

基于近端策略优化的火电商参与 电能量-调频联合市场竞价策略

张斌¹, 曹蕃², 肖坤¹, 宋寅², 郭瑛², 叶宇剑¹, 许德智¹

(1. 东南大学电气工程学院, 南京市 210096; 2. 中国大唐集团科技创新有限公司, 北京市 100033)

摘要:【目的】随着新电改政策的深入实施和“双碳”目标的推进, 新能源在电力系统中的渗透率不断提高。高比例新能源接入虽然有助于清洁能源转型, 但也带来了显著的电价波动与市场不确定性风险, 尤其对依赖现货交易的发电商而言, 报价策略制定的复杂性大幅增加。针对传统火电企业及多类型能源主体在电能量与调频辅助服务联合市场中如何制定最优报价策略的问题, 提出了一种基于近端策略优化(proximal policy optimization, PPO)的报价策略优化方法。【方法】首先, 构建包含多类型发电资源参与的电能量-调频联合市场双层优化模型, 并且考虑新能源配储, 通过投标过程中的充放电调节实现价格平抑, 提升风储联合体等市场主体的风险应对能力: 上层发电商以利润最大化为目标制定报价策略; 下层市场出清模型以系统运行成本最小化为目标实现联合调度。其次, 将报价问题转化为马尔可夫决策过程(Markov decision process, MDP), 引入深度强化学习(deep reinforcement learning, DRL)框架, 并利用PPO算法实现报价策略的自主学习与动态优化。【结果】通过典型算例将所提方法与理论最优解进行对比, 验证了其在提升火电企业收益、平抑新能源价格波动风险、降低市场运行成本及提升调频效率方面的优势。【结论】该方法在联合市场环境中表现出更优的策略经济性与更高的实时计算效率。

关键词: 发电商报价; 电力市场风险应对; 深度强化学习(DRL); 近端策略优化(PPO); 演员-批评家结构

中图分类号: TM611

文献标志码: A

文章编号: 1000-7229(2026)04-0082-11

DOI: 10.12204/j.issn.1000-7229.2026.04.007

Proximal Policy Optimization-based Bidding Strategy for Thermal Power Generators Participating in Energy and Frequency Regulation Markets

ZHANG Bin¹, CAO Fan², XIAO Kun¹, SONG Yin², GUO Ying², YE Yujian¹, XU Dezhi¹

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China;

2. China Datang Group Technology Innovation Co., Ltd., Beijing 100033, China)

ABSTRACT: [Objective] With China's ongoing electricity market reforms and the pursuit of carbon peaking and neutrality goals, renewable energy penetration in the power system is rapidly increasing. While supporting clean energy transition, this also introduces marked electricity price volatility and market uncertainty, highly complicating the development of bidding strategies by power producers, relying in particular on spot trading. In response to the development of the optimal bidding strategies by traditional thermal power enterprises and diverse energy market players in the joint energy and frequency regulation ancillary services market, a bidding strategy optimization method based on proximal policy optimization (PPO) is proposed. [Methods] First, a bi-level optimization model is established for the joint energy-frequency regulation market, integrating multiple generation types and renewable energy storage, where storage smooths price fluctuations through charge-discharge control, elevating the risk response capability of market players such as wind-storage unions. In this framework, the upper-level power producers develop bidding strategies aiming at profit maximization, while the lower-level market clearing model achieves joint dispatch with the objective of minimizing system operating costs. Second, the bidding problem is formulated as a Markov decision process (MDP) within a deep reinforcement learning (DRL) framework, where PPO algorithm is employed to achieve autonomous learning and dynamic optimization of bidding strategies. [Results] Comparative analysis against the theoretical optimal solution in typical cases demonstrates that the proposed approach effectively boosts thermal power enterprises' revenues, mitigates the risks resulting from renewable energy price fluctuations, reduces system

operating costs, and enhances frequency regulation efficiency. [Conclusions] The proposed approach demonstrates superior economic performance and higher real-time computational efficiency in a joint market compared with benchmark solutions.

This work is supported by National Natural Science Foundation of China (No. 52207082) and the First Batch of Science and Technology Project in 2024 of China Datang Group Technology Innovation Co., Ltd. (No. DTKC-024-20595).

KEYWORDS: power generator bidding; electricity market risk response; deep reinforcement learning (DRL); proximal policy optimization (PPO); actor-critic architecture

0 引言

为缓解全球能源危机与气候变化的双重压力,中国制定了“双碳”目标,大力推动清洁能源转型^[1-3]。随着2015年启动的新电改持续深化,我国电力市场建设取得显著进展,市场化交易机制不断完善。然而,新能源在电力系统中的高比例接入虽然有助于清洁能源发展,却也带来了更高的电价波动性和更强的市场不确定性,尤其在现货交易中,价格频繁波动与供需失衡可能显著增加发电企业的经营风险。在此转型背景下,传统发电企业的经营模式面临重大挑战,原有报价机制已难以满足新型电力系统的运行与风险防控需求。如何构建适应市场化改革、在实现经济效益的同时有效平抑价格波动并保障系统平衡的竞价决策体系,成为当前发电企业亟待解决的关键问题^[4]。

调频辅助市场主要负责维持系统频率稳定,通过快速调节发电机组出力来实时平衡电网供需。电能量市场则以电能交易为核心,通过分时定价机制反映不同时段的电力商品价值^[5]。2024年2月,国家发展和改革委员会与国家能源局联合出台《关于建立健全电力辅助服务市场价格机制的通知》,特别强调需要建立调频辅助服务与电力现货市场的价格联动机制,通过市场化手段实现二者的有机衔接与协调运作^[6-7]。在这一机制下,报价策略不仅需要考虑收益最大化,还必须兼顾调度安全性与对市场波动风险的应对能力。

针对发电商报价策略优化问题,传统研究方法主要可归纳为4类^[8]:1)基于成本分析的报价策略^[9-10]。该方法以发电边际成本为核心,叠加预期利润空间形成报价策略。其优势在于计算简便、实施成本低,但存在明显缺陷:既未考虑市场竞争态势,也难以反映供需关系变化,导致报价策略缺乏市场适应性。2)基于市场电价预测的报价策略^[11]。该方法通过构建电价预测模型,采取略低于预测值的报价策略来提升中标概率。然而,在电力现货市场建设初期,该方法面临三大实施障碍:一是历史交易数据积累不足,难以支撑可靠的预测模型;二是市场规则处于动态调整期,增加了预测的不确定性;三

是新能源占比快速提升,加剧了价格波动性。3)基于竞争对手行为预测的报价策略^[12-13]。该方法运用概率密度估计、模糊推理等数学工具,构建竞争对手报价行为的预测模型。但在实际应用中存在显著局限性:一方面,由于商业机密保护,竞争对手的历史报价数据获取困难;另一方面,在市场主体数量较多时,预测模型的复杂度呈指数级增长。4)基于博弈论的报价策略^[14-16]。该方法通过构建非合作博弈模型,求解纳什均衡点来确定最优报价策略。虽然博弈论在理论上具有严谨性,但在处理实际电力市场问题时存在2个主要不足:一是对市场信息完备性要求过高,难以适应非对称信息环境;二是对于多人博弈,均衡解的计算复杂度急剧上升。

在优化问题的求解中,传统的数学规划方法因其良好的理论收敛性和模型可解释性而被广泛应用^[17-18]。然而,对于电力市场报价这类高维、随机且动态的决策问题,此类方法存在一定局限。首先,目标函数和约束条件的精确构建往往依赖于市场出清价格、机组运行成本等先验信息,但在实际市场中,这些参数通常具有非平稳性和部分可观测性,难以准确获取。其次,为满足凸性假设而进行的线性化或分段近似处理,可能导致模型误设,从而使最优解偏离真实的经济均衡点。相比之下,启发式算法虽然能够在一定程度上避免对精确建模的依赖,但也存在固有缺陷^[19-20]:一方面缺乏收敛性保证,容易陷入局部最优;另一方面,其计算复杂度随决策维度和约束数量呈指数级增长,在处理机组组合等复杂场景时容易出现计算不可行的问题。

近年来,深度强化学习(deep reinforcement learning, DRL)作为一种新型数据驱动的序贯决策框架,展现出突破传统方法局限的潜力^[21-22]。该方法通过将序贯决策问题分解为马尔可夫决策过程(Markov decision process, MDP),并利用深度神经网络(deep neural network, DNN)进行函数逼近,能够直接从历史数据中学习最优策略。已有研究表明,深度强化学习在机器人控制^[23]、自动驾驶^[24]等领域的成功应用验证了其在处理高维状态空间和复杂动作空间方面的优势,这为解决电力市场报价优化问题提供了新的技术路径。DRL算法已被应用于电力市

场研究中。文献[25]提出基于深度Q网络(deep Q learning, DQN)算法的电力市场虚拟投标模型,以虚拟投标者累积收益最大化为目标。文献[26]基于智能体建模和深度确定性策略梯度(deep deterministic policy gradient, DDPG)算法制定以利润最大化为目标的火电企业市场交易策略,提升火电机组的市场竞争力。文献[27]针对现有策略竞价研究仅报价不报量的缺陷,提出了考虑量价组合申报的发电商双层竞价模型,并采用深度策略确定性算法求解优化策略。文献[28]采用多智能体深度强化学习方法求解不完全信息市场环境下的多主体风储系统竞价问题,在保证电网调频调峰需求的同时,显著提升了经济收益。然而,现有关于DRL在多市场联合出清中的应用研究仍较为有限。

针对多类型机组参与电能量-调频联合市场的情景,本文引入联合出清机制,并考虑负荷需求与新能源出力的不确定性,提出一种基于近端策略优化(proximal policy optimization, PPO)的火电机组竞价模型,用于指导其参与联合市场交易,从而提升企业经济效益。通过算例仿真验证,所提方法不仅能够为火电企业提供实时的竞价决策支持,还能在一定程度上提升电网的调频与调峰能力,降低发电商的市场风险暴露。

1 各机组参与电能量-调频市场竞价模型

1.1 电力市场机制框架

多类型机组参与电能量-调频市场的交易框架如图1所示。在市场申报环节,风储系统、火电厂和核电厂等市场主体需分别向调度机构提交能量与调频市场的报价信息。尽管各类主体采用的报价策略存在差异,但其优化目标均为自身利润最优化。各

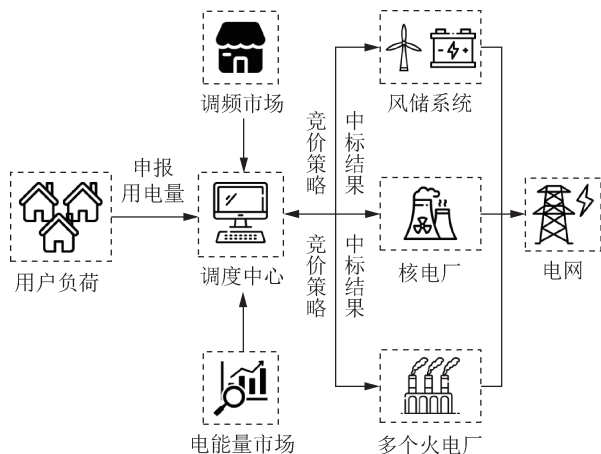


图1 多类型机组参与电能量-调频市场的交易框架

Fig. 1 Trading framework for multi-type units participating in the energy and frequency regulation markets

主体分别报送其在电能市场与调频市场中的报价及可用容量信息。调度中心则在满足系统负荷需求与调频容量要求的同时,结合各类物理约束条件,以最大化社会福利为目标,开展日前的联合出清。不同的发电商再据此优化下一阶段的报价策略,如此循环。基于此,发电商的报价可以建模为双层优化模型,其中上层为发电商报价决策层,下层为市场出清层。

1.2 上层发电商报价决策模型

1.2.1 上层优化目标

上层是发电商报价决策层,发电商作为策略性报价主体参与市场,其目标为发电商的利润最大化,即发电商的收益减去其发电成本。上层发电商报价的目标函数为:

$$\max_{\alpha} \sum_{t=1}^T \sum_{i=1}^S (\lambda_t - c_i^{\text{real}}) P_{i,t}^{\text{out}}(\alpha) + \sum_{g=1}^G c_g^{\text{fm}} r_{g,t} \quad (1)$$

式中: $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_S]$ 为机组的报价向量; c_i^{real} 为第*i*分段的真实边际成本; λ_t 为下层市场出清模型返回的*t*时段的出清电价; $P_{i,t}^{\text{out}}(\alpha)$ 为机组第*i*分段在*t*时段的中报电量,依赖于报价 α ;S为机组报价分段数目;*T*为报价周期; c_g^{fm} 为机组*g*参与市场调频服务的报价; $r_{g,t}$ 为机组*g*在*t*时段提供的调频容量。

1.2.2 上层约束条件

上层发电商报价的约束条件为策略性报价机组分段报价单调不递减以及报价上下限约束:

$$\alpha_1 \leq \alpha_2 \leq \dots \leq \alpha_S \quad (2)$$

$$\alpha_i^{\text{min}} \leq \alpha_i \leq \alpha_i^{\text{max}} \quad (3)$$

式中: α_i^{max} 、 α_i^{min} 分别为机组在第*i*分段报价的最大、最小值。

1.3 下层电能量-调频市场出清模型

1.3.1 下层优化目标

下层模型为电力市场出清模型,目的是实现社会福利最大化,即电能量市场成本和调频辅助服务成本最小化。下层电力市场出清模型的目标函数为:

$$\min \left(\sum_{t=1}^T \sum_{g \in G} \sum_{i=1}^{N_g} c_{g,i} P_{g,t,i} + \sum_{t=1}^T \sum_{g \in G} c_g^{\text{fm}} r_{g,t} \right) \quad (4)$$

式中: $c_{g,i}$ 为机组*g*在第*i*成本段的报价; $P_{g,t,i}$ 为机组*g*在*t*时段第*i*成本段的出力;*G*为机组集合; N_g 为机组*g*的成本分段数。第一项为电能量市场成本;第二项为调频辅助服务成本。

1.3.2 下层约束条件

为提高模型的物理逼近度,联合出清模型引入输电网络约束,采用直流潮流近似形式将潮流方程

线性化。系统电功率平衡约束为:

$$\sum_{g \in G} \sum_{i=1}^{N_g} P_{g,t,i} + P_{dis,t} - P_{ch,t} - \sum_{m \in \psi_n^N} B_{n,m} (\delta_{n,t} - \delta_{m,t}) = D_t \quad (5)$$

$$B_{n,m} (\delta_{n,t} - \delta_{m,t}) \leq P_{n,m}^{\max} \quad (6)$$

$$-\pi \leq \delta_{n,t} \leq \pi \quad (7)$$

$$\delta_{1,t} = 0 \quad (8)$$

式中: D_t 为 t 时段的负荷需求; $P_{ch,t}$ 、 $P_{dis,t}$ 分别为储能的充、放电功率; ψ_n^N 为与节点 n 相连接的节点构成的集合; $B_{n,m}$ 为节点 n 和节点 m 之间线路的电导; $\delta_{n,t}$ 为节点 n 在 t 时段的相角; $P_{n,m}^{\max}$ 为节点 n 、 m 之间线路传输功率的上限。

式(6)确保线路输功率不超过限值;式(7)限制节点相角不超过上下限;式(8)规定节点1为参考节点。

调频总容量需满足需求,调频容量平衡约束为:

$$\sum_{g \in G} r_{g,t} = \delta D_t, \forall t \quad (9)$$

式中: δ 为调频需求占总负荷需求的比例,本文设置为2%。

机组 g 的分段出力限制约束为:

$$0 \leq P_{g,t,i} \leq P_{g,i}^{\max} \quad (10)$$

式中: $P_{g,i}^{\max}$ 为机组 g 第 i 成本段的最大出力。

考虑调频备用,机组总出力限制约束为:

$$r_{g,t} \leq \sum_{i=1}^{N_g} P_{g,t,i} \leq C_g - r_{g,t} \quad (11)$$

式中: C_g 为机组 g 的最大容量。

储能充放电功率约束为:

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

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

式中: P_{ch}^{\max} 、 P_{dis}^{\max} 分别为最大充、放电功率。

储能荷电状态约束为:

$$E_t = E_{t-1} + \eta_{ch} P_{ch,t} - \frac{P_{dis,t}}{\eta_{dis}} \quad (14)$$

$$E^{\min} \leq E_t \leq E^{\max} \quad (15)$$

$$E_0 = E_T \quad (16)$$

式中: E_t 为 t 时段的储能电量; η_{ch} 、 η_{dis} 分别为充、放电效率; E^{\min} 、 E^{\max} 分别为储能电量最小、最大值; E_0 为初始时刻的储能电量; E_T 为末端时刻的储能容量。

2 基于深度强化学习算法的报价策略

DRL作为一种先进的序列决策方法,其决策框架如图2所示,通过集成深度神经网络的智能体与环境的交互机制实现最优策略学习。首先,将电力市场报价问题形式化为MDP,建立包含转移概率和

即时奖励的完整数学模型;其次,采用PPO算法求解该MDP问题,通过策略梯度更新和重要性采样机制,能够稳定地收敛至最优报价策略。




图2 DRL决策框架

Fig. 2 Decision framework of DRL

2.1 MDP构建

本文构建了基于DRL的发电商报价决策框架,其中:

状态 s : 智能体状态 $s = [d, w, S_{soc}, c_g^{\text{real}}, C_g]$, 其中, d 为负荷信息; w 为风电信息; $c_g^{\text{real}} = [c_1^{\text{real}}, c_2^{\text{real}}, \dots, c_s^{\text{real}}]$ 为机组的实际边际成本; S_{soc} 为储能系统的电容量。

动作 a : 智能体的动作为报价策略,即机组报出的分段电能报价向量 $a = \alpha = [\alpha_1, \alpha_2, \dots, \alpha_s]$, 动作空间需满足 $\alpha_i \leq \alpha_{i+1}$ 。

奖励 r : 智能体的奖励为机组在当天参与电能量和调频市场的总利润。

转移概率 $P: P(s_{t+1}|s_t, a_t)$ 为智能体在状态 s_t 下执行动作 a_t 后转移到状态 s_{t+1} 的条件概率,是马尔可夫且部分可观测的。

在DRL的序贯决策框架中,每个训练回合包含多个决策步。智能体的优化目标是通过学习策略 $\pi: s \rightarrow a$ 最大化期望累计折扣奖励,其目标函数可形式化表示为:

$$J(\pi) = \max_{\pi} \mathbb{E}_{\tau \sim \pi} [\hat{R}] \quad (17)$$

$$\hat{R} = \sum_{t=0}^T \gamma^t r(s_t, a_t) \quad (18)$$

式中: $\tau = (s_0, a_0, \dots, s_T)$ 为轨迹; $\mathbb{E}_{\tau \sim \pi} [\hat{R}]$ 为策略 π 下回报 \hat{R} 的期望值; $\sum_{t=0}^T$ 表示时间步0累加到时间步 T ; $\gamma \in (0, 1]$ 为折扣因子,当 γ 趋于0,智能体表现出短视决策特性,其策略优化将主要考虑即时奖励的获取,当 γ 趋于1,智能体呈现长远规划能力,策略评估会显著提高未来奖励的权重; γ^t 表示对未来的奖励进行“打折”。

2.2 近端策略优化算法

PPO是一种基于策略梯度的强化学习算法,用

于优化 MDP 中的策略^[29]。PPO 算法的核心在于通过优化策略函数来最大化累积奖励,并且引入了裁剪机制,限制了策略的更新幅度,从而提高训练的稳定性。PPO 算法基于演员-评论家(actor-critic)架构。策略网络(actor) $\pi_{\theta}(\mathbf{a}|s)$ 负责生成动作。给定当前状态 s_t ,策略网络输出一个概率分布 $\pi_{\theta}(\mathbf{a}|s_t)$,从而决定该状态下应该采取哪一个动作 a_t 。价值网络(critic) $V_{\phi}(s)$ 负责评估当前策略的优劣,通过估计状态值函数 $V(s)$ 来衡量某一个状态的价值。演员-评论家架构通过将策略网络与价值网络相结合实现高效的策略优化。

PPO 的核心创新在于通过“裁剪”机制来限制新旧策略的比率。该比率决定了每次策略更新的幅度,从而避免策略的剧烈变化导致训练不稳定。新旧策略比率的定义为:

$$\zeta_i(\theta) = \frac{\pi_{\theta}(a_i|s_i)}{\pi_{\theta_{old}}(a_i|s_i)} \quad (19)$$

式中: $\pi_{\theta}(a_i|s_i)$ 为当前策略网络输出的概率分布,表示当前策略下在状态 s_i 下采取动作 a_i 的概率; $\pi_{\theta_{old}}(a_i|s_i)$ 为上一次更新的策略网络输出的概率分布,表示之前的策略下在状态 s_i 下采取动作 a_i 的概率。

优势函数 \hat{A}_i 表示某个状态-动作对相对于平均水平的好坏,有助于评估某个动作在某个状态下的优越性,即该动作的回报是否优于平均水平。优势函数 \hat{A}_i 通常表示为:

$$\hat{A}_i = \delta_i + (\gamma\lambda)\delta_{i+1} + (\gamma\lambda)^2\delta_{i+2} + \dots + (\gamma\lambda)^T\delta_T \quad (20)$$

$$\delta_i = r_i + \gamma V_{\theta}(s_{i+1}) - V_{\theta}(s_i) \quad (21)$$

式中: δ_i 为 t 时刻的时序差分误差; λ 为广义优势估计中的平滑参数。如果一个动作 a_i 在状态 s_i 下的优势函数 \hat{A}_i 为正,说明此动作比当前策略平均水平好,策略网络应该通过该信号加强该动作的选择概率;反之,若为负,应该减少该动作的选择概率。

PPO 的目标是最大化策略的期望回报,因此其优化目标函数为:

$$L^{CLIP}(\theta) = \mathbb{E}_i\{\min\{\zeta_i(\theta)\hat{A}_i, \text{clip}[\zeta_i(\theta), 1 - \varepsilon, 1 + \varepsilon]\hat{A}_i\}\} \quad (22)$$

式中: $\varepsilon \in [0.1, 0.3]$ 为裁剪参数,控制策略更新的幅度。PPO 通过裁剪机制来限制新旧策略之间的比率,防止过大的策略更新导致不稳定的训练过程。

策略网络的目标是通过梯度下降法来最小化损失函数,使用 Adam 优化器对策略网络的参数 θ 进行更新:

$$\theta \leftarrow \theta - \xi \nabla_{\theta} L^{CLIP}(\theta) \quad (23)$$

式中: ξ 为策略网络的学习率。

价值网络的目标是通过最小化预测值与实际回报之间的均方误差来学习一个准确的状态值函数,该均方误差定义为:

$$L^{VF}(\phi) = \mathbb{E}_i\{[V_{\phi}(s_i) - \hat{R}_i]^2\} \quad (24)$$

通过梯度下降方法,价值网络的参数更新式为:

$$\phi \leftarrow \phi - \beta \nabla_{\phi} L^{VF}(\phi) \quad (25)$$

式中: β 为价值网络的学习率。

2.3 基于 PPO 算法的火电商策略性报价模型

基于 PPO 算法的训练与部署流程如图 3 所示,采用离线训练与在线部署相结合的架构设计。在离线训练阶段,智能体通过与电力出清模拟环境进行持续交互,将交互过程中获取的 (s_t, a_t, r_t, s_{t+1}) 数据存入经验回放池。当经验回放池达到预设容量后,系统采用随机采样策略抽取历史经验数据构成训练批次,作为 PPO 算法的输入。PPO 算法通过策略评估和策略改进的交替迭代,在完成预设值的训练回合后,模型性能趋于稳定,累计奖励值达到收敛阈值,此时离线训练阶段终止。系统将训练得到的最优策略网络参数 θ^* 进行保留,为后续在线部署做好准备。在线部署阶段,智能体实时接收电力市场出清系统的状态观测信息,通过策略网络的前向传播计算,实现实时输出最优策略决策。

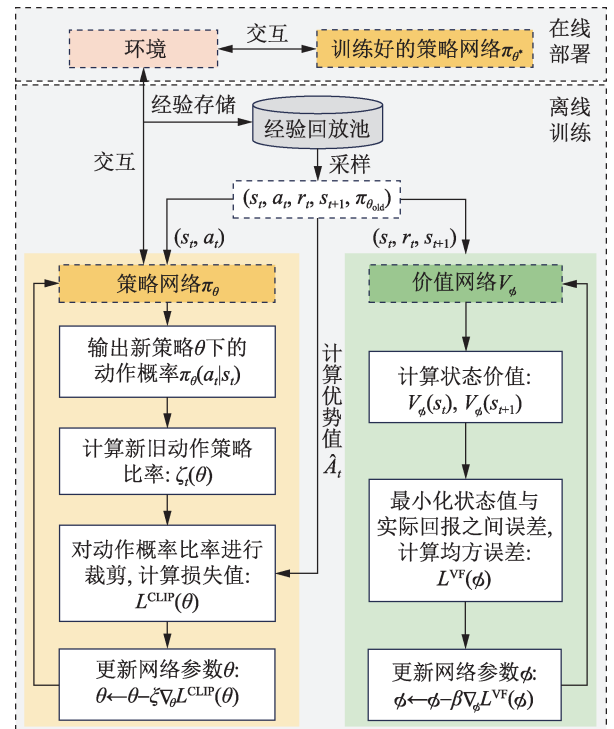


图 3 基于 PPO 算法的离线训练与在线部署流程

Fig. 3 Flowchart of PPO-based offline training and online deployment

3 算例分析

3.1 参数设置

为验证所提 DRL 报价策略在联合市场环境中的有效性,本文构建了一个典型的单日联合市场出清场景,覆盖电能市场和调频辅助服务市场 2 个部分。联合市场出清模型基于线性优化构建,其中电能市场采用分段报价,按最小系统运行成本进行出清,调频辅助服务按照固定比例的负荷需求提供,并按调频报价排序确定边际价格。为测试所提策略的泛化能力,本文将训练后的智能体报价结果输入联合出清模型,并与真实成本报价结果进行对比分析,最终从出清电量、电价走势、调频响应、系统成本及利润等多个维度进行效果评估。

本文选取基于 ϵ -贪婪策略的 DQN 算法和基于离散学习的 DDPG 算法作为对比方法。DQN 算法的动作空间采用多段报价的离散化组合表示,通过多维离散动作编码实现报价策略的近似优化。每段报价被离散为 5 个价格档位,并通过一维索引方式映射至对应的报价组合。PPO、DQN 与 DDPG 算法超参数设置对比见表 1。总回合数为 10 000。仿真电力系统中包含 1 台核机组、1 台配备储能的风电机组和 4 台火电机组(分别记为 CCGT1、CCGT2、OCGT1、OCGT2)。其中机组 CCGT2 使用 DQN、DDPG 和 PPO 这 3 种算法分别进行报价策略训练,其余机组采用固定分段成本报价。将上述机组接入 IEEE 39 节点系统作为算例模型。表 2 为储能系统

表 1 PPO、DQN 与 DDPG 算法超参数设置对比

Table 1 Comparison of hyperparameter settings for PPO, DQN, and DDPG algorithms

参数	数值		
	PPO	DQN	DDPG
策略网络学习率	3×10^{-4}		3×10^{-4}
价值网络学习率	2×10^{-3}	1×10^{-4}	2×10^{-3}
折扣因子	0.9	0.9	0.9
批量大小	64	64	64
优化器	Adam	Adam	Adam
策略网络	[128, 128]	[128, 128]	[64, 64]
价值网络	[128, 128]	[128, 128]	[64, 64]

表 2 储能系统参数

Table 2 Parameters of energy storage system

参数	数值	参数	数值
P_{ch}^{max}/kW	600	E_0/kWh	2000
P_{dis}^{max}/kW	800	$\eta^{ch}/\%$	98
E^{max}/kWh	4000	$\eta^{dis}/\%$	98

参数,包括容量限制、充放电功率上限与效率。不考虑储能系统的充放电成本。储能系统详细参数可参考文献[30]。

3.2 训练过程

图 4 展示了 PPO、DQN 和 DDPG 这 3 种算法在训练过程中奖励函数的变化趋势。从图中可以看出,智能体在不断交互中逐渐学习如何更有效地适应环境,从而获得更高的累计奖励。DRL 的训练过程可大致分为 3 个阶段:探索阶段、学习阶段与收敛阶段。在探索阶段,DQN 由于设定了较大的 ϵ 值,智能体倾向于采取随机动作,以充分探索环境状态空间,因此奖励波动较大。PPO 则是在连续动作空间中通过高斯分布对策略进行采样,由于初始阶段策略分布的标准差较大,也会导致显著的奖励波动。当训练进行至约 5000 回合时,训练进入学习阶段,智能体开始利用探索阶段积累的经验,通过小批量更新策略或价值函数,不断优化神经网络参数,奖励值整体呈现上升趋势。在收敛阶段,奖励提升趋于平缓,说明智能体策略已接近最优。此时神经网络通过微调进一步提高策略性能,最终实现奖励函数的收敛,表明智能体已成功学得较优的报价策略。




图 4 PPO、DQN 和 DDPG 算法训练奖励值对比

Fig. 4 Comparison of training rewards values for PPO, DQN, and DDPG algorithms

3.3 测试结果分析

为验证所提基于 DRL 算法报价策略在实际电力市场中的可行性与有效性,本文在典型的单日市场出清场景下对训练完成的智能体进行测试,并对出清结果进行定量分析与对比,以评估其收益表现及报价策略的合理性。图 5 为典型日的负荷需求和风电出力数据。

3.3.1 电能量市场出清结果

图 6 展示了各台机组及储能设备在电能量市场中的中标情况。可以看出,常规火电机组在各时段出力占比 50% 左右,是主要发电来源,体现了常规机组在电能量市场中的主导地位。此外,由图 6 可见,核电和风电机组在各阶段几乎均处于满发状态,




图5 典型日的负荷需求和风电出力数据

Fig. 5 Profiles of load demand and wind power output of a typical day

这主要得益于其成本低,使其在市场出清中具有优先供电权。当核电和风电机组出力达到上限后,由报价相对较低的CCGT2机组补充发电来满足系统负荷需求。

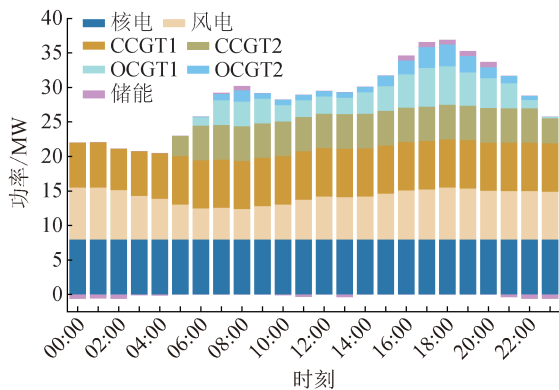


图6 典型日电能量市场出清结果

Fig. 6 Electricity market clearing results on a typical day

新能源场站配备储能装置,在该出清模型中,储能的主要作用体现在削峰填谷。图7给出了电能量市场的出清电价,图8展示了储能系统的充放电功率及其荷电状态变化情况。由图7和图8可观察到,在市场电价较低的时段(如01:00—05:00、11:00—12:00和22:00—23:00时段),储能设备倾向于充电;而在电价较高的时段(如08:00—09:00和17:00—21:00时段),储能则通过放电为系统提供电力,从而实现降低运行成本的作用。此外,在负荷低谷时段(如01:00—06:00时段),储能系统处于充电状态,在电价较低时吸收能量;而在负荷高峰期(如17:00—21:00时段),系统则处于放电状态,辅助满足负荷需求。

3.3.2 调频市场出清结果

表3给出了各类型机组在调频辅助服务市场中的申报信息,主要包括调频服务的单位报价以及最大可用调频容量。通常情况下,最大调频能力为机组额定功率的10%左右。从表3中可以看出,核电




图7 电能量市场出清电价

Fig. 7 Electricity market clearing price




图8 储能充放电功率和荷电状态

Fig. 8 Results of charging/discharging operation and state of charge of storage systems

机组由于运行稳定性高且不具备快速调节能力,因此不参与调频服务。风电机组虽然具备一定的调节能力,但其出力具有间歇性和不确定性,因此其调频成本相对较高,最大调频能力为200 kW。

表3 机组参与调频市场申报信息
Table 3 Bidding information of units in the frequency regulation market

机组	调频单位报价/ (欧元/MWh)	最大调频能力/kW
核电机组	0	0
风电机组	6	200
CCGT1	4	500
CCGT2	5	300
OCGT1	7	400
OCGT2	8	200

图9展示了在典型日情形下,电能量市场与调频辅助服务市场联合出清后的各机组出力构成情况。从图9中可以看出,常规火电机组(CCGT与OCGT)通过预留部分装机容量参与了调频服务。图10进一步呈现了调频市场的边际出清价格变化趋势。CCGT1与CCGT2的调频成本相对较低,因此在

低调频需求时段(01:00—06:00)往往由这 2 台机组承担主要调频任务,对应调频价格较低,反映了联合优化模型对系统调频成本的最小化策略。此外,调频价格在 06:00—07:00 时段快速上升,随后在 09:00—21:00 时段保持在较高水平(约为 7.5 欧元/MWh),对应于调频需求增加且边际调频机组报价较高的时段。根据表 3 所示的调频成本,OCGT2(8 欧元/MWh)与 OCGT1(7 欧元/MWh)在该时段较频繁地参与调频服务,因此其报价较高,是造成调频边际价格升高的主要原因。调频价格在 07:00 从 4 欧元/MWh 跳升至 6 欧元/MWh,对应于此时风电机组(6 欧元/MWh)开始参与调频服务。进一步,从 08:00 开始,调频价格迅速升至 8 欧元/MWh,说明此时调频服务由调频成本最高的 OCGT2(8 欧元/MWh)提供边际支持。此外,在 17:00—20:00 时段,OCGT1 和 OCGT2 的出力显著增加且未饱和运行,其部分容量用于调频市场,从而维持了图 9 中较高的调频价格水平。

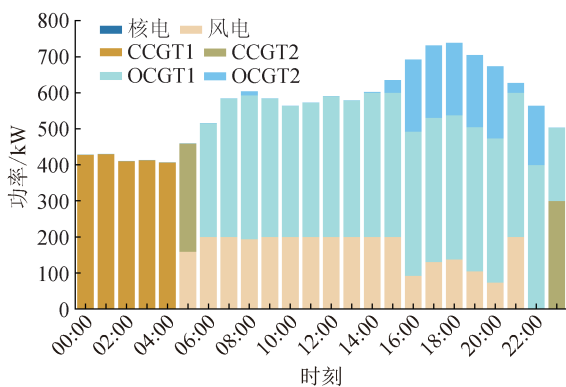


图 9 典型日调频市场出清结果

Fig. 9 Frequency regulation market clearing results on a typical day




图 10 调频市场出清电价

Fig. 10 Frequency market clearing electricity

3.3.3 联合出清下各类机组的收益表现分析

在联合出清机制下,发电侧资源不仅根据电能量市场的边际成本进行调度,同时还需承担系统的

调频辅助服务需求,从而共同影响各类机组的运行特性与经济性表现。表 4 展示了各类机组在联合出清模式下从电能量市场和调频服务中获得的收入情况。电能量市场依旧是各机组的主要收益来源,但部分机组也通过调频服务获得了额外收益。

表 4 不同机组联合出清下的收益
Table 4 Profits under joint clearing of different units

机组	万欧元	
	电能量市场收入	调频服务收入
核电	937.056 0	0
风电	735.676 4	2.142 3
CCGT1	815.918 3	0.835 1
CCGT2	539.545 5	0.390 0
OCGT1	375.682 3	5.155 0
OCGT2	151.724 8	0.990 5

由表 4 可以看出,核电机组作为基础负荷电源,其运行特性决定了其不具备调频调节能力,因此调频服务收入为 0。但其电能量市场收入达到 937.056 0 万欧元,体现了其低边际成本带来的高中标率。尽管风电出力具有较强的不确定性,但由于模型中允许其提供最大调频容量为 200 kW 的调频能力,在部分时段其剩余灵活性可用于系统调频,因而实现了一定收益。OCGT1 和 OCGT2 在调频市场中表现出较强的中标能力,在多数时段承担了较高比例的调频服务任务,与调频价格的上升阶段高度吻合。

3.3.4 算法对比

本文选取了 DQN、DDPG、PPO 算法进行对比分析,并将其决策结果与通过商业求解器 COPT (cardinal optimizer) 获得的理论最优值作为参考基准。实验采用 30 天的负荷和风电历史数据,分别在每日运行环境中独立测试 DQN 与 PPO 训练后的策略,记录其所控制机组在 24 h 内的总利润。

图 11 展示了 DQN、DDPG、PPO 算法与理论最优解(由 COPT 求解器获得)在每小时的利润对比情况。从图中可以观察到,PPO 和 DDPG 策略获得的利润表现优于 DQN,其调度策略能够更有效地协调电能量市场和调频市场的出力分配,从而实现更高的收益。相比之下,DQN 策略在若干时段下存在利润偏低的现象,主要原因在于 DQN 基于离散动作空间建模,不适合处理电力市场中的连续报价决策,且在高维约束条件下易出现动作选择粗糙、策略不稳定等问题。而 DDPG 虽然能够直接处理连续动作空间,但由于其依赖确定性策略更新,容易受到噪声和

超参数设置的影响,导致收敛速度较慢、训练稳定性不足,在复杂市场环境下表现略逊于 PPO。与最优解相比,PPO 的利润曲线更接近理论上界,验证了其在联合市场出清问题中的实际可行性与优越性。

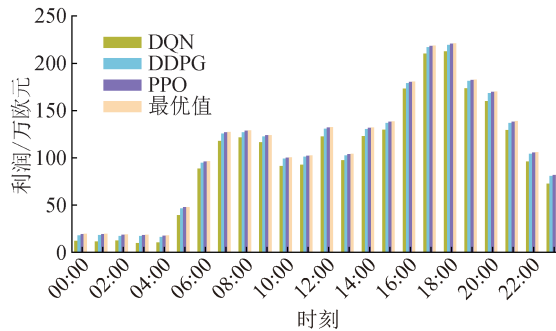


图 11 不同算法下的 24 h 累计利润对比

Fig. 11 Comparison of 24 h cumulative profit under different algorithms

表 5 对比了 DQN、DDPG、PPO 和最优解在连续 10 天内的平均利润和计算时间。结果表明,PPO 算法的利润接近最优值,仅相差约 0.5%,且计算时间仅为 0.03 s,远低于基于 COPT 求解器的 2.50 s。与 COPT 等基于数学规划的优化方法不同,DRL 算法在测试阶段,决策过程仅需策略网络进行一次前向传播,即可在毫秒级时间内输出控制策略,无需重新构建和求解数学模型。这种决策方式显著降低了实时优化所需的计算开销,尤其适用于需要快速响应的调度与控制场景。

表 5 不同算法在连续 10 天内的平均利润和计算时间

Table 5 Average profit and computation time of different algorithms over a 10-day period

算法	利润/万欧元	测试时间/s
DQN 算法	164.876 9	0.02
DDPG 算法	182.765 9	0.02
PPO 算法	193.465 6	0.03
最优值	194.379 0	2.50

4 结 论

本文针对火电企业参与电能量-调频联合市场的报价策略优化问题,构建了双层优化模型,并提出了基于 PPO 的报价策略优化方法。上层模型以火电商利润最大化为目标,通过学习优化其报价曲线;下层模型则在系统运行成本最小化的目标下,同时完成电能量与调频辅助服务的联合出清,从而充分反映报价对市场结果的影响。为应对复杂市场环境和状态空间维度较高的挑战,本文将报价问题形式化为 MDP,并采用演员-评论家结构的 PPO 算法进行训

练。训练过程中,智能体能够逐步探索环境并学习最优报价策略,在不同负荷与风电出力情景下保持较高的利润水平。仿真算例进一步验证了所提方法的有效性。通过与 DQN、DDPG 算法及理论最优解对比,结果表明,PPO 算法不仅具有更高的训练稳定性和收益水平,还在应对联合市场出清的非线性特性方面表现出更强的适应能力。特别是在策略收敛速度和市场收益提升方面,PPO 算法相较于另外 2 种 DRL 算法表现出明显优势。

针对新能源出力不确定性带来的市场波动,应鼓励发电商配置储能或与储能主体开展协同交易,充分发挥储能削峰填谷与快速调节的作用,从而增强电力系统的风险承受能力,降低市场价格大幅波动对企业经营的冲击。同时,通过建立统一的竞价与出清机制,引导火电企业等传统主体在追求利润的同时兼顾系统调节能力,以提升整体市场运行效率与灵活性。

在后续研究中,可以探索多智能体强化学习框架下的竞价交互机制,研究不同类型发电主体之间的博弈行为与协同策略,并进一步引入网络约束、机组启停与爬坡限制等实际因素,为构建更加公平、高效和低碳的电力市场提供理论与方法支持。

利益冲突声明 (Conflict of Interests):

所有作者声明不存在利益冲突。

作者贡献声明 (Authors' Contributions):

张斌提出研究方向,设计论文框架,绘制图谱;曹蕃参与论文修订及最终版本修订;肖坤进行实验并进行实验分析,参与文献调研与整理;宋寅参与论文修订;郭瑛参与修订论文、审核论文;叶宇剑设计研究思路及研究方案;许德智参与论文修订,审核论文。所有作者均阅读并同意了论文终稿内容。

5 参 考 文 献

- [1] 周孝信,赵强,张玉琼,等.“双碳”目标下我国能源电力系统发展趋势分析:绿电替代与绿氢替代[J].中国电机工程学报,2024,44(17):6707-6721.
ZHOU Xiaoxin, ZHAO Qiang, ZHANG Yuqiong, et al. Analysis of the development trend of China's energy and power system under the dual carbon target: green electricity substitution and green hydrogen substitution [J]. Proceedings of the CSEE, 2024, 44(17): 6707-6721.
- [2] 魏旭,刘东,高飞,等.“双碳”目标下考虑源网荷储协同优化运行的新型电力系统发电规划[J].电网技术,2023,47(9):3648-3658.
WEI Xu, LIU Dong, GAO Fei, et al. Generation expansion

- planning of new power system considering collaborative optimal operation of source-grid-load-storage under carbon peaking and carbon neutrality [J]. *Power System Technology*, 2023, 47(9): 3648-3658.
- [3] 辛永. “双碳”目标下的电网数字化转型技术研究与应用[J]. *供用电*, 2023, 40(11): 1.
XIN Yong. Research and application of digital transformation technology of power grid under the goal of “double carbon” [J]. *Distribution & Utilization*, 2023, 40(11): 1.
- [4] 杨知方, 王娴琳, 李琪瑞. 目标导向的电力市场机制设计: 基本框架与案例分析[J/OL]. *中国电机工程学报*, 2025: 1-12. (2025-08-20) [2025-09-10]. <https://doi.org/10.13334/j.0258-8013.pcsee.250312>.
YANG Zhifang, WANG Xianlin, LI Qirui. Goal-oriented electricity market mechanism design: fundamental framework and case studies [J/OL]. *Proceedings of the CSEE*, 2025: 1-12. (2025-08-20) [2025-09-10]. <https://doi.org/10.13334/j.0258-8013.pcsee.250312>.
- [5] 张硕, 陈媛丽, 李英姿, 等. 计及电力现货机会成本的构网型储能电站调频辅助服务竞价出清双层博弈模型[J]. *中国电机工程学报*, 2024, 44(S1): 146-158.
ZHANG Shuo, CHEN Yuanli, LI Yingzi, et al. A bi-level game model for frequency regulation ancillary service bidding and clearing of grid-forming energy storage stations considering opportunity cost of electricity spot trading [J]. *Proceedings of the CSEE*, 2024, 44(S1): 146-158.
- [6] 国家发展改革委 国家能源局关于建立健全电力辅助服务市场价格机制的通知[EB/OL]. (2024-02-07) [2025-09-10]. https://www.gov.cn/zhengce/zhengceku/202402/content_6931026.htm.
- [7] 王傲儿, 赵书强, 宋金历, 等. 考虑新能源与储能参与调频的联合市场出清模型[J]. *太阳能学报*, 2024, 45(3): 367-376.
WANG Aoer, ZHAO Shuqiang, SONG Jinli, et al. Joint market clearing model considering participation of new energy and energy storage in frequency modulation [J]. *Acta Energetica Solaris Sinica*, 2024, 45(3): 367-376.
- [8] 唐成鹏, 张粒子, 刘方, 等. 基于多智能体强化学习的电力现货市场定价机制研究(一): 不同定价机制下发电商报价双层优化模型[J]. *中国电机工程学报*, 2021, 41(2): 536-552.
TANG Chengpeng, ZHANG Lizi, LIU Fang, et al. Research on pricing mechanism of electricity spot market based on multi-agent reinforcement learning (part I): bi-level optimization model for generators under different pricing mechanisms [J]. *Proceedings of the CSEE*, 2021, 41(2): 536-552.
- [9] LI G, SHI J, QU X L. Modeling methods for GenCo bidding strategy optimization in the liberalized electricity spot market: a state-of-the-art review [J]. *Energy*, 2011, 36(8): 4686-4700.
- [10] 张晓瑾. 火电厂生产成本分析与报价策略的研究[D]. 天津: 天津大学, 2007.
ZHANG Xiaojin. The study of generator cost analysis and bidding strategies for power plant [D]. Tianjin: Tianjin University, 2007.
- [11] CONEJO A J, NOGALES F J, ARROYO J M. Price-taker bidding strategy under price uncertainty [J]. *IEEE Power Engineering Review*, 2002, 22(9): 57.
- [12] 汤君博, 潘凯岩, 王富友, 等. 基于纳什议价法的多主体虚拟电厂优化调度及效用分配策略[J]. *太阳能学报*, 2025, 46(5): 79-88.
TANG Junbo, PAN Kaiyan, WANG Fuyou, et al. Optimal scheduling and utility allocation strategy for multi-agent virtual power plants based on Nash bargaining method [J]. *Acta Energetica Solaris Sinica*, 2025, 46(5): 79-88.
- [13] 于娣, 胡健, 张晓杰, 等. 电力P2P交易中的双轮竞价博弈模型[J]. *电力建设*, 2023, 44(7): 21-32.
YU Di, HU Jian, ZHANG Xiaojie, et al. Double-round bidding game model for P2P electricity transactions [J]. *Electric Power Construction*, 2023, 44(7): 21-32.
- [14] 王晔, 王胜彩, 张少华. 电-碳-绿证交易耦合下新能源发电商参与投标竞争的多市场博弈分析[J]. *电网技术*, 2024, 48(10): 4125-4134.
WANG Xian, WANG Shengcai, ZHANG Shaohua. Game analysis of coupled electricity-carbon-green certificate markets with strategic bidding of renewable generators [J]. *Power System Technology*, 2024, 48(10): 4125-4134.
- [15] LI Y B, YANG Y N, ZHANG F, et al. A Stackelberg game-based approach to load aggregator bidding strategies in electricity spot markets [J]. *Journal of Energy Storage*, 2024, 95: 112509.
- [16] ZHU X X, ZHAO G Q, LI J H, et al. Stackelberg game for shared energy storage and wind farm bilateral trading with multi-market participation [J]. *Energy*, 2025, 326: 136238.
- [17] 董雷, 田爱忠, 于汀, 等. 基于混合整数半定规划的含分布式电源配电网无功优化[J]. *电力系统自动化*, 2015, 39(21): 66-72, 125.
DONG Lei, TIAN Aizhong, YU Ting, et al. Reactive power optimization for distribution network with distributed generators based on mixed integer semi-definite programming [J]. *Automation of Electric Power Systems*, 2015, 39(21): 66-72, 125.
- [18] 徐潇源, 王晗, 严正, 等. 能源转型背景下电力系统不确定性及应对方法综述[J]. *电力系统自动化*, 2021, 45(16): 1-13.
XU Xiaoyuan, WANG Han, YAN Zheng, et al. Overview of power system uncertainty and its solutions under energy transition [J]. *Automation of Electric Power Systems*, 2021, 45(16): 1-13.
- [19] 刘洪, 徐正阳, 葛少云, 等. 考虑储能调节的主动配电网有功-无功协调运行与电压控制[J]. *电力系统自动化*, 2019, 43(11): 51-58.
LIU Hong, XU Zhengyang, GE Shaoyun, et al. Coordinated operation of active-reactive power and voltage control for active distribution network considering regulation of energy storage [J]. *Automation of Electric Power Systems*, 2019, 43(11): 51-58.
- [20] 王守相, 李琦, 赵倩宇, 等. 计及源荷随机性的交直流配电网电压多目标优化改进粒子群算法[J]. *电力系统及其自动化学报*, 2021, 33(12): 10-17.
WANG Shouxiang, LI Qi, ZHAO Qianyu, et al. Improved particle swarm optimization algorithm for multi-objective voltage optimization of AC/DC distribution network considering the randomness of source and loads [J]. *Proceedings of the CSU-EPSA*, 2021, 33(12): 10-17.
- [21] 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.
- [22] 胥栋, 李逸超, 李赞, 等. 基于深度强化学习的多能流楼宇低碳调度方法[J]. 浙江电力, 2024, 43(2): 126-136.
XU Dong, LI Yichao, LI Yun, et al. A low-carbon scheduling method for multi-energy flow buildings based on deep reinforcement learning[J]. Zhejiang Electric Power, 2024, 43(2): 126-136.
- [23] 沈健, 宋智功. 基于深度学习的双臂系统协同控制综述[J/OL]. 控制工程, 2025: 1-13. (2025-09-09) [2025-10-10]. <https://doi.org/10.14107/j.cnki.kzgc.20250283>.
SHEN Jian, SONG Zhigong. Review of coordinated control for dual-arm systems based on deep learning [J/OL]. Control Engineering of China, 2025: 1-13. (2025-09-09) [2025-10-10]. <https://doi.org/10.14107/j.cnki.kzgc.20250283>.
- [24] 方虹苏. 基于深度强化学习的智能汽车控制模型研究[J]. 自动化应用, 2025, 66(4): 59-62.
FANG Hongsu. Research on intelligent automotive control model based on deep reinforcement learning[J]. Automation Application, 2025, 66(4): 59-62.
- [25] 韩冬, 黄微, 严正. 基于深度强化学习的电力市场虚拟投标策略[J]. 中国电机工程学报, 2022, 42(4): 1443-1454.
HAN Dong, HUANG Wei, YAN Zheng. Deep reinforcement learning for virtual bidding in electricity markets [J]. Proceedings of the CSEE, 2022, 42(4): 1443-1454.
- [26] 李超英, 檀勤良. 基于智能体建模的新型电力系统下火电企业市场交易策略[J]. 中国电力, 2024, 57(2): 212-225.
LI Chaoying, TAN Qinliang. Market trading strategy for thermal power enterprise in new power system based on agent modeling [J]. Electric Power, 2024, 57(2): 212-225.
- [27] 许丹, 胡晓静, 胡斐, 等. 基于深度强化学习的电力市场量价组合竞价策略[J]. 电网技术, 2024, 48(8): 3278-3286.
XU Dan, HU Xiaojing, HU Fei, et al. Strategic bidding of price-quantity pairs in electricity market based on deep reinforcement learning [J]. Power System Technology, 2024, 48 (8): 3278-3286.
- [28] 李钟平, 向月. 深度强化学习驱动的风储系统参与能量-调频市场竞争竞价策略[J]. 电力工程技术, 2025, 44(3): 30-42.
LI Zhongping, XIANG Yue. Deep reinforcement learning-driven bidding strategy for wind-storage systems in energy and frequency regulation markets [J]. Electric Power Engineering Technology, 2025, 44(3): 30-42.
- [29] ZHANG B, HU W H, CAO D, et al. Deep reinforcement learning-based approach for optimizing energy conversion in integrated electrical and heating system with renewable energy [J]. Energy Conversion and Management, 2019, 202: 112199.
- [30] QIU D W, DONG Z H, RUAN G C, et al. Strategic retail pricing and demand bidding of retailers in electricity market: a data-driven chance-constrained programming [J]. Advances in Applied Energy, 2022, 7: 100100.

收稿日期: 2025-08-14 修回日期: 2025-10-23

作者简介:



张斌

张斌(1994),男,博士,工程师,通信作者,主要研究方向为新型电力系统运行优化、人工智能,E-mail: 101013997@seu.edu.cn;

曹蕃(1988),男,博士,正高级工程师,主要从事电力市场研究工作,E-mail: caofan@china-cdt.com;

肖坤(2001),男,硕士研究生,主要从事电力市场运行机制研究工作,E-mail: 220232902@seu.edu.cn;

宋寅(1987),男,博士,正高级工程师,主要从事电力市场研究工作,E-mail: songyin@china-cdt.com;

郭瑛(1983),女,硕士,工程师,主要从事电力市场研究工作,E-mail: gy_imu@163.com;

叶宇剑(1988),男,博士,教授,通信作者,主要研究方向为电力系统运行优化研究、能源交通耦合,E-mail: yeyujian@seu.edu.cn;

许德智(1985),男,博士,高级工程师,主要研究方向为储能系统、运动体与电机控制、故障诊断与容错,E-mail: xudezhi@seu.edu.cn。

(编辑 景贺峰)