCop}} P_{\text{FC},t} + c_{\text{ELop}} P_{\text{EL},t} + c_{\text{Wop}} P_{W,t} + c_{\text{BATop}} (P_{\text{BAT},t}^{\text{dis}} - P_{\text{BAT},t}^{\text{ch}}) + c_{\text{PVop}} P_{\text{PV},t}] \quad (29)$$

$$C_{\text{AB}} = \sum (P_{\text{WG},t} + P_{\text{PVG},t} - P_{W,t} - P_{\text{PV},t}) c_{\text{AB}} \Delta t \quad (30)$$

式中: $c_{B,t}$ 为购电电价; $c_{S,t}$ 为上网电价; $c_{\text{SU},t}$ 为向

用户的售电电价; c_{FCop} 、 c_{ELop} 、 c_{Wop} 、 c_{BATop} 、 c_{PVop} 分别为氢燃料电池、电解槽、风机、电化学储能、光伏的运行成本系数; c_{AB} 为弃风弃光惩罚系数。

2 储能系统日初/日终 SOC 设定影响分析

结合图 1 给出的系统典型结构, 选取内蒙古某源网荷储工业园区作为研究对象, 储能以及新能源容量配置模型参数如表 1 所示。

表 1 园区设备参数

类型	参数
电解槽额定功率/MW	7.5
储氢罐容量/Nm ³	6000
氢燃料电池最大功率/MW	3.5
电化学储能充放电功率/MW	2
电化学储能容量/MWh	4
风电装机/MWp	30
光伏装机/MWp	10
负荷最大功率/MW	15.1
负荷平均功率/MW	8.97
最大上网功率/MW	10

购售电分时电价以内蒙古某地的分时电价为基础, 各部分电价如表 2 所示。

表 2 购售电分时电价

Table 2 Time-of-use electricity price for purchasing and selling electricity

时段	元/kWh		
	从电网购电	向电网售电	新能源发电商售电
00:00—04:00	0.3946	0.1973	0.2960
04:00—10:00	0.4610	0.2305	0.3458
10:00—15:00	0.3946	0.1973	0.2960
15:00—17:00	0.4610	0.2305	0.3458
17:00—21:00	0.6128	0.3064	0.4596
21:00—24:00	0.4610	0.2305	0.3458

首先研究氢储能 SOC 设定对系统收益的影响, 对园区连续 48 h 的风力发电、光伏发电以及负荷用电数据进行测试。其中, 第 1 天可再生能源出力充足, 第 2 天的可再生能源出力不足。遍历第 1 天日终氢储能 SOC 设定值, 并观察两天的累计收益随第 1 天日终 SOC 变化的情况, 结果如图 2 所示。从结果可以看出, 在第 1 天日终 SOC 变化的情况下, 两天的累计收益曲线呈现出先升后降的趋势, 并且存在一个最优点。

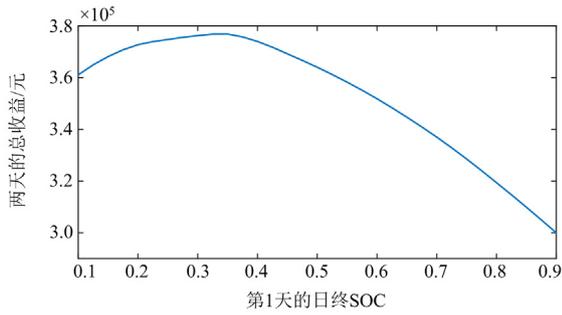


图2 累计收益随第1天日终SOC变化曲线

Fig. 2 Accumulated income with end SOC of the first day

在遍历氢储能单日日初和日终 SOC 设定的情况下, 同样可以观察到新能源供电商的收益发生了明显的变化, 且存在最优的储能 SOC 组合, 如图 3 所示。因此, 如何设定储能 SOC 并在连续多日的时间尺度下找到最优的 SOC 组合成为关键。

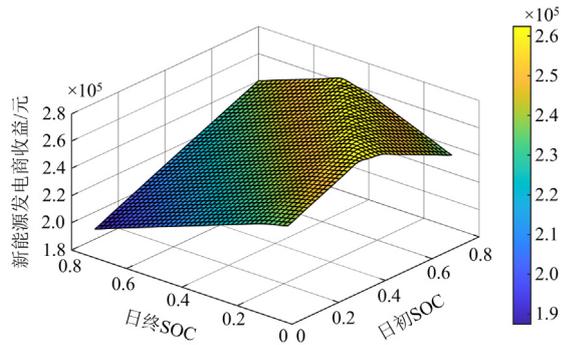


图3 单日收益随日初SOC和日终SOC的变化

Fig. 3 Returns on a single day vary with the SOC at the beginning and the end of the day

结合以上的分析结果可以得出, 氢储能日终 SOC 的设定值对优化结果产生了显著的影响。在工程实际应用中, 将储能日终 SOC 与日初 SOC 设定为固定值的方案可能无法获得最优的运行结果。另一方面, 日终 SOC 的优化值还受后续一天的风光发电以及负荷数据的影响。

3 考虑储能 SOC 设定的日前-实时优化

本文提出一种考虑氢储能 SOC 设定的日前-实时优化调度模型。日前调度通过深度时间聚类方法获得氢储能系统的 $S_{H_2}^{end}$ 设定值并开展优化; 实时调度采用深度强化学习算法将历史数据中氢储能的运行状态加入到状态空间中, 并基于一年的运行数据进行训练以获得实时优化调度模型和策略。图 4 给出了计及氢储能 SOC 优化设定的日前-实时优化方法的示意图。

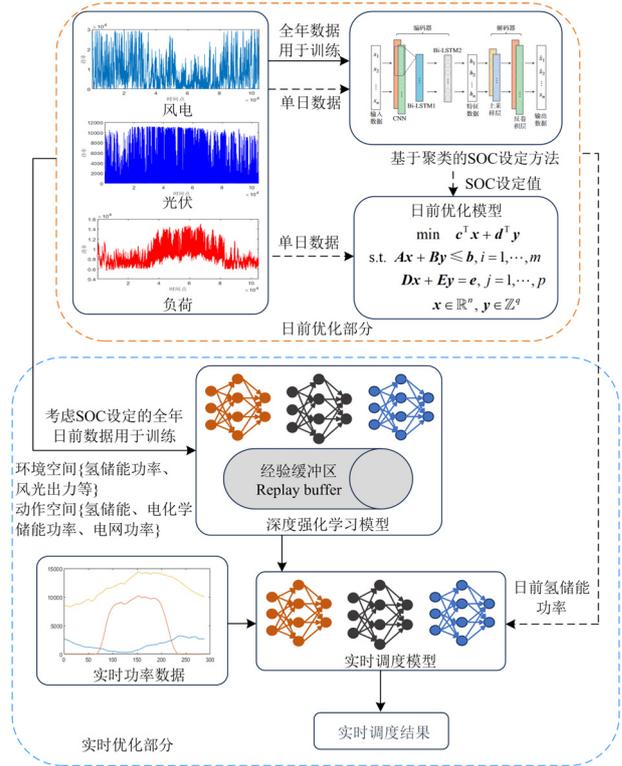


图4 日前-实时联合优化模型

Fig. 4 Joint optimization model for day-ahead and real-time scheduling

3.1 储能系统日前优化调度 SOC 设定方法

假设对第 p 天进行日前优化, 第 p 天的储能日终 SOC 确定策略主要包括以下几个步骤。

- 1) 确定优化模型。优化模型的目标可根据实际系统需求进行设定, 本文选取式(26)作为优化目标。
- 2) 历史数据的聚类。本文采用具有复杂时序特征挖掘能力的深度时间聚类方法对历史数据进行聚类^[28]。该方法采用卷积神经网络(convolutional neural network, CNN)和双向长短期记忆网络(bi-directional long short-term memory, Bi-LSTM)相结合的时序自动编码器(temporal auto encoder, TAE), 通过编码-解码的方式提取真实历史数据中时序数据特征, 并计算编码损失, 同时基于受路径约束的动态时间规整(dynamic time warping, DTW)算法对编码数据进行聚类, 并进行损失计算, 通过对损失函数进行梯度下降来更新 TAE 模型参数及聚类中心参数, 不断训练直至聚类达到收敛, 最后对完成分类的编码数据通过 TAE 进行解码重构, 获得聚类中心。

风电、光伏以及负荷 m 天的历史数据集为 $[x_1, x_2, \dots, x_i, \dots, x_{m-1}, x_m]$, 其中 x_i 为第 i 天的风电、光伏以及负荷数据。对每两天的数据 $[x_i, x_{i+1}]$ 进行聚类,

获取 K 个聚类中心 c_y , $y \in [1, K]$ 。

3) 计算日终最优 SOC 策略表。将步骤 2) 得到的 K 个两天长度的聚类中心数据代入到优化运行模型中。下面以一个聚类中心 c_y 为例, 按照式(10) 以一定的步长遍历 S_{H2}^{start} , 在 SOC 的上下限内均匀选取 J 个点, 并将第 2 天的 S_{H2}^{end} 设置为较为安全的 0.5。在遍历 S_{H2}^{start} 的情况下对 48 h 时间长度的聚类中心数据进行优化, 得到第 1 天的 S_{H2}^{end} 即为所需的 SOC 设定值, 进而得到类型 y 的日终 SOC 设定策略 $S_{H2,j}^{end}(S_{H2,j}^{start})$, $j \in [1, J]$ 。对 K 个聚类中心的数据均进行相同的操作, 即可获得一个维数为 $K \times J$ 的日终最优 SOC 策略表 $S_{H2}^{end}(S_{H2}^{start}, y)$ 。

4) 从策略表获取日终 SOC 的设定。获取未来两天的风、光和负荷的功率预测数据, 将这两天的预测值按照步骤 2) 的聚类中心进行分类, 确定种类 y , 获取当前储能 S_{H2}^{start} , 从策略表中获取最优日终 SOC 设定值 S_{H2}^{end} 。

5) 进行日前优化。根据步骤 4) 确定的日终 SOC, 求解优化模型, 计算得到未来一天的系统优化运行数据。

图 5 为储能 SOC 优化设定流程图。

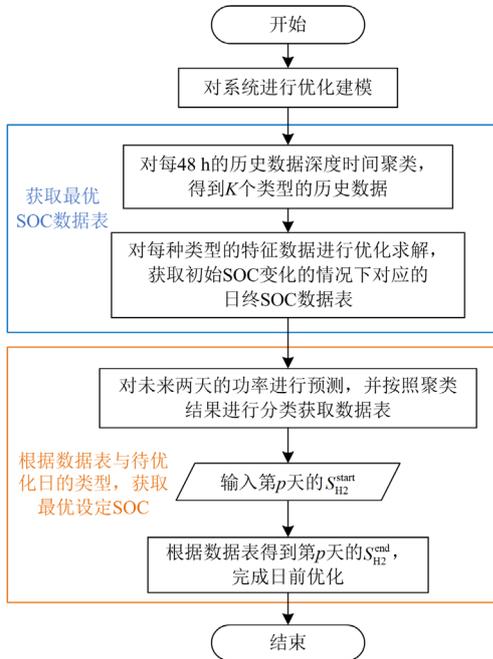


图 5 储能 SOC 优化设定流程图

Fig. 5 Flowchart of SOC optimization setting for energy storage

3.2 基于 TD3 的源网荷储系统实时优化

对于源网荷储系统, 各个储能充放电、购电、

卖电、弃风弃光等行为可以表述为马尔可夫决策过程, 通过智能体对电价、负荷大小、储能状态等作出动作, 获得对智能体动作的奖励或惩罚。本文采用 TD3 算法, 通过构建智能体与环境空间, 对智能体与环境空间的交互进行学习, 优化智能体的动作。采用深度强化学习算法对历史数据进行学习, 可以将负荷、新能源出力的不确定性学习到模型中, 从而减小对预测精准度的依赖^[29]。TD3 算法应用于本文优化模型时, 训练架构如图 6 所示。

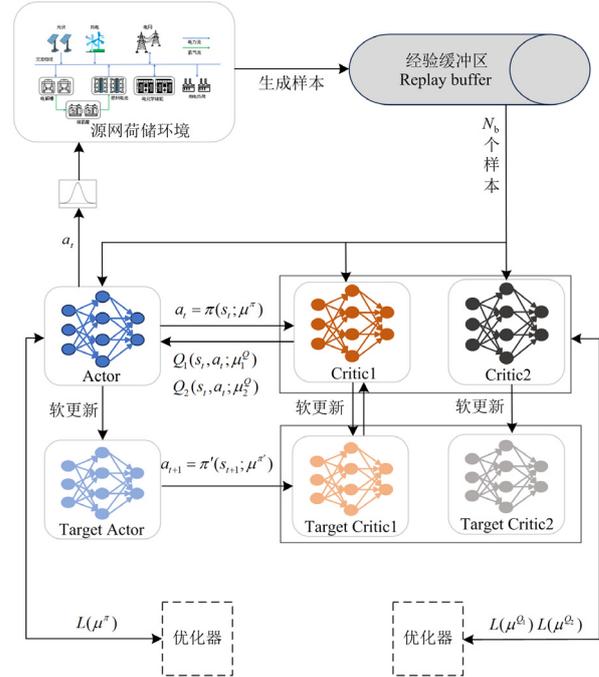


图 6 TD3 训练架构图

Fig. 6 TD3 training architecture diagram

3.3 TD3 算法的概念

TD3 算法中共包含 6 个神经网络, 分为两大类, 分别为一对 Actor-Target Actor 网络和两对 Critic-Target Critic 网络。前者输入为状态, 输出为动作, 后者输入为状态和动作, 输出为 Q 值。为了实现参数更新的稳定性, Target Actor 网络采用软更新的方式跟踪 Actor 网络参数。两对 Critic-Target Critic 网络在进行参数更新时同时计算 Q 值, 但是选取较小的 Q 值用于更新 Actor 网络, 可以缓解过度估计的问题。同时, Actor 网络的更新频率要慢于 Critic 网络, 进一步保证训练的稳定性^[23]。

实现 TD3 算法首先要构建初始经验回放池, 经验回放池中的数据为 $\{s_t, a_t, r_t, s_{t+1}, d_t\}$, 其中 s_t 为时刻 t 环境状态, a_t 为当前环境下 Actor 网络作出的动作, r_t 为时刻 t 的奖励, s_{t+1} 为时刻 $t+1$ 的环境状态, d_t 为动作终止符号。时刻 t 的动作 a_t 表示为

$$a_t = \pi(s_t; \mu^\pi) \quad (31)$$

式中, μ^π 为 Actor 神经网络权重。

在训练过程中可以对动作添加噪声, 提高智能体对环境的探索性。本文采用的噪声是 Ornstein-Uhlenbeck 噪声, Ornstein-Uhlenbeck 噪声具有时变性, 对于连续动作空间的情况可以生成更平稳的噪声^[30]。

将 a_t 以及 s_t 作为输入传递给两对 Critic 网络, 可以得到 Critic 网络的评价为 $Q_1(s_t, a_t; \mu_1^Q)$ 、 $Q_2(s_t, a_t; \mu_2^Q)$, Target Critic 网络的评价为 $Q'_1(s_t^i, a_t^i; \mu_1^{Q'})$ 、 $Q'_2(s_t^i, a_t^i; \mu_2^{Q'})$ 。更新 Critic 网络需要计算 N_b 条样本的损失函数 $L(\mu_1^Q)$ 、 $L(\mu_2^Q)$ 。

$$L(\mu_1^Q) = \frac{1}{N_b} \sum_{i=1}^{N_b} [y_t^i - Q_1(s_t^i, a_t^i; \mu_1^Q)]^2 \quad (32)$$

$$L(\mu_2^Q) = \frac{1}{N_b} \sum_{i=1}^{N_b} [y_t^i - Q_2(s_t^i, a_t^i; \mu_2^Q)]^2 \quad (33)$$

$$y_t^i = r_t^i + \gamma \min(Q'_1(s_{t+1}^i, a_{t+1}^i; \mu_1^{Q'}), Q'_2(s_{t+1}^i, a_{t+1}^i; \mu_2^{Q'})) \quad (34)$$

式中: r_t^i 为第 i 个样本在 t 时刻的奖励; γ 为折扣率; μ_1^Q 、 μ_2^Q 为两个 Critic 网络的权重; $\mu_1^{Q'}$ 、 $\mu_2^{Q'}$ 为两个 Target Critic 网络的权重; s_t^i 为第 i 个样本在时刻 t 的环境参数; a_{t+1}^i 为第 i 个样本在时刻 $t+1$ 由 Target Actor 网络产生的动作, 即 $\pi(s_{t+1}^i; \mu^\pi)$, μ^π 为 Target Actor 网络权重。

Actor 网络的目标为最大化输出动作的 Q 值, 需要计算的损失函数为

$$L(\mu^\pi) = -\frac{1}{N_b} \sum_{i=1}^{N_b} Q_1(s_t^i, \pi(s_t^i; \mu^\pi); \mu_1^Q) \quad (35)$$

通过梯度下降法更新 Actor 和 Critic 网络的权重, 同时采用软更新的方法将 Actor 和 Critic 网络权重更新到 Target Actor 网络和 Target Critic 网络中。

$$\lambda \mu_1^Q + (1-\lambda) \mu_1^{Q'} \rightarrow \mu_1^Q \quad (36)$$

$$\lambda \mu_2^Q + (1-\lambda) \mu_2^{Q'} \rightarrow \mu_2^Q \quad (37)$$

$$\lambda \mu^\pi + (1-\lambda) \mu^{\pi'} \rightarrow \mu^\pi \quad (38)$$

式中, λ 为软更新系数, 通常设定 $0 < \lambda \ll 1$ 。

3.4 实时调度动作空间与状态空间的构建

结合第 3.2 节中储能 SOC 动态设定的日前优化结果, 采用 TD3 算法对源网荷储系统进行实时优化运行训练和调度, 首先需要构建 TD3 算法的动作空间和状态空间。

1) 动作空间构建

在本文的源网荷储系统中, 需要优化确定的数据为电解槽功率 $P_{EL,t}$ 、氢燃料电池功率 $P_{FC,t}$ 、电化学储能的充放电功率 $P_{BAT,t}^{ch}$ 、 $P_{BAT,t}^{dis}$ 和电网功率 $P_{G,t}$ 。

为了降低动作空间维度, 提升训练的速度与效果, 设置动作空间为

$$a_t = (P_{H,t}, P_{BAT,t}, P_{G,t}) \quad (39)$$

式中: $P_{H,t}$ 表示氢储能在 t 时刻的充放电功率; $P_{BAT,t}$ 表示电化学储能在 t 时刻的充放电功率。

2) 状态空间构建

深度强化学习的状态空间反映智能体作出动作之后环境中状态变量达到的状态, 在本文的源网荷储系统中, 风机出力 $P_{W,t}$ 、光伏出力 $P_{PV,t}$ 、负荷大小 $P_{L,t}$ 、储氢罐状态 $S_{H2,t}$ 和电化学储能荷电状态 $S_{BAT,t}$ 可以作为状态空间。此外, 由于氢储能容量较大, 在日前调度中考虑了 SOC 的设定问题。并且氢储能的调节速度要低于电化学储能, 考虑将日前的氢储能出力作为环境变量, 在实时调度过程中保持氢储能出力不发生大的改变。由预测误差导致的出力误差经由电化学储能进行调节。因此本文的状态空间可以表示为

$$s_t = (P_{W,t}, P_{PV,t}, P_{L,t}, P_{H,t}^{ahead}, S_{H2,t}, S_{BAT,t}) \quad (40)$$

式中, $P_{H,t}^{ahead}$ 为氢储能的日前运行状态。TD3 模型输入 s_t 可以得到当前状态下合理的 a_t , 同时得到当前状态下的奖励 r_t , 并得到下一个时刻的状态 s_{t+1} 。

3) 奖励与惩罚函数的构建

在使用强化学习进行优化问题求解时, 强化学习的奖励函数与数学优化问题中的目标函数起到类似的作用。对于本文的源网荷储系统, 在构建奖励函数时, 参考 1.2 节目标函数部分。

奖励函数包含售电奖励 $r_{1,t}$, 表示为

$$r_{1,t} = \begin{cases} (-c_{S,t} P_{G,t} + c_{SU,t} P_{L,t}) \Delta t & P_{G,t} < 0 \\ c_{SU,t} P_{L,t} \Delta t & P_{G,t} \geq 0 \end{cases} \quad (41)$$

在功率平衡约束式(21)中添加 $P_{DIS,t}$ 表示弃电量和功率缺额, $P_{DIS,t}$ 大于 0 时意味着存在弃电, 小于 0 时意味着存在功率缺额。调整之后的功率平衡公式为

$$P_{W,t} + P_{PV,t} + P_{G,t} + P_{BAT,t} + P_{H,t} = P_{L,t} + P_{DIS,t} \quad (42)$$

惩罚函数包含购电惩罚 $d_{1,t}$ 、设备运行惩罚 $d_{2,t}$ 、弃电惩罚 $d_{3,t}$ 、功率不平衡惩罚 $d_{4,t}$ 、氢储能日前-实时偏差惩罚 $d_{5,t}$ 、储氢罐状态越限惩罚 $d_{6,t}$ 、电化学储能 SOC 越限惩罚 $d_{7,t}$ 和电化学储能 SOC 日终偏差惩罚 $d_{8,t}$ 。各个惩罚函数表示为

$$d_{1,t} = c_{B,t} P_{G,t} \Delta t \quad P_{G,t} \geq 0 \quad (43)$$

$$d_{2,t} = (c_{Hop} |P_{H,t}| + c_{Wop} P_{W,t} + c_{BATop} |P_{BAT,t}| + c_{PVop} P_{PV,t}) \Delta t \quad (44)$$

$$d_{3,t} = c_{AB} P_{DIS,t} \Delta t \quad P_{DIS,t} > 0 \quad (45)$$

$$d_{4,t} = -c_{SH} P_{DIS,t} \Delta t \quad P_{DIS,t} \leq 0 \quad (46)$$

$$d_{5,t} = c_H |P_{H,t} - P_{H,t}^{ahead}| \Delta t \quad (47)$$

$$d_{6,t} = \begin{cases} \beta_H P_{H,t} & \text{if } S_{H2,t+1} < S_{H2}^{\min} \\ -\beta_H P_{H,t} & \text{if } S_{H2,t+1} > S_{H2}^{\max} \end{cases} \quad (48)$$

$$d_{7,t} = \begin{cases} \beta_{BAT} P_{BAT,t} & \text{if } S_{BAT,t+1} < S_{BAT}^{\min} \\ -\beta_{BAT} P_{BAT,t} & \text{if } S_{BAT,t+1} > S_{BAT}^{\max} \end{cases} \quad (49)$$

$$d_{8,t} = \beta_{END} (S_{BAT,t} - S_{BAT,l}) \quad \text{if } d_t = \text{True} \quad (50)$$

式中: c_{SH} 为功率不平衡惩罚系数; c_H 为氢储能日前与实时动作偏差惩罚系数; β_H 氢储能越限惩罚系数; β_{BAT} 为电化学储能越限惩罚系数; d_t 为布尔型变量, 当 d_t 为 True 时表示调度结束; β_{END} 为调度结束时氢储能 SOC 偏差惩罚系数。

最终的奖励函数 r_t 如式(51)所示。

$$r_t = r_{1,t} - \sum_{i=1}^8 d_{i,t} \quad (51)$$

3.5 训练数据、经验缓冲区的初始化

TD3 模型进行训练时, 需要对经验缓冲区添加初始化的数据, 在强化学习中, 经验缓冲区数据的优劣对训练效果影响非常大。初始化数据不好可能导致训练过程中梯度消失、收敛到动作的边界或者训练过慢的现象出现。

首先采用本文所提储能系统 SOC 设定策略对测试集的数据进行优化设定。根据氢储能 SOC 的优化设定值, 对测试集每天的数据进行日前优化调度, 获取测试集的运行数据。基于测试集的运行数据, 生成样本数据 $\{s_t, a_t, r_t, s_{t+1}, d_t\}$, 然后将样本数据填入到经验缓冲区中, 作为初始化经验缓冲区的数据。

在训练过程中, 采用单一经验池具有一定的局限性。由于一天的调度动作很长, 每天的调度动作有 288 步, 经验池中缺少调度结束时的数据, 因此考虑增加调度结束经验池, 在进行经验回放的过程中, 从调度结束经验池中抽取一部分数据进行网络更新。此外, 由于经验池的容量有限, 在进行训练的过程中, 加入的新数据会挤出旧数据, 然而旧数据可能比新加入的数据质量更高, 反而会降低训练的效率, 因此考虑将日前优化调度数据添加到日前调度经验池中, 将训练过程产生的数据添加到探索经验池中。

4 算例分析

日前优化调度计算采用 Matlab R2019b, 通过 Gurobi 9.5 求解器求解。基于 TD3 的实时优化调度

模型的训练环境为 Python 3.7.16 与 Pytorch 1.13.1, 通过 CPU i5-11400H 与 GPU RTX3050 训练。

4.1 日前优化运行算例分析

日前优化运行测试采用含新能源发电的内蒙古某工业园区的运行数据, 共 364 天, 数据采样间隔为 5 min。在使用深度时间聚类时需要采用手肘法确定编码数据的聚类数目, 聚类得到的各个数据的数量见表 3。

表 3 各种类型数据的数量

类型	1	2	3	4	5	6	7	8	9	10
数量	28	18	23	47	42	19	36	68	17	66

首先测试时间段 1, 共 30 天, 将处理好的测试数据根据聚类质心进行分类, 通过比较测试集数据与各质心的欧氏距离来判断测试集数据所属类别。根据分类的结果, 按照第 3 节中日终 SOC 的确定策略对其进行计算, 设定第 1 天的日初 SOC 为 0.5, 得到剩余连续日期的日终 SOC, 结果见表 4。

表 4 日终 SOC 的确定值

日期	1	2	3	4	5	6
日终 SOC	0.42	0.66	0.51	0.33	0.15	0.69
日期	7	8	9	10	11	12
日终 SOC	0.22	0.34	0.26	0.10	0.28	0.32
日期	13	14	15	16	17	18
日终 SOC	0.54	0.42	0.32	0.63	0.77	0.35
日期	19	20	21	22	23	24
日终 SOC	0.28	0.83	0.72	0.39	0.39	0.81
日期	25	26	27	28	29	30
日终 SOC	0.46	0.23	0.67	0.83	0.30	0.73

下面对所提算法的效果进行测试, 并对比传统 SOC 的设定方法和本文所提方法的效果。

1) 传统方法设定储能系统的日终 SOC 和日初 SOC 均为 0.5, 测试 30 天累计收益的优化结果。

2) 采用本文所提设定方法, 按照表 4 中的储能日终 SOC 确定值进行数据测试, 并获取 30 天累计收益的优化结果。

采用传统 SOC 设定方法和本文所提 SOC 优化设定方法得到的累计收益结果如图 7 所示。通过传统的储能 SOC 设定方法得到 30 天的累计收益为 850.89 万元。当采用本文提出的 SOC 优化设定方法时, 30 天的总收益升至 922.55 万元, 相较传统方法增加了 71.66 万元, 提升了 8.42%。据此, 通过对氢储能 SOC 的日前优化设定, 可以在连续多日的时间尺度下优化源网荷储系统的电能调度。考虑氢储

能 SOC 优化设定的累计收益要明显高于传统氢储能 SOC 设定的累计收益。

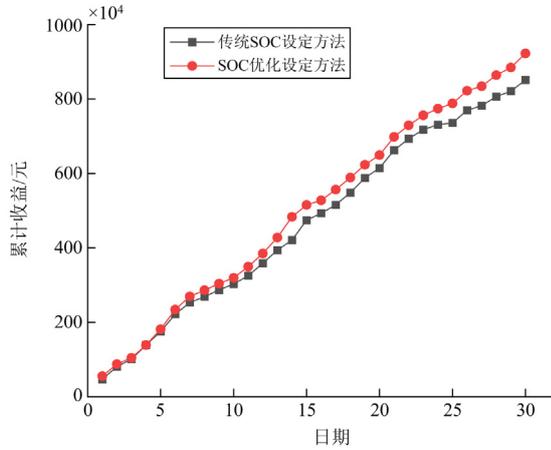


图7 累计收益效果对比

Fig. 7 Comparison of cumulative returns

4.2 基于 TD3 的实时优化模型训练

采用的 TD3 算法包含 3 对神经网络, 其中 Actor 和双 Critic 网络为全连接网络, 网络的参数如表 5 所示。

表 5 TD3 网络参数

Table 5 TD3 network parameters

参数	Actor 网络	Critic1 网络	Critic2 网络
隐藏层数	2	2	2
神经元数	[128,64]	[128,64]	[128,64]
隐藏层 激活函数	Leakyrelu(0.01)	Leakyrelu(0.01)	Leakyrelu(0.01)
输出层 激活函数	Softsign	—	—
初始学习率	5×10^{-4}	1×10^{-3}	1×10^{-3}

训练过程中采用了 3 个经验池, 其中调度结束经验池大小为 2000、探索经验池大小为 200 000、日前初始经验池大小为 100 000。Actor 网络设定为比 Critic 网络延迟 4 轮进行更新, 网络的软更新系数为 0.1。开始训练前, 首先将日前的全年优化数据生成样本, 分别填入到调度结束经验池以及日前调度经验池。开始训练后, 每次抽取 N_0 条样本数据输入到 Actor 网络和环境, 生成新的样本数据填入到探索经验池。由于调度过程的先后对调度的优劣没有影响, 因此设定折扣率 γ 为 1。

选取其中 344 天的风电、光伏、负荷以及氢储能运行功率数据进行训练, 剩余 20 天的数据则作为测试集进行测试。考虑到每天的调度奖励存在差异, 因此将 Actor 神经网络的权重作为训练收敛的依据。当 Actor 神经网络权重的绝对值之和不再变化

时, 可认为训练已经收敛。图 8 为训练过程中权重的变化, 可以判定在训练达到 700 轮左右时已基本收敛。

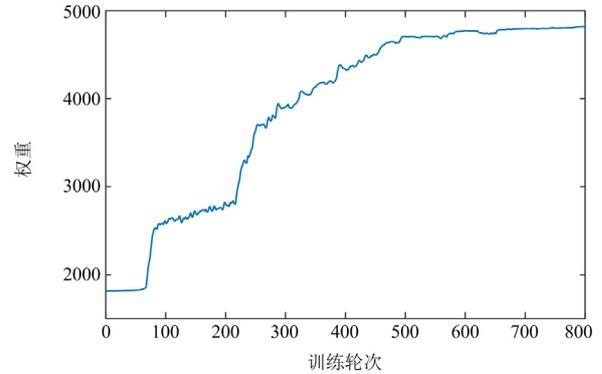


图8 训练权重变化曲线

Fig. 8 Training weight change curve

4.3 实时调度与日前调度对比

经过训练得到的实时调度模型在获取实时调度策略时采用表 6 所示的流程。

表 6 实时调度策略

Table 6 Real-time scheduling strategy

实时调度策略流程

1. 获取日前 SOC 设定值: 获取日前预测数据, 根据初始氢储能 SOC 以及 SOC 设定方法获取氢储能的日终 SOC。
2. 根据日前优化模型获取日前的优化运行数据, 得到氢储能的出力作为实时调度的环境数据。
3. 对于任意时刻 t , 获取当前时刻的风电、光伏以及负荷数据, 结合日前的氢储能出力, 通过 Actor 网络获取实时调度策略。
4. 每 5 min 获取一次实时调度策略, 完成一天的实时调度, 一天运行结束时, 氢储能的 SOC 作为下一天初始氢储能 SOC, 从步骤 1 重新开始。

在进行日前优化调度时, 需要采用日前的预测数据。由于进行功率预测并不是本文的重点内容, 因此本文采用已有的功率预测结果。

对测试集数据进行测试时, 首先对 20 天的测试集数据进行连续的前日优化调度, 考虑储能 SOC 的设定, 得到连续的前日优化调度数据。然后采用实时调度模型获取实时调度数据并进行比较。图 9 为集中部分天数的系统日前优化调度的结果, 图 10 为系统的实时优化调度结果。

实时调度结果与日前调度结果, 由于将日前氢储能出力作为实时调度氢储能出力的参考, 因此氢储能相比于日前调度计划中的氢储能出力有相近的部分。在实时调度中, 氢储能和电化学储能均会在电价低谷时段(1—8 h、97—104 h)进行充电, 并在新能源发电短缺或电价较高时(14—20 h、111—117 h)放电, 供给电能需求、提高系统收益。此外,

实时调度结果中,氢储能的出力更加平滑,更符合实际系统中的运行状态。经过测试,依据日前优化调度策略可以获得的累计收益为728.05万元,依据实时优化调度策略可以获得的累计收益为780.68万元。

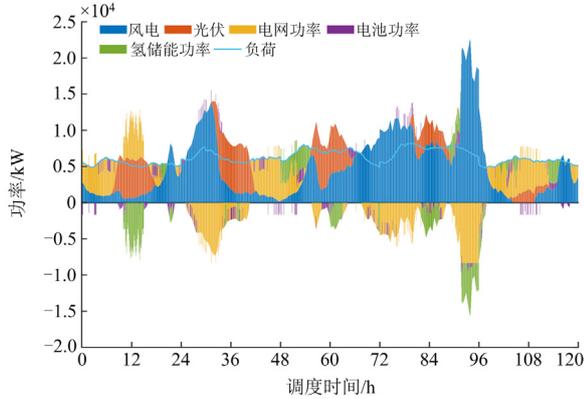


图9 部分天数日前调度结果

Fig. 9 Day-ahead scheduling results for some days

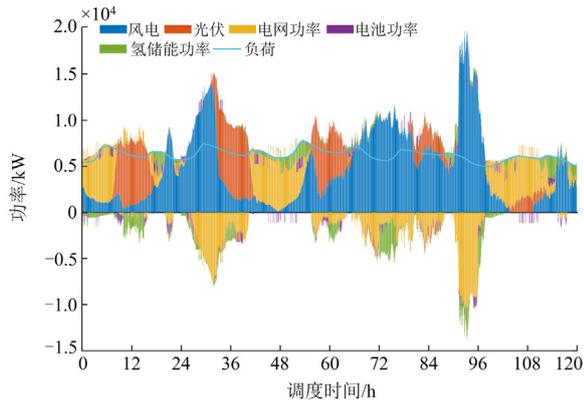


图10 部分天数实时调度结果

Fig. 10 Real-time scheduling results for some days

4.4 与滚动优化的对比分析

下面将本文提出的基于深度强化学习的日前-实时优化调度方法与两阶段滚动优化方法进行对比,以下分别称为方法1和方法2。方法2的具体方式见附录A。基于方法2,同时考虑日前氢储能SOC的设定作为方法3,对这3种优化调度方法进行测试。3种方法的前日优化阶段均需要采用日前的预测数据,方法1的实时调度层需要获取实时的功率数据,测试时采用实际出力数据。方法2、3的日内阶段需要获取日内的超短期预测数据,本文采用在实际数据上叠加噪声的方式实现^[12],加上期望为0、标准差为实际值与预测误差乘积的白噪声。两种运行策略在测试集累计的运行成本、损失费用、买电成本、卖电收益、总利润如表7所示。

表7 3种方法数据对比

Table 7 Comparison of results from three methods

各种费用	万元		
	方法1	方法2	方法3
买电成本	220.31	242.86	227.13
卖电收益	999.04	967.76	981.56
运行成本	2.01	2.88	2.18
损失费用	1.35	3.19	1.48
总利润	775.37	718.83	750.77

通过以上结果可以看出,本文提出的基于TD3深度强化学习的前日-实时优化调度模型因考虑了氢储能SOC设定,在累计利润方面,相比于传统SOC设定的两阶段滚动优化以及考虑了氢储能SOC设定的两阶段滚动优化都有一定的提升。在考虑氢储能SOC动态设定的情况下,系统更高效地利用了氢储能,从而使得系统的运行成本更小。

此外,使用基于深度强化学习的优化调度模型只需要调用神经网络进行简单的计算,相比于求解器求解的方式具有更快的求解速度,更适用于需要实时响应的实时调度场景。

5 结论

本文以含风光新能源发电及含氢储能的混合储能的源网荷储系统为研究对象,以系统最小运行成本为目标,构建了基于深度强化学习的前日-实时的联合优化调度模型。

在日前优化调度阶段,提出了大容量储能设备SOC的优化设定方法,在连续多日的时间尺度下采用SOC的优化设定能进一步提高系统的运行效率。基于提出的SOC优化设定方法对历史数据进行预处理,用于对基于TD3的实时优化调度模型进行训练,得到了实时优化调度模型。在进行日前-实时优化调度时,获取日前的容量储能出力值作为实时优化调度的参考值,实时调度过程中混合储能可以对新能源出力的不确定性作出调整。算例分析表明,本文提出的日前-实时联合优化调度模型能有效降低系统的运行成本,提高系统的运行收益,提高对储能的使用效率。

本文的工作还存在不足之处,TD3的环境参数设计、训练超参数以及训练方式还有进一步优化的空间,还需要进一步推进在实际工程中的应用。

附录A

方法2的两阶段优化模型中包含日前优化模型与日内滚动优化调度模型。

(a) 日前优化模型采用式(1)一式(30)的优化模

型, 日前调度策略包含氢储能运行策略、电化学储能运行策略、电量上网与供电策略。

(b) 日内滚动优化模型根据剩余时段日前的风电、光伏功率以及负荷功率, 同时获取未来 1 h 更精确的超短期预测结果, 作为优化调度模型的输入数据。日内以日前调度策略得到的氢储能运行功率作为参考, 添加氢储能出力调整惩罚项 C_{PUN} , 表示为

$$C_{\text{PUN}} = \beta(P_{\text{EL},n}^{\text{ref}} + P_{\text{FC},n}^{\text{ref}} - P_{\text{EL},n} - P_{\text{FC},n})^2 \quad (\text{A1})$$

式中: β 为氢储能出力调整惩罚系数; $P_{\text{EL},t}^{\text{ref}}$ 、 $P_{\text{FC},t}^{\text{ref}}$ 分别为日前电解槽和氢燃料电池出力。

日内滚动优化模型的目标函数修改为式(A2)。

$$F = \min(C_{\text{BE}} + C_{\text{OP}} + C_{\text{AB}} - C_{\text{SE}} + C_{\text{PUN}}) \quad (\text{A2})$$

每次滚动优化调度获取未来 1 h 的调度策略, 不断对剩余时段进行优化。

参考文献

- [1] 余鹏飞, 朱继忠, 熊小伏, 等. 基于储能的电力系统安全调控方法[J]. 电力系统保护与控制, 2023, 51(19): 173-186.
YU Pengfei, ZHU Jizhong, XIONG Xiaofu, et al. Regulating & control method of power system security based on battery energy storage[J]. Power System Protection and Control, 2023, 51(19): 173-186.
- [2] 潘旭, 王会超, 王建中, 等. 基于优先消纳新能源的电网调峰难度分析指标体系研究[J]. 供用电, 2023, 40(2): 78-84.
PAN Xu, WANG Huichao, WANG Jianzhong, et al. Index system research on difficulty analysis of power grid peak shaving with priority consumption of new energy[J]. Distribution & Utilization, 2023, 40(2): 78-84.
- [3] 上官甲天, 茅云寿. 计及新能源不确定性微能源网优化运行研究[J]. 供用电, 2023, 40(8): 92-99.
SHANGGUAN Jiatian, MAO Yunshou. Optimal operation of micro-energy networks considering new energy uncertainty[J]. Distribution & Utilization, 2023, 40(8): 92-99.
- [4] 郭佩乾, 郝峰杰, 袁志昌, 等. 混合多类型储能的分布式能源系统运行优化方法[J/OL]. 南方电网技术: 1-11[2023-10-22]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20230913.2328.008.html>.
GUO Peiqian, HAO Fengjie, YUAN Zhichang, et al. Operational optimization method for distributed energy systems with hybrid multi-type energy storage[J]. Southern Power System Technology: 1-11[2023-10-22]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20230913.2328.008.html>.
- [5] ZIA M F, ELBOUCHIKHI E, BENBOUZID M. Optimal operational planning of scalable DC microgrid with demand response, islanding, and battery degradation cost considerations[J]. Applied Energy, 2019, 237: 695-707.
- [6] ABOMAZID A M, EL-TAWEEL N A, FARAG H E Z. Optimal energy management of hydrogen energy facility using integrated battery energy storage and solar photovoltaic systems[J]. IEEE Transactions on Sustainable Energy, 2022, 13(3): 1457-1468.
- [7] 李蕊睿, 李奇, 蒲雨辰, 等. 计及功率交互约束的含电-氢混合储能的多微电网系统容量优化配置[J]. 电力系统保护与控制, 2022, 50(14): 53-64.
LI Ruirui, LI Qi, PU Yuchen, et al. Optimal configuration of an electric-hydrogen hybrid energy storage multi-microgrid system considering power interaction constraints[J]. Power System Protection and Control, 2022, 50(14): 53-64.
- [8] PEI W, ZHANG X, DENG W, et al. Review of operational control strategy for DC microgrids with electric-hydrogen hybrid storage systems[J]. CSEE Journal of Power and Energy Systems, 2022, 8(2): 329-346.
- [9] 袁铁江, 郭建华, 杨紫娟, 等. 平抑风电波动的电-氢混合储能容量优化配置[J/OL]. 中国电机工程学报: 1-10[2023-11-22]. DOI:10.13334/j.0258-8013.pcsee.222572.
YUAN Tiejia, GUO Jianhua, YANG Zijuan, et al. Optimal allocation of power electric-hydrogen hybrid energy storage of stabilizing wind power fluctuation[J]. Proceedings of the CSEE: 1-10[2023-11-22]. DOI:10.13334/j.0258-8013.pcsee.222572.
- [10] KANG D, KANG D, HWANGBO S, et al. Optimal planning of hybrid energy storage systems using curtailed renewable energy through deep reinforcement learning[J]. Energy, 2023, 284: 128623.
- [11] 赵波, 王文博, 陈哲, 等. 计及长短周期混合储能的多微网能量-功率分布鲁棒优化[J]. 电力系统自动化, 2023, 47(16): 22-33.
ZHAO Bo, WANG Wenbo, CHEN Zhe, et al. Energy-power distributionally robust optimization for multi-energy microgrid considering long short-term hybrid energy storage[J]. Automation of Electric Power Systems, 2023, 47(16): 22-33.
- [12] 黄弦超, 封钰. 考虑机组灵活性的独立微网日前日内协调优化调度[J]. 电力自动化设备, 2020, 40(4): 125-131.
HUANG Xianchao, FENG Yu. Day-ahead and intra-day coordinated optimal scheduling of stand-alone microgrid considering unit flexibility[J]. Electric Power Automation Equipment, 2020, 40(4): 125-131.
- [13] QIU Y, LI Q, AI Y, et al. Two-stage distributionally robust optimization-based coordinated scheduling of integrated energy system with electricity-hydrogen hybrid energy storage[J]. Protection and Control of Modern Power Systems, 2023, 8(2): 542-555.

- [14] 崔杨, 周慧娟, 仲悟之, 等. 考虑广义储能与火电联合调峰的日前-日内两阶段滚动优化调度[J]. 电网技术, 2021, 45(1): 10-20.
CUI Yang, ZHOU Huijuan, ZHONG Wuzhi, et al. Two-stage day-ahead and intra-day rolling optimization scheduling considering joint peak regulation of generalized energy storage and thermal power[J]. Power System Technology, 2021, 45(1): 10-20.
- [15] 王磊, 周建平, 朱刘柱, 等. 基于分布式模型预测控制的综合能源系统多时间尺度优化调度[J]. 电力系统自动化, 2021, 45(13): 57-65.
WANG Lei, ZHOU Jianping, ZHU Liuzhu, et al. Multi-time-scale optimization scheduling of integrated energy system based on distributed model predictive control[J]. Automation of Electric Power Systems, 2021, 45(13): 57-65.
- [16] 李振坤, 李一骄, 宋德毅, 等. 独立型微电网日前与日内协调优化调度[J]. 电力科学与技术学报, 2018, 33(2): 50-58.
LI Zhenkun, LI Yijiao, SONG Siyi, et al. Multi-time scale optimal dispatch of isolated microgrid based on model predictive control[J]. Journal of Electric Power Science and Technology. 2018, 33(2): 50-58.
- [17] BEN-TAL A, NEMIROVSKI A. Robust solutions of uncertain linear programs[J]. Operations Research Letters, 1999, 25(1): 1-13.
- [18] ZHAO H, WU Q, HU S, et al. Review of energy storage system for wind power integration support[J]. Applied Energy, 2015, 137: 545-553.
- [19] SIGAUD O, BUFFET O. Markov decision processes in artificial intelligence[M]. New York: John Wiley & Sons, 2013.
- [20] XIAO H, PU X, PEI W, et al. A novel energy management method for networked multi-energy microgrids based on improved DQN[J]. IEEE Transactions on Smart Grid, 2023, 14(6): 4912-4926.
- [21] 宋煜浩, 魏韡, 黄少伟, 等. 风储联合电站实时自调度的高效深度确定性策略梯度算法[J]. 电工技术学报, 2022, 37(23): 5987-5999.
SONG Yuhao, WEI Wei, HAUNG Shaowei, et al. Efficient deep deterministic policy gradient algorithm for real-time self-dispatch of wind-storage power plant[J]. Transactions of China Electrotechnical Society, 2022, 37(23): 5987-5999.
- [22] 徐博涵, 向月, 潘力, 等. 基于深度强化学习的含高比例可再生能源配电网就地分散式电压管控方法[J]. 电力系统保护与控制, 2022, 50(22): 100-109.
XU Bohan, XIANG Yue, PAN Li, et al. Local decentralized voltage management of a distribution network with a high proportion of renewable energy based on deep reinforcement learning[J]. Power System Protection and Control, 2022, 50(22): 100-109.
- [23] FUJIMOTO S, HOOF H, MEGER D. Addressing function approximation error in actor-critic methods[C] // 35th International Conference on Machine Learning, July 10-15, 2018, Stockholm, Sweden: 1587-1596.
- [24] 国家电网公司. 光伏发电系统接入配电网技术规定: GB/T 29319—2012[S]. 北京: 中国标准出版社, 2012.
- [25] 邓智宏, 江岳文. 考虑制氢效率特性的风氢系统容量优化[J]. 可再生能源, 2020, 38(2): 259-266.
DENG Zhihong, JIANG Yuewen. Optimal sizing of a wind-hydrogen system under consideration of the efficiency characteristics of electrolysers[J]. Renewable Energy Resources, 2020, 38(2): 259-266.
- [26] SHEN X, ZHANG X. Mathematical modeling and simulation for external electrothermal characteristics of an alkaline water electrolyzer[J]. International Journal of Energy Research, 2018, 42(12): 3899-3914.
- [27] AKARSU B, SERDAR GENÇ M. Optimization of electricity and hydrogen production with hybrid renewable energy systems[J]. Fuel, 2022, 324: 124465.
- [28] 庄颖睿, 程林, 齐宁, 等. 基于深度时间聚类的微电网典型场景生成方法[J]. 电力系统自动化, 2023, 47(20): 95-103.
ZHUANG Yingrui, CHENG Lin, QI Ning, et al. Typical scenario generation algorithm for microgrid based on deep temporal clustering[J]. Automation of Electric Power Systems, 2023, 47(20): 95-103.
- [29] ZHAO J, LI F, 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.
- [30] LILLICRAP T P, HUNT J J, PRITZEL A, et al. Continuous control with deep reinforcement learning[C] // 4th International Conference on Learning Representations, May 2-4, 2016, San Juan, Puerto Rico: 1-15.

收稿日期: 2023-10-24; 修回日期: 2024-03-01

作者简介:

姜智霖(1997—), 男, 硕士研究生, 主要研究方向为新能源电力系统运行优化; E-mail: jiang_zl17@163.com

郝峰杰(1987—), 男, 博士, 高级工程师, 主要研究方向为电力系统优化运行、电能质量治理; E-mail: hao_fengjie@ctg.com.cn

袁志昌(1980—), 男, 通信作者, 博士, 副研究员, 主要研究方向为柔性交直流输电、电池储能系统。E-mail: yuanzc@tsinghua.edu.cn

(编辑 许威)