

基于分布鲁棒优化的多虚拟电厂主从 博弈动态定价模型及求解方法

陈渠, 杨苹, 陈年昊, 刘根饶, 颜璐
(华南理工大学电力学院, 广州市 510641)

摘 要:【目的】针对多虚拟电厂与配电网运营商的主从博弈格局, 现有动态定价模型未充分考虑新能源出力的不确定性对博弈策略影响的问题, 且传统求解方法在高维决策空间时求解质量差, 为此提出一种基于分布鲁棒优化的主从博弈动态定价模型及求解方法。【方法】建立以配电网运营商为领导者、多虚拟电厂为跟随者的主从博弈动态定价模型; 在虚拟电厂优化模型中引入分布鲁棒机会约束描述风电出力不确定性, 对已知风电功率的一阶矩和二阶矩信息构造模糊集, 通过 Cantelli 不等式将机会约束转化为确定性等价形式; 提出基于神经网络增强的区域粒子群优化(neural network-enhanced regional particle swarm optimization, NN-RPSO)算法, 通过构建虚拟电厂行为预测模型替代频繁调用下层优化, 结合区域划分策略实现高效搜索。【结果】决策者可通过调节风险预算参数在运行风险与成本间权衡; 所提算法相较于区域粒子群优化算法在提升配电网运营商收益 47.2% 的同时, 减少下层模型调用次数约 67.4%。【结论】所提模型为决策者提供了灵活应对不确定性的建模手段, 所提求解算法显著提升了求解质量, 为多主体主从博弈问题提供了有效解决方案。

关键词: 多虚拟电厂; 配电网运营商; 主从博弈; 分布鲁棒优化; 动态定价; 神经网络增强的区域粒子群优化(NN-RPSO)算法

中图分类号: TM73

文献标志码: A

文章编号: 1000-7229(2026)10-0166-15

DOI: 10. 12204/j. issn. 1000-7229. 2026. 10. 013

Distributionally Robust Optimization-Based Dynamic Pricing Model and Solution Method for Multiple Virtual Power Plants in a Stackelberg Game

CHEN Qu, YANG Ping, CHEN Nianhao, LIU Genrao, YAN Lu

(School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, China)

ABSTRACT: [Objective] To address the Stackelberg game between multiple virtual power plants (VPP) and a distribution system operator (DSO), where existing dynamic pricing models fail to adequately account for the impact of renewable energy output uncertainty on game strategies, and conventional solution methods suffer from poor performance in high-dimensional decision spaces, this paper proposes a dynamic pricing model and solution method based on distributionally robust optimization (DRO) within a Stackelberg game framework. [Methods] A Stackelberg game dynamic pricing model is formulated with the DSO as the leader and multiple VPPs as followers. In the VPP optimization subproblem, a distributionally robust chance constraint is introduced to capture wind power output uncertainty. An ambiguity set is constructed using only the first and second moments of wind power, and the chance constraint is transformed into a deterministic equivalent via the Cantelli inequality. Moreover, a neural network-enhanced regional particle swarm optimization (NN-RPSO) algorithm is proposed, which constructs a predictive model of VPP behavior to replace frequent calls to the lower-level optimization, and incorporates a regional partitioning strategy to enable efficient search. [Results] The results show that decision-makers can trade off operational risk against cost by adjusting the risk budget parameters. Compared with the regional particle swarm optimization (RPSO) algorithm, the proposed NN-RPSO increases the DSO's revenue by 47.2% while reducing the number of lower-level model calls by approximately 67.4%. [Conclusions] The proposed DRO model provides decision-makers with a flexible means to handle uncertainty, and the proposed algorithm markedly enhances solution quality, offering an effective approach for the multi-agent Stackelberg game problem.

This work is supported by National Key Research and Development Program of China(No. 2023YFB4203102)and Shanxi Major Science and Technology Special Project(No. 202501150302001).

KEYWORDS: multiple virtual power plants; distribution system operator; Stackelberg game; distributionally robust optimization; dynamic pricing; neural network-enhanced regional particle swarm optimization(NN-RPSO)

0 引言

在“双碳”目标深入推进和新型电力系统加快建设背景下,分布式电源、储能系统、柔性负荷及微型燃气轮机等分布式资源在配电网中的接入规模不断扩大^[1-2]。虚拟电厂(virtual power plant, VPP)作为一种高效的分布式资源聚合管理形式^[3],能够整合各类分布式资源构成虚拟整体参与电网运行与电力市场交易^[4],提升系统灵活性与运行经济性^[5-7]。与此同时,配网运营商(distribution system operator, DSO)作为配电网的运行主体,承担着协调各 VPP 与上级电网之间电能交易的重要职责^[8]。随着社会资本逐步涌入电力市场,未来不同 VPP 将可能隶属于不同的利益主体^[9],形成多决策主体相互竞争的博弈格局^[10-12]。在此背景下,如何合理制定 DSO 与多个 VPP 之间的交易价格,激励 VPP 灵活调度内部资源,同时兼顾各主体利益,成为亟待解决的关键问题。

主从博弈理论为刻画多主体分层决策与策略互动提供了有效的分析框架^[13-16],目前已有学者将主从博弈应用于 DSO 与多 VPP 的交互分析中。文献[17]建立了以电网运营商为领导者、虚拟电厂为跟随者的主从博弈模型,并引入纳什谈判理论实现多 VPP 间的合作收益分配。文献[18]针对不同投资商偏好下虚拟电厂灵活性资源构成差异,构建了运营商与多虚拟电厂的双层主从博弈模型,研究运营商的动态定价与 VPP 优化运行的交互影响。文献[19]构建了电-碳-绿证市场耦合下的 DSO 与多 VPP 联合交易框架,建立了以 DSO 为领导者、多 VPP 为跟随者的主从博弈模型,研究多市场耦合环境下的动态定价与竞价策略。上述研究为理解 DSO 与多 VPP 的博弈关系奠定了基础,但均假设 VPP 内部资源确定可调^[17-20],未充分考虑风电出力不确定性对 VPP 调度策略及博弈均衡的潜在影响。事实上,新能源出力的波动性与随机性会显著改变 VPP 的边际成本曲线和可调节能力,进而影响其对价格信号的响应行为。针对 VPP 内部不确定性调度问题,现有研究多采用随机规划^[21]或传统鲁棒优化方法^[22-23],但是随机规划需要已知风电出力的精确概率分布,在实际工程中难以准确获取。鲁棒优化虽不依赖分布信息,但其决策结果往往过于保守,易牺牲系统运行的经济性,难以在鲁棒性与经济性之间取得平衡。相比之下,

分布鲁棒优化融合了随机优化和鲁棒优化的优点,仅需不确定参数的部分信息即可构造模糊集,无需精确分布,同时通过优化最坏情况下的期望性能避免了经典鲁棒优化的过度保守。根据模糊集构造方式,分布鲁棒优化主要分为基于矩信息^[24]的方法和基于概率距离^[25-26]的方法。文献[27]进一步将分布鲁棒优化与主从博弈定价相结合,应用于共享储能优化配置问题中,验证了该协同建模框架的有效性。此外,考虑到实际运行中不确定性来源的多样性,文献[28]针对虚拟电厂与配电网的交互问题,同时考虑了新能源出力和电价的双重不确定性,并采用交替方向乘子法进行分布式求解,在保护双方隐私的同时实现了多类型不确定性协同优化。然而,这些不确定性处理方法尚未被有效融入 DSO 与多 VPP 的主从博弈分析框架中,亟需开展进一步研究。

在主从博弈模型的求解方面,现有方法主要分为基于 Karush-Kuhn-Tucker(KKT)条件的数值优化方法^[29-31]和启发式智能算法^[32-34]两类。KKT 条件法可将双层优化模型转化为单层混合整数规划问题求解,但要求下层问题为凸规划,且需要获取下层所有参数信息,涉及 VPP 内部数据的隐私保护问题,实际应用中存在较大局限性^[35]。启发式智能算法虽避免了 KKT 条件法对下层模型可微性和凸性的要求,但需要大量调用下层博弈模型进行适应度评估,计算繁复、效率低下,难以满足多时段、多 VPP 场景下的求解需求^[36-37]。针对上述问题,文献[20]提出基于 Kriging 元模型的求解算法,通过元模型拟合替代 VPP 能量管理模型,减少对下层优化模型的调用次数,在保护 VPP 隐私的同时提高求解效率,该方法在处理高维决策空间时仍面临模型精度与计算效率的权衡问题。文献[38]针对一主多从博弈模型,提出 Kriging 元模型与遗传优化算法相结合的求解方法,在简化计算量的同时求解出双方的均衡解。然而,该方法在处理高维决策空间时仍面临模型精度与计算效率的权衡问题,且对初始样本点的选取较为敏感。文献[39]提出了一种统计隐私保护的在线分布式算法,能够在保护参与者隐私的同时,实时跟踪动态博弈环境下的均衡解,但该方法要求博弈模型具有强单调性以保证收敛,且仅适用于特定结构的聚合博弈。

鉴于此,本文提出基于分布鲁棒优化的 DSO-多

VPP 主从博弈动态定价模型及求解方法。在建模层面,引入分布鲁棒机会约束描述风电出力不确定性,仅需已知风电功率的一阶矩和二阶矩信息,即可构造模糊集刻画所有可能概率分布,并通过 Cantelli 不等式将机会约束转化为确定性等价形式,在保证鲁棒性的同时降低模型保守性,实现经济性与鲁棒性的协同优化。在求解层面,提出一种基于神经网络增强的区域粒子群优化(neural network-enhanced regional particle swarm optimization, NN-RPSO)算法,通过构建 VPP 行为预测模型,减少了对下层优化模型的频繁调用,结合区域划分策略实现决策空间的高效搜索,在保护 VPP 隐私的前提下显著提升求解质量。通过算例分析验证所提模型与方法的有效性与优越性。

1 DSO-多 VPP 主从博弈框架

DSO-多 VPP 主从博弈架构如图 1 所示。在该架构中,博弈参与者包括一个 DSO 和多个 VPP,各自有不同的利益目标和决策变量。




图 1 DSO-多 VPP 主从博弈架构

Fig. 1 DSO-multiple VPPs Stackelberg game framework

DSO 作为博弈的领导者,负责制定各时段购售电价,其目标是其自身净利润最大化,即通过与上级电网和 VPP 之间进行电能交易获取收益。DSO 的定价策略直接影响 VPP 的用能行为,进而影响到系统最终的功率平衡与经济性。

VPP 作为博弈中的跟随者,聚合了微型燃气轮机、储能系统、柔性负荷和风电机组等多种分布式资源。VPP 的优化目标是在确保内部负荷用电需求的情况下最小化运行成本,包括电能交易成本、设备运行成本和应对风电不确定性所付出的备用成本。VPP 根据 DSO 发布的价格信号来优化调度内部资源,

并确定与 DSO 的交易电量。

在上述主从博弈框架下,DSO 与 VPP 之间形成了动态的策略互动关系。DSO 作为先行者,首先制定并发布各时段购售电价,VPP 则作为跟随者,在接收电价信号后优化内部资源配置,确定与 DSO 的交易电量并反馈执行。DSO 根据所有 VPP 的总体响应情况评估自身收益,若当前收益并非最优或存在提升空间,则重新调整定价策略以引导 VPP 改变用电行为。这一过程并非单向的价格传导,而是双向的策略迭代:VPP 的调度决策依赖 DSO 的价格信号,而 DSO 的价格优化又取决于 VPP 的响应结果。双方在反复交互中不断修正自身策略,直至 DSO 无法通过单方面调整电价进一步提升收益,且各 VPP 也无法在当前电价下进一步降低运行成本时,博弈达到均衡状态。该均衡解揭示了 DSO 最优定价策略与 VPP 最优响应行为之间的内在均衡关系,为实现系统经济运行提供了理论依据。

2 DSO-多 VPP 主从博弈模型

2.1 领导者 DSO 优化模型

DSO 作为博弈的领导者,其博弈策略集 Ω^{DSO} 包括运营商为虚拟电厂制定的各个时段的购电价 $\lambda_t^{\text{D},\text{b}}$ 和售电价 $\lambda_t^{\text{D},\text{s}}$,记为:

$$\Omega^{\text{DSO}} = \{\lambda_t^{\text{D},\text{b}}, \lambda_t^{\text{D},\text{s}}\} \quad (1)$$

DSO 以最大化其净利润 C^{DSO} 为目标函数,包括与上级电网以及下级 VPP 的购售电成本与收益,具体表达式为:

$$\begin{aligned} \max C^{\text{DSO}} = & \sum_{t=1}^T (\lambda_t^{\text{W},\text{s}} P_t^{\text{DSO},\text{s}} - \lambda_t^{\text{W},\text{b}} P_t^{\text{DSO},\text{b}} + \\ & \lambda_t^{\text{D},\text{b}} \sum_{i=1}^N P_{i,t}^{\text{VPP},\text{b}} - \lambda_t^{\text{D},\text{s}} \sum_{i=1}^N P_{i,t}^{\text{VPP},\text{s}}) \end{aligned} \quad (2)$$

式中: T 为调度周期内的总时段数; N 为 VPP 个数; $\lambda_t^{\text{W},\text{b}}$ 、 $\lambda_t^{\text{W},\text{s}}$ 分别为上级电网的购、售电价; $P_t^{\text{DSO},\text{b}}$ 、 $P_t^{\text{DSO},\text{s}}$ 分别为 DSO 向上级电网的购、售电量; $P_{i,t}^{\text{VPP},\text{b}}$ 、 $P_{i,t}^{\text{VPP},\text{s}}$ 分别为第 i 个 VPP 向 DSO 的购电电量和售电电量。为保证各 VPP 之间的供需平衡, $P_t^{\text{DSO},\text{b}}$ 和 $P_t^{\text{DSO},\text{s}}$ 的表达式为:

$$\begin{cases} P_t^{\text{DSO},\text{s}} = \begin{cases} P_t^{\text{DSO},\text{s}} & P_t^{\text{DSO},\text{s}} > 0 \\ 0 & P_t^{\text{DSO},\text{s}} \leq 0 \end{cases} \\ P_t^{\text{DSO},\text{b}} = \begin{cases} 0 & P_t^{\text{DSO},\text{s}} > 0 \\ -P_t^{\text{DSO},\text{s}} & P_t^{\text{DSO},\text{s}} \leq 0 \end{cases} \\ P_t^{\text{DSO}} = \sum_{i=1}^N (P_{i,t}^{\text{VPP},\text{s}} - P_{i,t}^{\text{VPP},\text{b}}) \end{cases} \quad (3)$$

式中: P_t^{DSO} 为 DSO 与各 VPP 交易后的电量,数值为正表示电量剩余,需要向上级电网售电,数值为负表示

电量缺额,需要向上级电网购电。

为确保 VPP 愿意与 DSO 进行电能交易,DSO 制定的购电价格需不大于电网电价,售电价格需不小于上网电价,这种情况下 VPP 为保证自身利益最大化,会选择与 DSO 进行交易,具体约束为:

$$\lambda_t^{W,s} \leq \lambda_t^{D,s} \leq \lambda_t^{D,b} \leq \lambda_t^{W,b} \quad (4)$$

需要说明的是,本文聚焦于 DSO 与多 VPP 的经济博弈关系,暂未考虑配电网内部的物理运行约束,该简化处理与文献[17-20]保持一致。

2.2 跟随者 VPP 优化模型

VPP 作为博弈的跟随者,其博弈策略集 Ω^{VPP} 为:

$$\Omega^{VPP} = \{P_t^{VPP,s}, P_t^{VPP,b}, P_{j,t}^{MT}, P_{j,t}^{ch}, P_{j,t}^{dch}, P_{j,t}^{IL}, P_{j,t}^W\}, j \in N_j \quad (5)$$

式中:下标 j 为第 j 个分布式资源; N_j 为 VPP 所包含的分布式资源的集合; $P_t^{VPP,s}$ 、 $P_t^{VPP,b}$ 分别为 VPP 向 DSO 出售的电量和购买的电量; $P_{j,t}^{MT}$ 为微型燃气轮机的功率; $P_{j,t}^{ch}$ 、 $P_{j,t}^{dch}$ 分别为储能的充、放电功率; $P_{j,t}^{IL}$ 为柔性负荷的功率; $P_{j,t}^W$ 为风电机组的计划功率。

VPP 以运行成本 C^{VPP} 最小为目标函数,包括电能交易成本 C^{ele} 、微型燃气轮机成本 C_j^{MT} 、储能运行成本 C_j^{BESS} 、可中断负荷成本 C_j^{IL} 以及应对风电出力不确定性所需要的备用容量成本 C_j^W ,具体为:

$$\begin{cases} \min C^{VPP} = C^{ele} + \sum_{j \in N_j} (C_j^{MT} + C_j^{BESS} + C_j^{IL} + C_j^W) \\ C^{ele} = \sum_{t=1}^T (\lambda_t^{D,b} P_t^{VPP,b} - \lambda_t^{D,s} P_t^{VPP,s}) \\ C_j^{MT} = a_j (P_{j,t}^{MT})^2 + b_j P_{j,t}^{MT} + c_j \\ C_j^{BESS} = \lambda_j^{BESS} (P_{j,t}^{ch} + P_{j,t}^{dch})^2 \\ C_j^{IL} = \lambda_j^{IL} P_{j,t}^{IL} \\ C_j^W = c_{up} R_{j,t}^{up} + c_{dn} R_{j,t}^{dn} \end{cases} \quad (6)$$

式中: a_j 、 b_j 、 c_j 为微型燃气轮机的成本系数; λ_j^{BESS} 为储能的运行成本系数; c_{up} 、 c_{dn} 分别为风机向上、向下备用成本系数; $R_{j,t}^{up}$ 、 $R_{j,t}^{dn}$ 分别为风机向上、向下备用容量,向上备用表示风电实际功率低于计划功率时所需要的备用容量,向下备用则相反。

VPP 在对 DSO 制定的价格进行响应的过程,需满足内部各类型分布式资源的运行约束以及功率平衡约束。

对于整体而言,需要考虑功率平衡约束以及 VPP 的购售电量约束:

$$\begin{cases} P_t^{VPP} = P_t^{VPP,b} - P_t^{VPP,s} \\ P_t^{VPP} + \sum_{j \in N_j} (P_{j,t}^{MT} + P_{j,t}^{dch} - P_{j,t}^{ch} + P_{j,t}^{IL} + P_{j,t}^W) = \sum_{j \in N_j} P_{j,t}^{LD} \\ P_t^{VPP,b} \cdot P_t^{VPP,s} = 0 \\ 0 \leq P_t^{VPP,b} \leq P_t^{VPP,b,max} \\ 0 \leq P_t^{VPP,s} \leq P_t^{VPP,s,max} \end{cases} \quad (7)$$

式中: $P_{j,t}^{LD}$ 为负荷功率; $P_t^{VPP,b,max}$ 、 $P_t^{VPP,s,max}$ 分别为 VPP 与 DSO 的购、售电量上限。

对于微型燃气轮机,考虑其功率约束与爬坡约束:

$$\begin{cases} 0 \leq P_{j,t}^{MT} \leq P_{j,t}^{MT,max} \\ P_{j,t}^{MT} \leq P_{j,t}^{MT} - P_{j,t-1}^{MT} \leq P_{j,t}^{MT} \end{cases} \quad (8)$$

式中: $P_{j,t}^{MT,max}$ 为微型燃气轮机的功率上限; $P_{j,t}^{MT}$ 、 $P_{j,t}^{MT}$ 分别为其向上、向下的爬坡率。

对于储能,考虑其充放电功率约束、能量约束以及状态转移方程:

$$\begin{cases} 0 \leq P_{j,t}^{ch}, P_{j,t}^{dch} \leq P_{j,t}^{BESS,max} \\ P_{j,t}^{ch} \cdot P_{j,t}^{dch} = 0 \\ 0 \leq E_{j,t}^{BESS} \leq E_{j,t}^{BESS,max} \\ E_{j,t}^{BESS} = E_{j,t-1}^{BESS} + \eta_j^{ch} P_{j,t-1}^{ch} - P_{j,t-1}^{dch} / \eta_j^{dch} \\ E_{j,0}^{BESS} = E_{j,T}^{BESS} \end{cases} \quad (9)$$

式中: $P_{j,t}^{BESS,max}$ 为储能充放电功率上限; $E_{j,t}^{BESS}$ 为储能的能量值; $E_{j,t}^{BESS,max}$ 为储能的能量值上限; η_j^{ch} 、 η_j^{dch} 分别为储能的充、放电效率。

对于柔性负荷,考虑其最大可中断量约束:

$$0 \leq P_{j,t}^{IL} \leq P_{j,t}^{IL,max} \quad (10)$$

式中: $P_{j,t}^{IL,max}$ 为柔性负荷的最大可中断量。

对于风电机组,考虑风电出力的不确定性,采用分布鲁棒优化模型进行描述。定义风电的实际出力为 $\tilde{P}_{j,t}^W$,并假设其真实概率分布未知,但其一阶矩(均值)已知为 $\mu_{j,t}$ 和二阶矩的方差存在且有上界 $\bar{\sigma}_{j,t}^2$,即:

$$\begin{cases} E(\tilde{P}_{j,t}^W) = \mu_{j,t} \\ \text{Var}(\tilde{P}_{j,t}^W) \leq \bar{\sigma}_{j,t}^2 \end{cases} \quad (11)$$

同时,考虑风电出力的物理约束,其取值受限于装机容量 $\bar{P}_j^W$,即支撑集为 $0 \leq \tilde{P}_{j,t}^W \leq \bar{P}_j^W$ 。基于上述矩信息与支撑集信息,可构造如下模糊集来描述所有可能的概率分布:

$$\mathcal{P}_{j,t} = \{ \mathbb{P}(\tilde{P}_{j,t}^W \in [0, \bar{P}_j^W]) = 1, \mathbb{P} \in \mathcal{P}_0(\mathbb{R}) \}$$

$$\mathbb{E}_{\mathbb{P}}(\tilde{P}_{j,t}^W) = \mu_{j,t}, \text{Var}_{\mathbb{P}}(\tilde{P}_{j,t}^W) \leq \bar{\sigma}_{j,t}^2 \quad (12)$$

式中: $\mathcal{P}_0(\mathbb{R})$ 表示 $\mathbb{R}$ 上所有概率分布的集合。

实际风电出力与计划风电出力之间存在的功率偏差即 VPP 所对应的功率缺额:

$$\Delta_{j,t} = P_{j,t}^W - \tilde{P}_{j,t}^W \quad (13)$$

为应对风电“出力不足”带来的功率不平衡风险,构造如下分布鲁棒机会约束:

$$\inf_{\mathbb{P} \in \mathcal{P}_{j,t}} \mathbb{P}(\Delta_{j,t} \leq R_{j,t}^{up}) \geq 1 - \alpha_{j,t} \quad (14)$$

式中: $\alpha_{j,t} \in (0, 1)$ 为风险预算参数,表示决策者可接受的功率缺额约束被违反的最大概率。该约束要求在所有可能的概率分布中,功率缺额不超过 $R_{j,t}^{up}$ 的最

小概率不低于 $1 - \alpha_{j,t}$ 。

将 $\Delta_{j,t}$ 的表达式代入 (14), 可得:

$$\inf_{P \in \mathcal{P}_{j,t}} \mathbb{P}(\tilde{P}_{j,t}^W \geq P_{j,t}^W - R_{j,t}^{up}) \geq 1 - \alpha_{j,t} \quad (15)$$

为便于求解,需将上述机会约束转化为确定性等价形式。令随机变量 $X = \tilde{P}_{j,t}^W$, 常数 $\gamma = P_{j,t}^W - R_{j,t}^{up}$, 则上述约束等价于:

$$\begin{aligned} \inf_{P \in \mathcal{P}_{j,t}} \mathbb{P}(X \geq \gamma) &\geq 1 - \alpha_{j,t} \Leftrightarrow \\ \sup_{P \in \mathcal{P}_{j,t}} \mathbb{P}(X < \gamma) &\leq \alpha_{j,t} \end{aligned} \quad (16)$$

即问题转化为:在所有满足矩条件的分布中,违约事件 $\{X < \gamma\}$ 发生概率的最大值不超过 $\alpha_{j,t}$ 。

根据 Cantelli 不等式^[40], 令 $a = \mu_{j,t} - \gamma$, 为保证 $a \geq 0$, 需满足 $\mu_{j,t} \geq \gamma$, 即 $R_{j,t}^{up} \geq P_{j,t}^W - \mu_{j,t}$, 则有:

$$\begin{aligned} \mathbb{P}(X < \gamma) &= \mathbb{P}(X - \mu_{j,t} < \gamma - \mu_{j,t}) = \\ \mathbb{P}(X - \mu_{j,t} < -a) &\leq \mathbb{P}(X - \mu_{j,t} \leq -a) \leq \\ \frac{\bar{\sigma}_{j,t}^2}{\bar{\sigma}_{j,t}^2 + a^2} \end{aligned} \quad (17)$$

因此,对任意 $P \in \mathcal{P}_{j,t}$, 均有 $\mathbb{P}(X < \gamma) \leq \bar{\sigma}_{j,t}^2 / (\bar{\sigma}_{j,t}^2 + a^2)$, 从而有 $\sup_{P \in \mathcal{P}_{j,t}} \mathbb{P}(X < \gamma) \leq \bar{\sigma}_{j,t}^2 / (\bar{\sigma}_{j,t}^2 + a^2)$, 为满足

$\sup_{P \in \mathcal{P}_{j,t}} \mathbb{P}(X < \gamma) \leq \alpha_{j,t}$, 只需要保证 $\bar{\sigma}_{j,t}^2 / (\bar{\sigma}_{j,t}^2 + a^2) \leq \alpha_{j,t}$ 。

求解该不等式并回代 a 可以得到:

$$R_{j,t}^{up} \geq P_{j,t}^W - \mu_{j,t} + \sqrt{\frac{1 - \alpha_{j,t}}{\alpha_{j,t}}} \bar{\sigma}_{j,t} \quad (18)$$

类似地,考虑“风电出力过剩”导致的反向功率不平衡风险,可得相应的确定性约束:

$$R_{j,t}^{dn} \geq \mu_{j,t} - P_{j,t}^W + \sqrt{\frac{1 - \alpha_{j,t}}{\alpha_{j,t}}} \bar{\sigma}_{j,t} \quad (19)$$

综合式 (18) 和式 (19), 原分布鲁棒机会约束可等价转化为一对线性确定性约束, 从而可直接嵌入优化模型中求解。需要指出的是, 所提分布鲁棒机会约束方法可自然推广至光伏出力、电动汽车充电负荷等其他类型的不确定性场景。对于光伏出力, 其出力波动可采用相同的矩信息框架进行描述, 仅需将模型中的风电功率替换为光伏功率即可。对于多源不确定性的叠加场景, 可将净负荷不确定性视为多个随机变量的组合, 利用随机变量之和的均值和方差公式进行处理, 仍保持在本文的分布鲁棒框架内。

综上, 本章所建立的 DSO-多 VPP 主从博弈模型可以表述为:

$$\begin{cases} \max_{\lambda^{D,b}, \lambda^{D,s}} C^{DSO}(\lambda^{D,b}, \lambda^{D,s}, P^{VPP,b}, P^{VPP,s}) \\ \text{s.t.} (P^{VPP,b}, P^{VPP,s}) = \arg \min C^{VPP}(\lambda^{D,b}, \lambda^{D,s}) \end{cases} \quad (20)$$

式中: $\lambda^{D,b}$ 、 $\lambda^{D,s}$ 分别为 DSO 制定的 24 个时段购、售电

价组成的向量; $P^{VPP,b}$ 、 $P^{VPP,s}$ 为所有 VPP 的交易电量响应。为增强模型的理论完整性, 本文对所建主从博弈模型的 Stackelberg 均衡存在性及唯一性问题^[41]进行了进一步讨论, 详见附录 A。

3 主从博弈模型求解方法

第二章构建了 DSO 与多 VPP 的一主多从博弈模型, 其中下层各 VPP 需要求解混合整数规划问题。该类双层优化问题具有非线性、非凸性的特点, 难以直接求解。传统求解方法主要有基于 KKT 条件的数值优化方法和启发式智能算法 2 类。KKT 条件法可将双层模型转化为单层优化, 但要求下层问题为凸规划, 且需要获取下层所有参数信息, 涉及 VPP 隐私保护问题。启发式智能算法虽避免了 KKT 条件法对下层模型可微性和凸性的要求, 但需要大量调用下层博弈模型, 计算繁复、效率低下。为克服上述问题, 本章提出 NN-RPSO 算法。该算法通过 NN 模型预测 VPP 对价格的响应行为, 减少对下层优化模型的调用次数, 并结合区域划分策略, 综合提高算法求解精度和收敛速度。

NN-RPSO 算法的核心在于 3 个层面的设计: 首先, 通过 NN 模型来学习并预测 VPP 对价格信号的响应行为, 从而大幅减少对下层真实优化模型的调用; 其次, 采用 K-means 算法进行区域划分, 实现对高维决策空间的有效分割; 最后, 在各个区域内实施精细化搜索。

3.1 基于 NN 的 VPP 响应行为建模

若直接在优化迭代中反复调用下层 VPP 的优化模型, 计算开销将难以承受。为此, 本文首先构建 VPP 行为的替代预测模型。具体做法是: 通过拉丁超立方采样 (Latin hypercube sampling, LHS) 生成 K 个初始样本点, 每个样本点坐标代表一组 DSO 制定的售电价和购电价 $\{(\lambda_k^{D,b}, \lambda_k^{D,s})\}$, $k=1, 2, \dots, K$, 并且将每组购售电价代入式 (20) 的下层优化模型进行求解, 得到对应的各个 VPP 的交易电量信息 $q^{VPP} = \{q_k^{VPP}\}$, $k=1, 2, \dots, K$, 至此, 初始样本数据集 $B = \{x, q^{VPP}\}$, $x = \{(\lambda_k^{D,b}, \lambda_k^{D,s})\}$, $k=1, 2, \dots, K$ 构建完毕。

在此基础上, 本文选用循环神经网络 (recurrent neural network, RNN) 来刻画 VPP 响应行为背后的非线性映射规律:

$$\hat{q}^{VPP} = f_{\theta}(x) \quad (21)$$

式中: $f_{\theta}(\cdot)$ 表示参数为 θ 的 RNN 模型, 对于 RNN 的最佳超参数通过高斯过程回归来实现; $\hat{q}^{VPP}$ 为 VPP 响应的预测值。

3.2 基于收益密度的决策空间划分

DSO的决策空间由24个时段的购电价与售电价构成,维度高达48维。若直接在这个高维空间内进行全局搜索,极易陷入“维数灾难”。为提升搜索的针对性,本文提出一种基于收益密度的空间划分策略。

首先,将初始样本集 B 代入式(2)得到对应DSO收益 $C^{DSO} = \{C_k^{DSO}\}, k = 1, 2, \dots, K$,然后,采用K-means聚类算法对样本点进行分组,但与传统聚类不同的是,这里的聚类中心并非随机初始化,而是由各区域内当前已知的最高收益点引导确定。聚类完成后得到 M 个关键区域 R_m :

$$R_m = \{(\mathbf{x}_k, q_k^{VPP}) | \mathbf{x}_k \in C_m\}, m = 1, 2, \dots, M \quad (22)$$

式中: C_m 表示第 m 个聚类簇。区域划分确保了在高收益区域分配更多计算资源,提高了优化效率,后续的优化搜索将主要在这些高价值区域内展开,而非在整个决策空间中盲目探索。

3.3 基于NN-RPSO的局部搜索机制

在每个关键区域 R_m 内,应用NN-RPSO算法进行局部搜索。PSO算法中,每个粒子代表一个可能的DSO定价策略,其位置更新式为:

$$\begin{cases} \mathbf{v}_i^{o+1} = \omega \mathbf{v}_i^o + c_1 r_1 (\mathbf{p}_i^o - \mathbf{x}_i^o) + c_2 r_2 (\mathbf{g}^o - \mathbf{x}_i^o) \\ \mathbf{x}_i^{o+1} = \mathbf{x}_i^o + \mathbf{v}_i^{o+1} \end{cases} \quad (23)$$

式中: $\mathbf{v}_i^o, \mathbf{x}_i^o$ 分别为第 o 代第 i 个粒子的速度和位置; $\mathbf{p}_i^o$ 为个体历史最优位置; $\mathbf{g}^o$ 为全局最优位置; ω 为惯性权重; c_1, c_2 为加速系数; r_1, r_2 为 $[0, 1]$ 区间内的随机数。

为避免在迭代过程中频繁调用真实下层模型进行收益评估,本文引入两阶段筛选机制:首先,利用训练好的RNN模型快速预测VPP在当前电价下的响应电量,并据此估算DSO的近似收益;基于该近似值,筛选出表现优异的候选电价策略;随后,仅对这些通过初筛的优质解调用真实的VPP优化模型进行精确验证。这一机制有效地将昂贵的计算资源聚焦于最有希望的搜索方向上。

综合上述各环节,本文所提的NN-RPSO算法的流程如图2所示。

具体步骤为:

步骤1:初始化模型参数,包括DSO与上级电网的购售电价、VPP模型参数、NN-RPSO算法相关参数。

步骤2:通过LHS生成DSO的初始样本点 $\mathbf{x}$,并将其代入下层模型以获取 q^{VPP} ,从而得到初始样本集 B 。

步骤3:依据步骤2构建的初始样本集,对每个




图2 NN-RPSO算法流程

Fig. 2 Flowchart of the NN-RPSO algorithm

VPP建立NN模型,在输入最优参数后进行训练。

步骤4:计算每组样本点对应的DSO的目标函数值 C^{DSO} ,采用K-means聚类算法对样本集进行分组,聚类中心由区域内最高收益点确定,从而形成 M 个关键区域。

步骤5:在每个关键区域 R_m 上,采用NN-RPSO算法求解局部最优电价 λ_m^{opt} ,然后调用下层模型获取各个VPP交易电量的真实值,最后计算出上层模型目标函数的真实值 $C_m^{DSO, opt}$,在区域内迭代最终求得区域 m 的最优解 $C_m^{DSO, best}$ 。

步骤6:比较所有区域最优解,得到当前迭代步的全局最优解。

步骤7:判断是否满足收敛条件,若满足则停止迭代,输出最优解,否则返回步骤5。

4 算例分析

4.1 参数设置

本文选取某地区DSO与3个VPP构成的主从博弈系统进行算例仿真分析。调度周期取24h,单位调度时长为1h。各个VPP的风电机组出力均值预测曲线、标准差上限曲线和负荷预测曲线如附录B图B1所示,其余分布式资源的相关数据参考文献[20]。各时段购售价格区间如附录B图B2所示。

4.2 模型验证

为检验RNN模型的有效性,在此将RNN模型与多层感知器(multi-layer perceptron, MLP)模型、前馈神经网络(feedforward neural network, FNN)模型、长短期记忆(long short-term memory, LSTM)网络模型和Kriging模型进行对比实验。实验前使用LHS法生成1000个样本点,用于训练模型。

模型训练结果如表1所示,表1中展示了不同模型的平均绝对误差(mean absolute error, MAE)、决定

表 1 模型训练结果
Table 1 Model training results

模型	MAE			R^2			训练时间/s		
	VPP1	VPP2	VPP3	VPP1	VPP2	VPP3	VPP1	VPP2	VPP3
RNN	0.164 3	0.247 4	0.357 6	0.713 0	0.771 7	0.800 0	5.2	6.8	6.8
FNN	0.193 0	0.345 9	0.559 9	0.638 7	0.606 0	0.595 3	2.0	2.6	2.9
MLP	0.174 8	0.337 4	0.566 0	0.626 6	0.612 1	0.582 1	1.5	1.7	1.7
LSTM	0.295 0	0.502 2	0.818 0	0.096 5	0.124 0	0.192 3	8.8	8.9	10.1
Kriging	0.124 6	0.243 7	0.408 9	0.758 0	0.767 2	0.760 0	36.5	35.6	38.1

系数 R^2 以及模型训练时间。通过训练结果可以看出,在预测精度方面,RNN模型在3个VPP模型中,预测精度与Kriging模型不相上下,两者预测性能相当接近。然而在训练效率方面,RNN模型展现出显著优势,其训练时间远低于Kriging模型,训练速度提升约5~7倍。反观其他NN模型训练精度并不高,这表明RNN结构更适合捕捉VPP响应的动态特征。综合考虑预测精度与计算效率的权衡,RNN模型实现了最佳平衡,因此,本文选择RNN模型作为VPP响应预测的核心模型,以在保证预测精度的同时兼顾计算效率。

4.3 不同方案对比分析

本文设置了4种方案,分别对应“是否采用动态分时电价”与“是否引入分布鲁棒优化”两类机制的组合,具体设置情况如表2所示。

表 2 方案设置
Table 2 Scenario settings

方案	动态分时电价	分布鲁棒优化
1	×	×
2	√	×
3	×	√
4	√	√

注:√表示引入;×表示不引入。

不同方案的仿真结果如表3所示。可以看出,动态分时电价机制和分布鲁棒优化对VPP成本和DSO收益均有显著影响。首先,动态分时电价机制能够引导VPP调整用电行为,在电价低谷时增加购电、高峰时增加售电,从而降低自身成本。对比方案1和方案2,3个VPP总成本从125 340元降至101 630元,降幅达18.9%。同时,VPP的售电量从81.80 MWh提升至105.08 MWh,购电量从53.11 MWh提升至55.59 MWh,总交易电量提升了19%,说明动态电价有效激励了VPP参与市场交易,降低了对上级电网的依赖,提升了系统运行经济性。

其次,分布鲁棒优化模型通过考虑风电不确定

表 3 不同调度方案对比
Table 3 Comparison of different scheduling schemes

方案	VPP	VPP成本/ 元	VPP总购电 量/MWh	VPP总售电 量/MWh	DSO运营 收益/元
1	1	66 045	53.11	81.80	12 161
	2	31 917			
	3	-9668			
2	1	28 623	55.59	105.08	19 145
	2	1914			
	3	-30 438			
3	1	68 956	43.90	137.07	14 923
	2	41 091			
	3	9834			
4	1	67 025	45.21	141.75	15 501
	2	41 091			
	3	9225			

性并预留备用容量,显著改变了VPP的运营策略。对比方案2和方案4,VPP总成本有所上升,这是因为分布鲁棒优化模型引入了备用成本,VPP需要为应对风电波动预留额外容量,导致成本增加。但值得注意的是,分布鲁棒优化使得VPP的售电量从105.08 MWh大幅提升至141.75 MWh,购电量从55.59 MWh降至45.21 MWh,表明在考虑不确定性后,VPP倾向于更多利用本地资源和向DSO售电来平衡风险。

最后,动态电价与分布鲁棒优化的协同作用体现在DSO收益上。方案2的DSO收益为19 145元,方案4的DSO收益为15 501元,方案3的DSO收益为14 923元。这表明虽然本文所构建的模型增加了VPP成本,但也促使VPP更多参与市场交易,促进电能电量的就近就地平衡,同时也让DSO通过赚取购售电价差获得了可观收益。然而,方案4的DSO收益略低于方案2,这是因为VPP预留备用,减少了可灵活调度的容量,部分削弱了动态电价的激励效果。整体而言,动态分时电价主要引导VPP优化日常运营,而分布鲁棒优化模型则增强了系统应对不确定

性的能力,两者结合可在风险与收益之间取得平衡。

4.4 主从博弈结果分析

基于 4.3 节中的方案 4,本节对 DSO-VPP 主从博弈的均衡策略进行解析。图 3 展示了 DSO 优化的内部电价曲线,内部购售电价均严格位于上级电网电价的可行区间内。值得注意的是,内部购电价为 08:00—16:00 时段多次出现购电价等于售电价的情况,这表明 DSO 在这些时段选择让渡部分价差收益,激励 VPP 在该时段内进行电能交易,从而获得更大的交易量,最终实现自身收益最大化。




图 3 DSO 内部购售电价

Fig. 3 Internal purchase and sale prices of DSO

图 4 揭示了 3 个 VPP 不同的交易模式,VPP1 和 VPP2 呈现出比较明显的“昼售夜购”特征;而 VPP3 因风电装机容量较大,全天保持净售电状态,尤其在 13:00—17:00 时段达到售电峰值。这种差异化响应印证了 DSO 电价策略的有效性:同一价格信号能够根据不同 VPP 的资源禀赋,引导出差异化的市场行为。对比图 3 和图 4 也可以发现,VPP 的购售电行为与内部电价呈现高度相关性:当内部购电价处于相对高位时,如时段 12:00—20:00,此时 VPP3 的售电量也大幅增加。






图 4 VPP 与 DSO 交易电量情况

Fig. 4 Electricity trading volume between VPP and DSO


3 个 VPP 的详细调度方案如图 5 所示。从仿真结果可以发现,在电价高峰时段 VPP 通过燃气轮机增发、储能放电和柔性负荷削减三重手段释放供电能力,这正是价格信号驱动下灵活性资源响应的具体体现。



(a) VPP1



(b) VPP2



(c) VPP3

图 5 VPP 调度方案

Fig. 5 Scheduling scheme of VPP

4.5 不确定性分析

在分布鲁棒优化框架下,VPP 需为风电不确定性预留备用容量以应对实时波动风险。3 个 VPP 的风电计划出力、波动区间及备用配置情况如图 6 所示。

从仿真结果可以看出,当风电出力波动上界降低时,系统正负备用也会随之降低。这是因为风电




图6 VPP风电出力及备用配置情况
Fig. 6 Wind power output and reserve allocation of VPP

的不确定性减小,系统面临的风险减少,所需的备用容量自然相应减少。当计划风电出力大于风电出力均值时,即调度计划更激进,那么出现实际风电出力不足情况的概率就会增加,于是从图6中体现出来的结果就是系统正备用大于系统负备用。反之,当计划风电出力低于风电出力均值时,系统的调度策略变得更为保守,预计风电发电量较低,因此需要更多的负备用来应对可能的缺电风险,而正备用则相对减少。上述结果表明本文所提分布鲁棒优化模型在面对风电不确定性时,可以通过灵活调整备用容量来平衡电力供需,确保系统的可靠性与经济性。

不同风险预算水平下3个VPP的运行成本与备用成本变化见表4。随着风险预算从0.05增至0.20,各VPP的运行成本和备用成本均呈现下降趋势。以VPP1为例,运行成本由72 712元降至64 757元,备用成本由13 140元降至6610元,降幅分别达10.9%和49.7%。这是因为较大的风险预算意味着VPP可以接受更高的风电不确定性,从而减少备用容量配置,降低总体成本。

表4 不同风险预算下的VPP运行与备用成本
Table 4 VPP operation and reserve costs under different risk budgets

风险预算	VPP	运行成本/元	备用成本/元
0.05	1	72 712	13 140
	2	47 746	22 800
	3	22 750	45 783
0.10	1	67 025	9283
	2	41 091	15 917
	3	9225	31 935
0.15	1	64 344	7640
	2	38 097	13 057
	3	3714	26 119
0.20	1	64 757	6610
	2	36 292	11 221
	3	303	22 413

不同VPP对风险预算的敏感度存在差异。VPP3的风电装机容量最大,其备用成本降幅最为显著,表明高风电渗透率VPP对风险预算变化更为敏感。当风险预算从0.15增至0.20时,各VPP的成本降幅趋于平缓,边际效益递减。这表明风险预算的选取需要在经济性与可靠性之间权衡,较小的预算适用于高可靠性场景,较大的预算则有助于降低运营成本。实际运行中可通过调节风险预算参数来权衡风险与经济性,从而在可接受的可靠性水平下降低运行成本。

为验证本文所提方法在多源不确定性场景下的有效性,本文在附录C中补充了考虑风电-光伏多源不确定性的算例分析。结果表明,本文方法同样适用于多源不确定性场景,决策者仍可通过调节风险预算参数在运行风险与运行成本之间进行权衡。

4.6 求解方法对比分析

为验证本文所提NN-RPSO算法的有效性,选取PSO算法、遗传算法(genetic algorithm, GA)、布谷鸟搜索(cuckoo search, CS)算法、灰狼优化(grey wolf optimizer, GWO)算法、鲸鱼优化算法(whale

optimization algorithm, WOA)以及未引入 NN 加速的区域 PSO 算法(RPSO)作为对比方法,在相同测试环境下求解本文所提的主从博弈优化模型,结果如表 5 所示,各算法目标函数值的收敛过程如图 7 所示。

表 5 不同算法求解性能对比
Table 5 Performance comparison of different algorithms

算法	DSO 最优目标函数值/元	下层调用次数	算法求解时间/s
NN-RPSO	15 501	6288	687.857
RPSO	10 533	19 260	520.608
PSO	580	3120	87.524
GA	8380	2160	36.645
CS	-1780	3921	120.491
GWO	3549	480	14.704
WOA	5517	3240	86.492




图 7 不同算法收敛曲线对比
Fig. 7 Convergence curve comparison of different algorithms

如表 5 所示,NN-RPSO 算法获得了最高的 DSO 收益,显著优于其他算法。与未集成 NN 预测的 RPSO 算法相比,其收益提升了 47.2%,而下层模型调用次数减少了约 67.4%。这表明,NN 预测模型能够有效筛选潜在优质解,将精确计算资源集中于收益更高的决策空间区域,从而保证求解质量。

从图 7 可以看出,PSO、GA 与 WOA 等算法的收敛曲线在迭代初期快速上升后即进入平台期,表明其全局勘探能力不足,易陷入局部最优。尤其是 PSO,其最终收益仅为 580 元,验证了传统启发式算法在处理此类高维非凸博弈问题时的局限性。而 RPSO 算法虽在迭代中期表现出更优的探索性,收益有所提升,但其收敛过程存在波动,最终收益仍与全局最优存在差距。

相比之下,NN-RPSO 算法的收敛曲线表现出更高效特征。尽管其总运行时间最长,但这主要消耗于 NN 在迭代中廉价的预测计算,其目标函数值在迭代初期即迅速逼近最优值附近,且后续迭代过程平稳无振荡,这验证了 NN 引导机制的有效性。NN-

RPSO 的综合计算效率体现在以可接受的上层预测时间,置换掉了大量不可接受的下层优化求解时间,从而在解的最优性、求解过程的稳定性与核心计算资源消耗之间实现了更优的全局权衡。该方法为求解此类高维多主体主从博弈问题提供了一条有效路径。

5 结 论

本文以 DSO 与多 VPP 为研究对象,提出了基于分布鲁棒优化的主从博弈动态定价模型及求解方法。建立了以 DSO 为领导者、多 VPP 为跟随者的主从博弈框架,并在 VPP 优化模型中引入分布鲁棒机会约束描述风电出力不确定性,实现了经济性与鲁棒性的协同优化。针对模型求解难题,提出 NN-RPSO 算法,通过 NN 模型预测 VPP 响应行为并结合 K-means 方法进行区域划分,在保护 VPP 隐私的同时显著提升求解质量。所得结论如下:

1)针对风电出力不确定性,提出了基于分布鲁棒机会约束的 VPP 优化调度模型,仅需已知风电功率的一阶矩和二阶矩信息即可构造模糊集,通过 Cantelli 不等式将机会约束转化为确定性等价形式。决策者可通过调节风险预算参数在运行风险与运行成本之间进行权衡,在保证系统鲁棒性的同时降低保守性,实现安全性与经济性的协同优化。

2)构建了 DSO 与多 VPP 的一主多从博弈动态定价模型,DSO 通过优化内部购售电价引导 VPP 调整用电行为,VPP 根据价格信号灵活调度内部资源。仿真结果表明,动态分时电价机制使 VPP 总成本降低 18.9%,交易量提升 19%,有效激励了 VPP 参与市场交易,发挥了多类灵活性资源的调度潜力,降低了对上级电网的依赖,提升了系统运行经济性。

3)提出的 NN-RPSO 算法通过构建 VPP 行为预测模型替代频繁调用下层优化,结合基于收益密度的区域划分策略实现决策空间的高效搜索。算例验证表明,相较于未集成预测模型的 RPSO 算法,NN-RPSO 在提升 DSO 收益 47.2% 的同时,减少下层模型调用次数约 67.4%,在保护 VPP 隐私的前提下实现了求解质量的提升,为求解高维复杂主从博弈问题提供了有效路径。

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):
陈渠提出了研究方向,设计了研究思路、研究方案,进行了文献调研与整理、对比实验、实验分析;杨

苹确定了研究对象范围,设计了论文框架;陈年昊确定了研究对象范围,收集数据,采集、清洗与分析数据;刘根饶参与论文修订、论文最终版本修订;颜璐参与撰写论文、论文修订。所有作者均阅读并同意了论文终稿内容。

6 参考文献

- [1] 孙荣富,王歌,闵睿,等.面向新型电力系统的虚拟电厂交易机制设计[J/OL].电力系统自动化,2026-01-23. <https://link.cnki.net/urlid/32.1180.TP.20260122.1705.004>.
Sun Rongfu, Wang Ge, Min Rui, et al. Trading mechanism design of virtual power plants for new power system[J/OL]. Automation of Electric Power Systems, 2026-01-23. <https://link.cnki.net/urlid/32.1180.TP.20260122.1705.004>.
- [2] 高明,曾平良,冯永朝.新型电力系统中的虚拟电厂研究综述[J].电力工程技术,2025,44(6):143-154.
Gao Ming, Zeng Pingliang, Feng Yongchao. Review of virtual power plant in new power system[J]. Electric Power Engineering Technology, 2025, 44(6): 143-154.
- [3] 罗凌,陈甜甜,华珉,等.考虑点对点交易的虚拟电厂联盟协同优化策略[J].浙江电力,2025,44(12):55-66.
Luo Ling, Chen Tiantian, Hua Min, et al. A collaborative optimization strategy for virtual power plant alliance considering peer-to-peer trading[J]. Zhejiang Electric Power, 2025, 44(12): 55-66.
- [4] 宋铎洋,薛田良,李艺瀑,等.考虑风光不确定性的虚拟电厂合作博弈调度及收益分配策略[J].电力工程技术,2025,44(1):193-206.
Song Duoyang, Xue Tianliang, Li Yipu, et al. Cooperative game scheduling and revenue sharing strategy for virtual power plants considering scenery uncertainty[J]. Electric Power Engineering Technology, 2025, 44(1): 193-206.
- [5] 余英,王海云,王维庆,等.虚拟电厂参与下含高渗透可再生能源系统的运行策略[J].电测与仪表,2023,60(1):94-103.
Yu Ying, Wang Haiyun, Wang Weiqing, et al. Operation strategy of high permeability renewable energy with virtual power plant participation[J]. Electrical Measurement & Instrumentation, 2023, 60(1): 94-103.
- [6] Wang H, Jia Y W, Shi M G, et al. A mutually beneficial operation framework for virtual power plants and electric vehicle charging stations[J]. IEEE Transactions on Smart Grid, 2023, 14(6): 4634-4648.
- [7] 陈永权,方瑜.多组合虚拟电厂中氢储能低碳经济配置与优化[J].电网与清洁能源,2024,40(3):107-118.
Chen Yongquan, Fang Yu. Low carbon economic configuration and optimization of hydrogen storage in multi-portfolio virtual power plants[J]. Power System and Clean Energy, 2024, 40(3): 107-118.
- [8] 吴亚雄,申展,吴科成.考虑配电系统运营商和多主体博弈的配电网规划方法[J].高压电器,2025,61(12):209-218.
Wu Yaxiong, Shen Zhan, Wu Kecheng. Distribution network planning method considering distribution system operators and multi-agent game[J]. High Voltage Apparatus, 2025, 61(12): 209-218.
- [9] 陈耀威,米阳,马思源,等.绿证-碳交易市场下基于广义纳什博弈的多虚拟电厂点对点交易策略[J].浙江电力,2025,44(12):43-54.
Chen Yaowei, Mi Yang, Ma Siyuan, et al. A peer-to-peer trading strategy for multiple virtual power plants based on generalized Nash game in green certificate-carbon trading markets[J]. Zhejiang Electric Power, 2025, 44(12): 43-54.
- [10] 史林军,燕志伟,李杨,等.基于动态电价机制的配网运营商与用户储能商双层协调多目标优化策略[J].太阳能学报,2024,45(6):75-85.
Shi Linjun, Yan Zhiwei, Li Yang, et al. Double-layer coordination multi-objective optimization strategy for distribution network operators and customer energy storage providers based on dynamic electricity price mechanism[J]. Acta Energetica Sinica, 2024, 45(6): 75-85.
- [11] 檀勤良,曾贾斌,吕函谕,等.考虑源网荷储协同的配网侧分布式光伏市场交易策略优化[J].中国电力,2025,58(10):39-49.
Tan Qinliang, Zeng Jiabin, Lü Hanyu, et al. Optimization of distribution-side distributed photovoltaic market trading strategies considering source-grid-load-storage coordination[J]. Electric Power, 2025, 58(10): 39-49.
- [12] 舒征宇,朱凯翔,王灿,等.考虑碳交易的虚拟电厂日前电力市场竞争策略[J].电力工程技术,2024,43(5):58-68,149.
Shu Zhengyu, Zhu Kaixiang, Wang Can, et al. Virtual power plants participating in day-ahead electricity market bidding strategy considering carbon trading[J]. Electric Power Engineering Technology, 2024, 43(5): 58-68, 149.
- [13] 王贵召,程静,胡利.基于纳什谈判和主从博弈的多园区综合能源系统电-碳共享运行优化策略[J].太阳能学报,2026,47(1):274-287.
Wang Guizhao, Cheng Jing, Hu Li. Optimization strategy of electricity-carbon sharing operation of multi-park integrated energy system based on Nash negotiation and Stackelberg game[J]. Acta Energetica Sinica, 2026, 47(1): 274-287.
- [14] 张儒峰,吴昊泽,吴昊,等.基于能量流-物质流耦合的高耗能工业负荷需求响应主从博弈优化方法[J/OL].中国电机工程学报,2026-01-26. <https://link.cnki.net/urlid/11.2107.TM.20260123.1532.002>.
Zhang Rufeng, Wu Haoze, Wu Hao, et al. Stackelberg game optimization method for demand response of energy-intensive industrial loads based on energy flow and material flow coupling[J/OL]. Proceedings of the CSEE, 2026-01-26. <https://link.cnki.net/urlid/11.2107.TM.20260123.1532.002>.
- [15] 谢敏,卢颖,魏东,等.基于双重交互主从博弈的新能源与用户双边协商交易策略[J].电力系统自动化,2026,50(10):137-151.
Xie Min, Lu Ying, Wei Dong, et al. Bilateral negotiation trading strategy for renewable energy and users based on dual-interactive Stackelberg game[J]. Automation of Electric Power Systems, 2026, 50(10): 137-151.
- [16] 高鑫,魏立保,梁岩.基于主从博弈的配电网-多微网双层优化调度[J].电网与清洁能源,2025,41(4):12-17.
Gao Xin, Wei Libao, Liang Yan. Hierarchical optimization dispatching of distribution network-multi microgrid based on

- master-slave game theory [J]. Power System and Clean Energy, 2025, 41(4): 12-17.
- [17] 徐慧慧, 田云飞, 赵宇洋, 等. 考虑绿证-碳交易的多虚拟电厂混合博弈优化调度[J]. 智慧电力, 2024, 52(3): 1-7, 16.
Xu Huihui, Tian Yunfei, Zhao Yuyang, et al. Optimal scheduling of multiple virtual power plants mixed game considering green certificate and carbon trading[J]. Smart Power, 2024, 52(3): 1-7, 16.
- [18] 栗然, 王炳乾, 彭湘泽, 等. 基于主从博弈的多虚拟电厂动态定价与优化调度[J]. 可再生能源, 2024, 42(7): 986-994.
Li Ran, Wang Bingqian, Peng Xiangze, et al. Dynamic pricing and optimal scheduling of multi-virtual power plants based on master-slave game [J]. Renewable Energy Resources, 2024, 42(7): 986-994.
- [19] 赵琛, 彭思远, 和萍, 等. 电-碳-绿证交易耦合下多虚拟电厂动态定价模型与博弈分析[J]. 电力系统自动化, 2026, 50(1): 188-198.
Zhao Chen, Peng Siyuan, He Ping, et al. Dynamic pricing model and game analysis of multiple virtual power plants under electricity-carbon-green certificate trading coupling [J]. Automation of Electric Power Systems, 2026, 50(1): 188-198.
- [20] 董雷, 涂淑琴, 李烨, 等. 基于元模型优化算法的主从博弈多虚拟电厂动态定价和能量管理[J]. 电网技术, 2020, 44(3): 973-981.
Dong Lei, Tu Shuqin, Li Ye, et al. A Stackelberg game model for dynamic pricing and energy management of multiple virtual power plants using metamodel-based optimization method [J]. Power System Technology, 2020, 44(3): 973-981.
- [21] Wang X J, Zhao H R, Lu H, et al. Decentralized coordinated operation model of VPP and P2H systems based on stochastic-bargaining game considering multiple uncertainties and carbon cost [J]. Applied Energy, 2022, 312: 118750.
- [22] 邱斌. 基于主从博弈的含氢虚拟电厂鲁棒优化调度研究[D]. 南昌: 南昌大学, 2024.
Qiu Bin. Research on robust optimal scheduling of hydrogen-containing virtual power plant based on master-slave game [D]. Nanchang: Nanchang University, 2024.
- [23] 宋嘉启, 杨永标, 徐青山, 等. 多虚拟电厂参与日前电力市场的鲁棒竞标博弈方法[J]. 电力自动化设备, 2023, 43(5): 77-85.
Song Jiaqi, Yang Yongbiao, Xu Qingshan, et al. Robust bidding game approach for multiple virtual power plants participating in day-ahead electricity market [J]. Electric Power Automation Equipment, 2023, 43(5): 77-85.
- [24] 王愿, 李彦斌, 宋明浩, 等. 计及多重不确定性和时间相关性的虚拟电厂参与碳-绿证协同交易优化调度[J]. 电网技术, 2024, 48(12): 4938-4947.
Wang Yuan, Li Yanbin, Song Minghao, et al. Optimal scheduling of virtual power plant participating in carbon-green certificates collaborative trading considering multiple uncertainties and time correlations[J]. Power System Technology, 2024, 48(12): 4938-4947.
- [25] 赵晨阳, 艾芊, 李晓露, 等. 基于分布鲁棒模型的冷热电联供虚拟电厂日前-日内协同优化调度策略[J]. 供用电, 2025, 42(10): 3-15.
Zhao Chenyang, Ai Qian, Li Xiaolu, et al. Day-ahead-intraday cooperative optimal scheduling strategy for cold-heat-electricity cogeneration VPP based on distributed robust model [J]. Distribution & Utilization, 2025, 42(10): 3-15.
- [26] 许桐, 唐彦嫣, 马超, 等. 计及数据驱动与 Wasserstein 度量的虚拟电厂分布鲁棒优化方法研究[J]. 可再生能源, 2025, 43(8): 1120-1129.
Xu Tong, Tang Yanyan, Ma Chao, et al. Distributionally robust optimization for virtual power plant considering data-driven and Wasserstein metric-based method [J]. Renewable Energy Resources, 2025, 43(8): 1120-1129.
- [27] 齐彩娟, 陈宝生, 韦冬妮, 等. 考虑主从博弈定价模式的共享储能分布鲁棒优化配置方法研究[J]. 中国电力, 2024, 57(7): 40-53.
Qi Caijuan, Chen Baosheng, Wei Dongni, et al. Distributionally robust optimal configuration for shared energy storage based on Stackelberg game pricing model [J]. Electric Power, 2024, 57(7): 40-53.
- [28] 汪进锋, 李金鹏, 许银亮, 等. 考虑不确定性和绿证交易的虚拟电厂与配电网分布式优化[J]. 中国电力, 2025, 58(4): 21-30, 192.
Wang Jinfeng, Li Jinpeng, Xu Yinliang, et al. Distributed optimization for VPP and distribution network operation considering uncertainty and green certificate market [J]. Electric Power, 2025, 58(4): 21-30, 192.
- [29] Cheng L F, Wang K, Peng P, et al. Multi-agent Stackelberg game for joint optimization of electricity spot and deep peak regulation markets: strategies and implications for system flexibility [J]. International Journal of Electrical Power & Energy Systems, 2025, 171: 111041.
- [30] Li X Y, Wu N, Lei L. Nash-Stackelberg-Nash three-layer mixed game optimal control strategy for multi-integrated energy systems considering multiple uncertainties [J]. Energy, 2025, 320: 135418.
- [31] 王作玮, 张真源, 杜月芳. 考虑调峰辅助服务的综合能源系统主从博弈优化调度[J]. 电力需求侧管理, 2025, 27(6): 37-44.
Wang Zuowei, Zhang Zhenyuan, Du Yuefang. Master-slave game optimization scheduling of integrated energy system considering peak regulation ancillary service [J]. Power Demand Side Management, 2025, 27(6): 37-44.
- [32] Amasyali K, Olama M M, Chen Y. Genetic algorithm for demand response: a Stackelberg game approach [C]//2020 Spring Simulation Conference (SpringSim). IEEE, 2020: 1-12.
- [33] 蒋东荣, 向洪伟, 王一雯, 等. 基于主从博弈的负荷聚合商奖励价格制定策略及可控负荷调度研究[J]. 重庆理工大学学报(自然科学), 2018, 32(5): 169-176.
Jiang Dongrong, Xiang Hongwei, Wang Yiwen, et al. Load aggregator incentive pricing scheme based Stackelberg game and flexible loads dispatching research [J]. Journal of Chongqing University of Technology (Natural Science), 2018, 32(5): 169-176.
- [34] 祁兵, 曹望璋, 李彬, 等. 计及负载特征及响应特性的多数据中心双层优化模型[J]. 电力系统自动化, 2022, 46(21): 30-41.
Qi Bing, Cao Wangzhang, Li Bin, et al. Bi-level optimization model of multiple data centers considering workload features and response characteristics [J]. Automation of Electric Power Systems, 2022, 46(21): 30-41.
- [35] 李国庆, 王冲, 雷顺波, 等. 考虑碳捕集技术的电力系统双层优化配置[J]. 电力自动化设备, 2023, 43(1): 25-31.
Li Guoqing, Wang Chong, Lei Shunbo, et al. Bi-level optimal

- allocation of power system considering carbon capture technology [J]. Electric Power Automation Equipment, 2023, 43(1): 25-31.
- [36] Li J Y, Yu J, Wang Q N, et al. Differentiable bilevel programming for Stackelberg congestion games [PP/OL]. arXiv (2024-05-14) [2026-03-01]. <https://doi.org/10.48550/arXiv.2209.07618>.
- [37] 王博闻, 张博涵, 鲁宇, 等. 考虑碳交易的多虚拟电厂主从博弈协调策略[J]. 电力需求侧管理, 2025, 27(1): 80-87.
- Wang Bowen, Zhang Bohan, Lu Yu, et al. Multi-virtual power plant master-slave game coordination strategy considering carbon trading [J]. Power Demand Side Management, 2025, 27(1): 80-87.
- [38] 王辉, 金子蓉, 方航, 等. 基于动态定价的虚拟电厂博弈能源管理模型[J]. 南方电网技术, 2023, 17(4): 101-108.
- Wang Hui, Jin Zirong, Fang Hang, et al. Game energy management model of virtual power plant based on dynamic pricing [J]. Southern Power System Technology, 2023, 17(4): 101-108.
- [39] Lin Y M, Liu K, Han D Y, et al. Statistical privacy-preserving online distributed Nash equilibrium tracking in aggregative games [J]. IEEE Transactions on Automatic Control, 2024, 69(1): 323-330.
- [40] Yang K, Yang D, Zhang Z, et al. A Chebyshev's inequality-based distributionally robust chance-constrained model for distribution

network reactive power optimization [J]. Journal of Physics: Conference Series, 2025, 3012(1): 012085.

- [41] 漆磊, 高扬, 艾芊. 基于能量共享的虚拟电厂多产消者混合博弈策略[J]. 电力建设, 2025, 46(1): 1-13.
- Qi Lei, Gao Yang, Ai Qian. Virtual power plant and multi-prosumer hybrid game strategy based on energy sharing [J]. Electric Power Construction, 2025, 46(1): 1-13.

收稿日期: 2026-03-16 修回日期: 2026-04-20



陈渠

作者简介:

陈渠(2001),男,硕士研究生,通信作者,主要研究方向为虚拟电厂优化调度,E-mail:dankerc@126.com;

杨苹(1967),女,博士,教授,博士生导师,主要研究方向为微能源网的优化调控运行技术;

陈年昊(1998),男,博士研究生,主要研究方向为新能源并网控制;

刘根饶(2002),男,硕士研究生,主要研究方向为可再生能源发电与并网控制;

颜璐(2002),女,硕士研究生,主要研究方向为电力市场。

(编辑 景贺峰)

附录 A

A.1 均衡解存在证明

当满足以下条件时,Stackelberg 博弈均衡解存在:

1)DSO 和 VPP 的收益函数为关于其策略集的连续函数;

2)VPP 的收益函数为关于其策略集的拟凸函数。

存在性证明:

对于1)显然成立;

对于2),VPP 的收益函数可以由式(6)确定,其中, C_t^{VPP} 为关于 $P_t^{VPP,b}$ 、 $P_t^{VPP,s}$ 的线性函数; C^{VPP} 为关于 $P_{j,t}^{MT}$ 的凸函数; C^{VPP} 为关于 $P_{j,t}^{ch}$ 、 $P_{j,t}^{dch}$ 的凸函数; C^{VPP} 为关于 $P_{j,t}^{IL}$ 的线性函数; C^{VPP} 为关于 $R_{j,t}^{up}$ 、 $R_{j,t}^{dn}$ 的线性函数。因此,从整体来看,VPP 的收益函数为关于其策略集的拟凸函数。

A.2 均衡解唯一证明

当满足以下条件时,Stackelberg 博弈均衡解唯一:

1)当 DSO 给定策略,VPP 存在唯一最优策略;

2)当 VPP 给定策略,DSO 存在唯一最优策略。

唯一性证明:

对于1),对 VPP 的收益函数关于其策略集求二阶偏导:

$$\frac{\partial^2 C^{VPP}}{(\partial P_t^{VPP,b})^2} = 0 \quad (A1)$$

$$\frac{\partial^2 C^{VPP}}{(\partial P_t^{VPP,s})^2} = 0 \quad (A2)$$

$$\frac{\partial^2 C^{VPP}}{(\partial P_{j,t}^{MT})^2} = 2a_j \quad (A3)$$

$$\frac{\partial^2 C^{VPP}}{(\partial P_{j,t}^{ch})^2} = 2\lambda_j^{BESS} \quad (A4)$$

$$\frac{\partial^2 C^{VPP}}{(\partial P_{j,t}^{dch})^2} = 2\lambda_j^{BESS} \quad (A5)$$

$$\frac{\partial^2 C^{VPP}}{(\partial P_{j,t}^{IL})^2} = 0 \quad (A6)$$

$$\frac{\partial^2 C^{VPP}}{(\partial R_{j,t}^{up})^2} = 0 \quad (A7)$$

$$\frac{\partial^2 C^{VPP}}{(\partial R_{j,t}^{dn})^2} = 0 \quad (A8)$$

由此可知,VPP 的 Hessian 矩阵为半正定矩阵,因此当 DSO 给定策略后,VPP 存在唯一最优策略。


对于2),对 DSO 的收益函数关于其策略集求二阶偏导:

$$\frac{\partial^2 C^{DSO}}{(\partial \lambda_t^{D,b})^2} = 0 \quad (A9)$$


$$\frac{\partial^2 C^{DSO}}{(\partial \lambda_t^{D,s})^2} = 0 \quad (A10)$$

DSO 的收益函数关于其策略集的二阶偏导均为 0,可知其收益函数为多元线性函数,因此,当 VPP 给定策略后,DSO 存在唯一最优策略。


附录 B



(a) VPP1



(b) VPP2



(c) VPP3

图 B1 新能源及负荷预测出力情况

Fig. B1 Forecasted output of renewable energy and load




图 B2 各时段购售价格区间

Fig. B2 Purchase and sale price intervals in each period

附录 C

C.1 参数设置

为验证本文方法在多源不确定性场景下的适用性,本附录在原算例基础上引入光伏出力不确定性。设 VPP2 和 VPP3 的光伏出力均值预测曲线如图 C1 所示,光伏出力标准差上限取风电标准差的 80%。风电与光伏出力相互独立,新能源总出力的均值 $\mu_{j,t}^{\text{RE}} = \mu_{j,t}^{\text{wind}} + \mu_{j,t}^{\text{PV}}$, 新能源出力方差上界 $\bar{\sigma}_{j,t}^{\text{RE}} = \sqrt{(\bar{\sigma}_{j,t}^{\text{wind}})^2 + (\bar{\sigma}_{j,t}^{\text{PV}})^2}$,代入本文所构建的分布鲁棒优化模型即可。




图 C1 VPP2 和 VPP3 的光伏出力预测情况

Fig. C1 Forecasted PV output of VPP2 and VPP3

C.2 结果分析

对多源不确定性模型进行分布鲁棒机会约束建模,并采用本文所提方法进行求解,得到的仿真结果如图 C2 所示。

从图 C2 可以看出,当新能源出力波动上界降低




图 C2 VPP 新能源出力及备用配置情况
Fig. C2 Renewable energy output and reserve allocation of VPP

时,系统正负备用也会随之降低。当新能源计划出力大于出力均值时,即调度计划更激进,那么出现实际风电出力不足情况的概率就会增加,于是从图 C2

中体现出来的结果就是系统正备用大于系统负备用。反之亦然。上述结果同样可以表明本文所提的分布鲁棒优化模型在面对风电不确定性时,可以通过灵活调整备用容量来平衡电力供需,确保系统的可靠性与经济性。

不同风险预算下的 VPP 运行与备用成本见表 C1。从表 C1 的仿真结果可以看出,随着风险预算参数从 0.05 增大至 0.20,各 VPP 的运行成本和备用成本均呈现下降趋势,表明决策者可通过调节风险预算在运行风险与经济性之间进行灵活权衡。并且多源不确定性场景下备用成本略高于单风电场景,这是由于光伏出力的引入增加了总不确定性的方差,系统需要预留更多的备用容量以应对叠加后的出力波动。但两者随风险预算的变化趋势一致,验证了本文所提方法的可扩展性。

表 C1 多源不确定性场景中不同风险预算下的 VPP 运行与备用成本

Table C1 VPP operation and reserve costs under different risk budgets in multi-source uncertainty scenario

风险预算	VPP	运行成本/元	备用成本/元
0.05	1	69 884	13 140
	2	44 595	25 923
	3	17 573	52 796
0.10	1	66 546	9255
	2	36 493	18 337
	3	-1210	37 872
0.15	1	65 851	7640
	2	32 359	14 865
	3	-5427	30 386
0.20	1	64 304	6610
	2	31 504	12 800
	3	-9067	26 183

综上,本附录验证了本文方法对风电-光伏多源不确定性场景的适用性。结果表明,本文所提分布鲁棒优化模型能够根据风光出力的波动特征,灵活调整正负备用容量以平衡电力供需,在保障系统可靠性的同时优化运行经济性。决策者可通过调节风险预算参数在运行风险与运行成本之间进行权衡,验证了该方法具有良好的可扩展性。