

考虑协变量因素的多能微电网 两阶段分布鲁棒优化调度

李鸿¹, 朱继忠^{1*}, 董瀚江²

(1. 华南理工大学电力学院, 广东省广州市 510641;
2. 香港理工大学电机工程学系, 香港特别行政区 九龙城区 999077)

Two-stage Distributionally Robust Optimization Scheduling for Multi-energy Microgrid Considering Covariate Factors

LI Hong¹, ZHU Jizhong^{1*}, DONG Hanjiang²

(1. School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, Guangdong Province, China;
2. Department of Electrical Engineering, Hong Kong Polytechnic University, Kowloon 999077, Hong Kong SAR, China)

ABSTRACT: To effectively deal with the influence of multiple uncertainties such as renewable energy output and load demand on the safe and stable operation of multi-energy microgrid system, this paper proposes a two-stage distributionally robust optimization model for multi-energy microgrid system considering covariate factors. First, based on the distributionally robust optimization method, a two-stage optimal scheduling model of a multi-energy microgrid system including photovoltaic generation units, combined cooling, heat and power units, cold, heat and electric load and thermal energy storage is constructed. Then, considering covariate factors, a Wasserstein ambiguity set based on multivariate decision tree regression is established to describe the internal relationship between the uncertainty of source and load, and between the uncertainty and covariate factors. Next, using linear decision rules and duality theorem, a mixed integer linear programming form of the model is given. Finally, the model is applied to a modified 33-node multi-energy microgrid system for example analysis. The results show that the introduction of covariate factors can effectively improve the economy of the model compared with the classical robust optimization model and the distributionally robust optimization model. In the Monte Carlo out-of-sample test, the proposed two-stage distributionally robust optimization model shows good reliability in the face of uncertainty fluctuations.

KEY WORDS: microgrid; economic dispatch; Wasserstein ambiguity set; distributionally robust optimization; covariate factor

摘要: 为有效应对新能源出力、负荷需求等多种不确定量同时波动对多能微电网系统安全稳定运行带来的影响,提出一种考虑协变量因素的多能微电网两阶段分布鲁棒优化模型。首先,基于分布鲁棒优化方法,初步构建包含光伏发电机组、冷热电联产机组、冷热电负荷和热储能的多能微电网系统两阶段优化调度模型;然后,考虑协变量因素,建立基于多元决策树回归的 Wasserstein 模糊集,刻画源荷双侧不确定量之间、不确定量与协变量因素之间的内在联系;接着,运用线性决策规则及对偶定理,给出模型的混合整数线性规划形式;最后,将模型应用于 33 节点多能微电网系统进行算例分析。结果表明,相比于经典鲁棒优化和分布鲁棒优化模型,引入协变量因素能够有效提高模型的经济性。在蒙特卡洛样本外测试中,所提出的两阶段分布鲁棒优化模型对不确定量波动表现出良好的可靠性。

关键词: 微电网; 经济调度; Wasserstein 模糊集; 分布鲁棒优化; 协变量因素

0 引言

微电网连接中低压配电网络,由分布式发电设备、冷热电联产设备、储能系统及冷、热、电负荷共同组成多能微电网系统。多能微电网系统能够综合利用太阳能、电能、热能等不同能源的互补特性,在提高能源利用效率、系统运行可靠性等方面发挥重要作用^[1-2]。在多能源耦合、多时间尺度运行环境下,多能微电网运行优化调度决策是保障系统安全

基金项目: 国家自然科学基金项目(52177087); 广东省基础与应用基础研究基金(2022B1515250006)。

Project Supported by National Natural Science Foundation of China (52177087); Guangdong Basic and Applied Basic Research Foundation (2022B1515250006).

经济运行及各类能源互补联产、可靠联供的重要前提。

通过冷热电联产(combined cooling, heat and power, CCHP)机组,多能微电网系统能够同时满足系统内的电力负荷和冷、热负荷需求^[3]。然而,多能耦合也给系统的安全稳定运行带来更多挑战,发电侧的可再生能源不确定性和负荷侧的冷、热、电负荷波动性同时存在,严重影响着微电网系统的功率平衡。针对可再生能源出力和负荷需求不确定性的问题,目前较为成熟的处理方法有随机优化(stochastic optimization, SO)^[4]和鲁棒优化(robust optimization, RO)^[5]。文献[6]针对含风光发电的微电网建立多目标随机动态优化模型,实现系统总运行费用和总网损最小的目标。为了使孤岛模式下的微网运行成本最小,文献[7]结合光伏预测模型提出一种两阶段随机优化框架,实现微电网的运行优化调度。文献[8]提出一种期望场景下的两阶段微电网鲁棒优化调度模型,保证在最恶劣场景下的鲁棒解可行。文献[9]采用鲁棒方法处理风电不确定性,提出基于多智能体博弈的电气多能源系统联合规划方法。然而,随机优化需要关于不确定量的概率分布,鲁棒优化对最恶劣场景的刻画较为保守。这两种经典方法通常只考虑单个不确定量,当同时考虑多种不确定量波动的影响时,随机优化会难以刻画其分布,鲁棒优化容易使得决策过于保守。

近年来,分布鲁棒优化(distributionally robust optimization, DRO)作为一种兼顾随机优化和鲁棒优化优势的方法,在电力系统中得到广泛的应用^[10-12]。根据模糊集建立方法的不同,分布鲁棒优化可分为基于矩(moment-based)类型^[13]和基于距离度量(metric-based)类型^[14]。基于矩的DRO主要考虑均值和方差信息,对样本数据的利用不充分,保守度较高;基于距离度量的DRO主要通过各种距离函数刻画不确定量经验分布和实际分布的距离,适用范围广但求解复杂性较高。随着电力系统中量测设备的完善和计算机算力的提高,基于距离度量的数据驱动型DRO引起学者的广泛关注。文献[15]基于Wasserstein距离构建考虑光伏出力不确定性的模糊集,提出电热综合能源调度模型;文献[16]针对风电预测误差波动提出可控负荷下的CCHP微电网两阶段分布式鲁棒优化模型;文献[17]构建基于风电出力概率分布模糊集的港口多能微网日前-日内两阶段分布鲁棒优化调度模型,并在海上风电

实测数据仿真中验证模型效果。

此外,可再生能源预测出力、负荷预测值等微电网系统运行参数受到气象条件^[18]、人为活动^[19]和政策规划等因素影响而呈现出周期性、时延性及外部因素相关性^[20]。文献[18]指出负荷预测受季节、温度、负荷自身变化规律影响,光伏出力预测受日照强度直接影响;文献[19]通过Copula函数的相关性测度方法定量计算外界天气、人为活动与目标负荷的相关程度。当前优化调度研究通常忽略这些协变量因素的影响,假设模型参数预测值能够间接反映这些协变量因素的影响并确保调度决策方案的可行性^[21]。然而,这种假设强依赖于预测结果的准确性,实际情况难以满足。气象条件、人为活动等协变量信息可用于提高各不确定量的预测精度,在进行优化调度时,同样可以利用历史协变量信息和历史不确定量信息的关系,深度挖掘其内在相关性,从而得到更为合理的优化调度结果。

因此,有必要对考虑协变量因素的多种不确定量同时作用下多能微电网优化运行问题进行研究。针对该问题,本文围绕考虑光伏出力、电负荷波动性的多能微电网运行优化问题进行以下工作:首先,提出多能微电网两阶段分布鲁棒优化调度模型,建立考虑协变量因素的改进Wasserstein模糊集以描述光伏出力、电负荷的预测误差波动;其次,采用多元决策树回归方法捕捉历史样本数据中协变量因素和不确定量、不确定量间的内在联系,获取模糊集参数;最后,基于线性决策规则和强对偶理论将所提模型等价转换为混合整数线性规划问题,并在改进的33节点多能微网系统中进行算例仿真,验证模型的可行性及有效性。

1 多能微电网分布鲁棒优化调度模型

1.1 目标函数

基于文献[22],本文建立了考虑协变量因素的多能微电网两阶段分布鲁棒优化调度模型。通过考虑协变量因素的Wasserstein模糊集 \mathcal{F} 刻画光伏出力、电负荷预测误差的分布情况,以日前预调度成本 $C(\mathbf{x})$ 和日内期望调度成本 $\mathbb{E}[Q(\mathbf{x}, \mathbf{v})]$ 总和最小为目标,获得兼具经济性和鲁棒性的日前最优调度决策 \mathbf{x} :

$$\min_{\mathbf{x}} \{C(\mathbf{x}) + \sup_{\mathbb{P} \in \mathcal{F}} \mathbb{E}_{\mathbb{P}} \{[Q(\mathbf{x}, \mathbf{v})]\}\} \quad (1)$$

式中: \mathbf{x} 为日前阶段决策变量; $C(\mathbf{x})$ 为日前阶段预调度成本函数; \mathbf{v} 为不确定量预测误差; $\sup(\cdot)$ 为

上确界函数; $\mathbb{P} \in \mathcal{F}$ 表示不确定量预测误差在模糊集 \mathcal{F} 上的最恶劣分布; $Q(\mathbf{x}, \mathbf{v})$ 为在日前调度决策 \mathbf{x} 和日内预测误差 \mathbf{v} 确定情况下的总成本函数。

1) 日前预调度成本。

该模型为并网情况下的多能微电网, 电能侧的备用柴油发电机组(backup diesel generator, BDG) 作为备用辅助, 需在日前阶段确定启停计划; 热能侧采用热储能系统(thermal energy storage system, TESS), 由于热能传输时间较长, 同样需要在日前确定其调度计划, 故日前预调度成本包括启停成本 C_S 和热储能成本 C_H 。

$$C(\mathbf{x}) = \min_{t \in T} (C_S + C_E) \quad (2)$$

$$C_S = \sum_{j \in J} C_j^{\text{BDG}} |B_{j,t}^{\text{BDG}} - B_{j,t-1}^{\text{BDG}}| \quad (3)$$

$$C_H = \sum_{k \in K} C_k^{\text{TESS}} (q_{k,t}^{\text{TSC}} \tau + q_{k,t}^{\text{TSD}} \tau) \quad (4)$$

式中: T 为时段总数; J 为 BDG 机组数量; K 为 CCHP 机组数量; C_j^{BDG} 为第 j 台 BDG 机组的开机/停机费用; $B_{j,t}^{\text{BDG}}$ 为 BDG 机组的启停机状态变量; C_k^{TESS} 为第 k 台储热装置的储热费用; $q_{k,t}^{\text{TSC}}$ 、 $q_{k,t}^{\text{TSD}}$ 为第 k 台储热装置 t 时段的储热、放热功率; τ 为各时段间隔, 设为 1h。

2) 日内再调度成本。

日内阶段通过可控机组再调度、并网购售电等手段应对源、荷功率预测误差产生的扰动。再调度成本包括煤耗成本 C_F 、运维成本 C_{OM} 、购售电成本 C_{EX} 。

$$Q(\mathbf{x}, \mathbf{v}) = \min_{t \in T} (C_F + C_{\text{OM}} + C_{\text{EX}}) \quad (5)$$

$$C_F = C^{\text{gas}} v_t^{\text{gas}} + \sum_{j \in J} C^{\text{fuel}} P_{j,t}^{\text{BDG}} \tau \quad (6)$$

$$C_{\text{OM}} = \sum_{j \in J} O_M^{\text{BDG}} P_{j,t}^{\text{BDG}} + \sum_{k \in K} O_M^{\text{CCHP}} P_{k,t}^{\text{CCHP}} + \sum_{l \in L} O_M^{\text{PV}} P_{l,t}^{\text{PV}} \quad (7)$$

$$C_{\text{EX}} = C_t^{\text{buy}} P_t^{\text{buy}} \tau - C_t^{\text{sell}} P_t^{\text{sell}} \tau \quad (8)$$

式中: C^{gas} 、 C^{fuel} 分别为 CCHP 机组和 BDG 机组的燃煤成本系数; v_t^{gas} 为第 t 时段的 CCHP 机组煤耗量; $P_{j,t}^{\text{BDG}}$ 为第 j 台 BDG 机组 t 时段的有功出力; L 为光伏发电机组(photovoltaic, PV)数量; O_M^{BDG} 、 O_M^{CCHP} 、 O_M^{PV} 分别代表不同机组的运维成本系数; $P_{k,t}^{\text{CCHP}}$ 为第 k 台 CCHP 机组 t 时段的有功出力; $P_{l,t}^{\text{PV}}$ 为第 l 台 PV 发电机组 t 时段的有功出力; C_t^{buy} 、 C_t^{sell}

分别为第 t 时段的购、售电价; P_t^{buy} 、 P_t^{sell} 分别为第 t 时段的购、售电功率。

1.2 约束条件

在数学模型上不对日前和日内调度约束作物理意义上的区分, 均需满足系统电热功率平衡约束、电网安全约束及各设备的运行约束。相较于传统微电网优化调度, 该文模型考虑了微型配电网潮流的情况, 系统功率平衡约束由潮流约束替代。

1) 电能约束。

电网潮流约束。对于考虑节点潮流的多能微电网系统, 本文采用径向潮流约束^[23]进行建模。

$$P_{i+1,t}^{\text{bus}} = P_{i,t}^{\text{bus}} + P_{i,t}^{\text{vir}} + P_{i,t}^{\text{EL}} \quad (9)$$

$$Q_{i+1,t}^{\text{bus}} = Q_{i,t}^{\text{bus}} + Q_{i,t}^{\text{vir}} + Q_{i,t}^{\text{EL}} \quad (10)$$

$$V_{i+1,t}^{\text{bus}} = V_{i,t}^{\text{bus}} - \frac{r_i P_{i,t}^{\text{bus}} + x_i Q_{i,t}^{\text{bus}}}{V_{\text{base}}} \quad (11)$$

$$P_{i,t}^{\text{vir}} = \lambda_i^{\text{BDG}} P_{j,t}^{\text{BDG}} + \lambda_i^{\text{CCHP}} P_{k,t}^{\text{CCHP}} + \lambda_i^{\text{PV}} P_{l,t}^{\text{PV}} \quad (12)$$

$$Q_{i,t}^{\text{vir}} = \lambda_i^{\text{BDG}} Q_{j,t}^{\text{BDG}} + \lambda_i^{\text{PV}} Q_{l,t}^{\text{PV}} \quad (13)$$

式中: i 为节点数; $P_{i,t}^{\text{bus}}$ 、 $Q_{i,t}^{\text{bus}}$ 为节点 i 在第 t 时段的有功、无功功率; $P_{i,t}^{\text{EL}}$ 、 $Q_{i,t}^{\text{EL}}$ 为节点 i 在第时段的有功、无功负荷; 为统一形式, 引入虚拟变量 $P_{i,t}^{\text{vir}}$ 、 $Q_{i,t}^{\text{vir}}$ 表示节点 i 第 t 时段所有机组的有功、无功出力, 其中, $P_{i,t}^{\text{vir}}$ 由节点 i 上的所有 BDG、CCHP 和 PV 机组有功出力组成, $Q_{i,t}^{\text{vir}}$ 由节点 i 上的所有 BDG 和 PV 机组无功出力组成; λ_i^{BDG} 、 λ_i^{CCHP} 、 λ_i^{PV} 为 0/1 变量, 表示节点 i 上是否存在 BDG、CCHP 或 PV 机组; $V_{i,t}^{\text{bus}}$ 为节点 i 在第 t 时段的电压值; r_i 、 x_i 为电阻、电抗参数; V_{base} 为基准电压值。

电网安全约束:

$$(P_{i,t}^{\text{bus}})^2 + (Q_{i,t}^{\text{bus}})^2 \leq (S_i^{\text{bus}})^2 \quad (14)$$

$$1 - \Delta V_{\text{max}} \leq V_{i,t}^{\text{bus}} \leq 1 + \Delta V_{\text{max}} \quad (15)$$

式中: S_i^{bus} 为支路传输容量上限; ΔV_{max} 为节点电压偏移上限, 取值 0.05。

各机组电功率约束:

$$P_{j,t}^{\text{BDG}} \geq B_{j,t}^{\text{BDG}} P_j^{\text{BDG},\text{min}} \quad (16)$$

$$(P_{j,t}^{\text{BDG}})^2 + (Q_{j,t}^{\text{BDG}})^2 \leq B_{j,t}^{\text{BDG}} (S_j^{\text{BDG}})^2 \quad (17)$$

$$P_k^{\text{CCHP},\text{min}} \leq P_{k,t}^{\text{CCHP}} \leq P_k^{\text{CCHP},\text{max}} \quad (18)$$

$$(P_{l,t}^{\text{PV}})^2 + (Q_{l,t}^{\text{PV}})^2 \leq (S_l^{\text{PV}})^2 \quad (19)$$

式中: $P_j^{\text{BDG},\text{min}}$ 为第 j 台 BDG 机组的出力下限, S_j^{BDG} 为第 j 台 BDG 机组的装机容量; $P_k^{\text{CCHP},\text{max}}$ 、

$P_k^{\text{CCHP},\min}$ 为第 k 台 CCHP 机组的出力上、下限； S_i^{PV} 为光伏机组容量，通过光伏机组上的逆变器实现对无功出力的控制^[23]。

各机组爬坡约束：

$$\left| P_{j,t}^{\text{BDG}} - P_{j,t-1}^{\text{BDG}} \right| \leq R_j^{\text{BDG}} P_{j,t}^{\text{BDG},\max} \quad (20)$$

$$\left| P_{k,t}^{\text{CCHP}} - P_{k,t-1}^{\text{CCHP}} \right| \leq R_k^{\text{CCHP}} P_{k,t}^{\text{CCHP},\max} \quad (21)$$

式中： R_j^{BDG} 为第 j 台 BDG 机组的爬坡、滑坡限制系数； R_k^{CCHP} 为第 k 台 CCHP 机组的爬坡、滑坡限制系数。

并网节点购售电约束如下：

$$P_{i,t}^{\text{bus}} = P_i^{\text{buy}} - P_i^{\text{sell}} \quad (22)$$

$$P_i^{\text{buy}} \geq 0, P_i^{\text{sell}} \geq 0 \quad (23)$$

式中： P_i^{buy} 、 P_i^{sell} 分别为第 t 时段微电网与主网的购电、售电功率。

2) 热能约束。

热功率平衡约束。该模型中热负荷、CCHP 机组热回收(heat recovery, HR)装置、储热装置、辅助锅炉(auxiliary boiler, AB)均位于对应的 k 个节点，热功率实现就地平衡，不考虑热功率潮流情况。

$$q_{k,t}^{\text{HR}} + q_{k,t}^{\text{AB}} + q_{k,t}^{\text{TSD}} = q_{k,t}^{\text{TSC}} + q_{k,t}^{\text{AC}} + q_{k,t}^{\text{HC}} \quad (24)$$

式中： $q_{k,t}^{\text{HR}}$ 为第 k 台 HR 装置在 t 时段的产热功率； $q_{k,t}^{\text{AB}}$ 为第 k 台辅助锅炉在 t 时段的产热功率； $q_{k,t}^{\text{TSC}}$ 、 $q_{k,t}^{\text{TSD}}$ 为第 k 个储热装置在 t 时段的储热、放热功率； $q_{k,t}^{\text{AC}}$ 、 $q_{k,t}^{\text{HC}}$ 为冷、热负荷功率。

各设备热功率约束：

$$0 \leq q_{k,t}^{\text{HR}} \leq q_{k,t}^{\text{HR},\max} \quad (25)$$

$$0 \leq q_{k,t}^{\text{AB}} \leq q_{k,t}^{\text{AB},\max} \quad (26)$$

式中： $q_{k,t}^{\text{HR},\max}$ 为第 k 台 HR 装置热功率的上限； $q_{k,t}^{\text{AB},\max}$ 为第 k 台辅助锅炉热功率的上限。

储热装置约束：

$$H_{k,t}^{\text{C}} + H_{k,t}^{\text{D}} \leq 1 \quad (27)$$

$$0 \leq q_{k,t}^{\text{TSC/D}} \leq H_{k,t}^{\text{C/D}} q_{k,t}^{\text{TSC/D},\max} \quad (28)$$

$$q_{k,t}^{\text{TS}} = \eta^{\text{TS}} q_{k,t-1}^{\text{TS}} + \eta^{\text{TSC}} q_{k,t}^{\text{TSC}} + \eta^{\text{TSD}} q_{k,t}^{\text{TSD}} \quad (29)$$

$$q_k^{\text{TS},\min} \leq q_{k,t}^{\text{TS}} \leq q_k^{\text{TS},\max} \quad (30)$$

$$q_{k,0}^{\text{TS}} = q_{k,T}^{\text{TS}} \quad (31)$$

式中： $H_{k,t}^{\text{C}}$ 、 $H_{k,t}^{\text{D}}$ 分别为第 k 台储热装置在 t 时段的储热、放热状态，储热装置不能同时进行储放热；

$q_{k,t}^{\text{TSC}}$ 、 $q_{k,t}^{\text{TSD}}$ 、 $q_{k,t}^{\text{TS}}$ 分别为储热装置在 t 时段的储热功率、放热功率和储热量； η^{TS} 、 η^{TSC} 、 η^{TSD} 分别为散热、储热和放热系数，热能在储热装置中仍会有自然散热损耗； $q_k^{\text{TS},\max}$ 、 $q_k^{\text{TS},\min}$ 分别为第 k 个储热装置的容量上下限。

3) 耦合约束。

电热耦合约束。模型中的热电联产机组和热回收装置具有强耦合关系，产热量与发电量成正相关关系，通过煤耗量联结。

$$P_{k,t}^{\text{CCHP}} \tau = \eta^{\text{PGU}} F^{\text{PGU}} \quad (32)$$

$$q_{k,t}^{\text{HR}} = \eta^{\text{HR}} (F^{\text{PGU}} - P_{k,t}^{\text{CCHP}} \tau) \quad (33)$$

式中： η^{PGU} 为 CCHP 机组发电煤耗折算系数； F^{PGU} 为 CCHP 机组煤耗量； η^{HR} 为热传输折算系数。

辅助锅炉约束：

$$q_{k,t}^{\text{AB}} = \eta^{\text{AB}} F^{\text{AB}} \quad (34)$$

式中 η^{AB} 为辅助锅炉发热煤耗折算系数。

煤耗量约束：

$$\sum_{k=1}^K (F_{k,t}^{\text{PGU}} + F_{k,t}^{\text{AB}}) = \rho v_t^{\text{gas}} \quad (35)$$

式中： ρ 为煤耗量折算系数； v_t^{gas} 为第 t 时段所有冷热电联产机组和辅助锅炉总的燃料消耗量。

4) 不确定量约束。

该多能微电网两阶段分布鲁棒调度模型考虑源荷双侧的不确定变量波动，即光伏出力、电负荷预测误差。

$$P_{i,t}^{\text{PV}} = \bar{P}_{i,t}^{\text{PV}} + v_{i,t}^{\text{PV}} \quad (36)$$

$$P_{i,t}^{\text{EL}} = \bar{P}_{i,t}^{\text{EL}} + v_{i,t}^{\text{EL}} \quad (37)$$

式中： $\bar{P}_{i,t}^{\text{PV}}$ 、 $\bar{P}_{i,t}^{\text{EL}}$ 分别为光伏出力、电负荷的预测值； $v_{i,t}^{\text{PV}}$ 、 $v_{i,t}^{\text{EL}}$ 为各个不确定量的波动值。

2 考虑协变量因素的模糊集构建

2.1 Wasserstein 模糊集概述

基于 Wasserstein 距离的模糊集使用欧氏范数描述不确定变量经验分布 \mathbb{P} 和真实分布 P_0 之间的距离。赋予历史样本数据各自的概率质量，两个分布的 Wasserstein 距离可以视作将概率质量从 \mathbb{P} 移动到 P_0 的最小运输成本^[24]。利用 Wasserstein 距离，模糊集在以历史数据样本均匀分布为中心的概率分布空间中构造一个尽可能包含真实分布的球，并根据这个 Wasserstein 球内的最坏情况分布寻求表现最佳的决策。经典 Wasserstein 模糊集 \mathcal{F} 可定义为

$$\mathcal{F} = \left\{ \mathbb{P} \in \mathcal{P}_0(\mathbb{R}^{T+1} \times [N]) \left| \begin{array}{l} (\tilde{\mathbf{v}}, \tilde{\mathbf{u}}) \in \mathbb{P} \\ \mathbb{E}_{\mathbb{P}}[\tilde{\mathbf{u}}] \leq \varepsilon \\ \mathbb{P}[(\mathbf{v}, \mathbf{u}) \in V_j | \tilde{j} = j] = 1 \\ \mathbb{P}[\tilde{j} = j] = 1/N \end{array} \right. \right\} \quad (38)$$

式中： \mathbf{u} 为辅助变量； j 为样本变量； \mathcal{P}_0 为真实分布的集合； N 为历史样本数据数； ε 为 Wasserstein 球半径； V_j 为样本 j 的支撑集。

$$V_j = \{(\mathbf{v}, \mathbf{u}) : \|\mathbf{v} - \hat{\mathbf{v}}_j\|_1 \leq u, \underline{\mathbf{v}} \leq \mathbf{v} \leq \bar{\mathbf{v}}\} \quad (39)$$

式中： $\|\mathbf{v} - \hat{\mathbf{v}}_j\|_1$ 为预测误差 \mathbf{v} 与历史样本数据 $\hat{\mathbf{v}}_j$ 的 1-范数； $\bar{\mathbf{v}}$ 、 $\underline{\mathbf{v}}$ 分别为预测误差的上界和下界。支撑集的作用是通过如 1-范数等距离函数，捕捉真实分布 \mathcal{P}_0 与经验分布 \mathbb{P} 的距离，并限制不确定量的波动范围。基于 1-范数距离易于线性化的优点，本文采用 1-范数距离度量经验分布和真实分布的偏差。

2.2 考虑协变量因素的模糊集

在现有研究中，通常仅将光伏出力或负荷预测误差 \mathbf{v} 纳入模糊集中。然而，上述建模方法忽略了不同不确定量预测误差之间的潜在关联性以及不确定量预测误差受协变量因素影响的内在依赖性，调度结果难以保证可靠性。为此，本文提出一种考虑协变量因素的改进 Wasserstein 模糊集，通过引入协变量信息串联各个不确定变量之间的关系。

$$\bar{\mathcal{F}} = \left\{ \mathbb{P} \in \mathcal{P}_0(\mathbb{R}^{T+1} \times [N]) \left| \begin{array}{l} (\tilde{\mathbf{v}}, \tilde{\mathbf{w}}, \tilde{\mathbf{u}}) \in \mathbb{P} \\ \mathbb{E}_{\mathbb{P}}[\tilde{\mathbf{u}}_s | \tilde{\mathbf{w}} \in \Omega_s] \leq \varepsilon_s \\ \mathbb{P}[(\mathbf{v}, \mathbf{u}) \in V_{j_s} | \tilde{\mathbf{w}} \in \Omega_s] = 1 \\ \mathbb{P}[\tilde{\mathbf{w}} \in \Omega_s] = p_s \end{array} \right. \right\} \quad (40)$$

$$V_{j_s} = \{(\mathbf{v}, \mathbf{u}) : \|\mathbf{v} - \hat{\mathbf{v}}_{j_s}\|_1 \leq u_s, \underline{\mathbf{v}} \leq \mathbf{v} \leq \bar{\mathbf{v}}\} \quad (41)$$

式中： $\tilde{\mathbf{w}}$ 为引入的协变量； s 为场景变量； Ω_s 为协变量的场景集合； p_s 为场景概率； $\hat{\mathbf{v}}_{j_s}$ 、 u_s 为场景 s 下的历史样本数据和 Wasserstein 半径辅助变量。模糊集 $\bar{\mathcal{F}}$ 的第 1 行约束各个场景下的辅助变量期望值上界；第 2 行表示在支撑集 V_{j_s} 下，不确定量的最大、最小值可位于每一个场景中；第 3 行约束了每个场景的概率。值得注意的是，当场景数 $s=1$ 时，模糊集 $\bar{\mathcal{F}}$ 可等效为式(38)中经典 Wasserstein 模糊集 \mathcal{F} 的形式，即此时协变量不提供额外的信息。

以天气为例，假设一维协变量 $\tilde{\mathbf{w}} = 0, 1, 2$ 分别代表晴天、阴天和雨天 3 种气象类型，各天气对应概率分布为 p_i ；在协变量约束下，存在 $\mathbb{P}(\tilde{\mathbf{v}} = v_i | \tilde{\mathbf{w}} = i) = 1$ ， $i = 0, 1, 2$ 分别代表不同天气下的光伏出力， $\varepsilon = \varepsilon_0, \varepsilon_1, \varepsilon_2$ 分别代表不同 Wasserstein 半径，

此时的模糊集可表示为

$$\bar{\mathcal{F}} = \left\{ \mathbb{P} \in \mathcal{P}_0(\mathbb{R}^{T+1}) \left| \begin{array}{l} (\tilde{\mathbf{v}}, \tilde{\mathbf{w}}, \tilde{\mathbf{u}}) \in \mathbb{P} \\ \mathbb{E}_{\mathbb{P}}[\tilde{\mathbf{u}}_i | \tilde{\mathbf{w}} = i] \leq \varepsilon_i, i = 0, 1, 2 \\ \mathbb{P}[\|\tilde{\mathbf{v}} - v_i\|_1 \leq u_i | \tilde{\mathbf{w}} = i] = 1, i = 0, 1, 2 \\ \mathbb{P}[\tilde{\mathbf{w}} = i] = p_i \end{array} \right. \right\} \quad (42)$$

在协变量的作用下，光伏出力 $\tilde{\mathbf{v}}$ 根据气象类型分类为 3 个场景，依据各场景 Wasserstein 半径和分布概率进行不确定量刻画。此时，考虑协变量因素模糊集所构成的 Wasserstein 球如图 1 所示。




图 1 考虑协变量因素的 Wasserstein 球

Fig. 1 Wasserstein sphere considering the covariate factors

图 1 中，球心为基于历史样本数据得到的经验分布 \mathbb{P} ，蓝色圆球由历史样本数据构成，协变量信息的引入将历史样本数据分为 3 个场景，不同场景有不同的 Wasserstein 半径。若场景数为 1，即不考虑协变量的影响时，3 个场景的中心为圆心，半径为单一 Wasserstein 半径，则为经典模糊集下的 Wasserstein 球。相较于经典模糊集 \mathcal{F} ，考虑协变量的模糊集 $\bar{\mathcal{F}}$ 有着更小的 Wasserstein 半径，并且涵盖了预测误差与协变量间的潜在关联性，提高模型的可靠性。

此外，不确定量 $\tilde{\mathbf{v}}$ 可同时考虑多种类型，如光伏出力与热负荷需求，两者的内在关联性可通过协变量信息体现(如晴天时有着更高的光伏出力和更低的热负荷需求)。协变量 $\tilde{\mathbf{w}}$ 也可同时涉及不同变量，包括常见的温度、湿度、风速、日照强度等外部因素，在多种协变量的共同作用下对不确定量进行场景分类。文献[25]给出协变量信息对模糊集影响的数学推导，协变量信息的引入能够增益模型对历史样本数据的有效利用，降低模型的保守度。

2.3 模糊集场景参数

对于考虑协变量的 Wasserstein 模糊集构建，关键在于获取合理的场景集合 Ω_s ，使得在不同场景下

经验分布 \mathbb{P} 与真实分布 P_0 最为接近。决策树作为一种直观且通用的非参数估计方法，由于其易理解、易构建、速度快等特点，被广泛应用在数据挖掘、机器学习等领域。

考虑到模型中的不确定量有多个维度，且因变量为光伏、电负荷预测误差数值，本文采用多元回归树(multivariate regression tree, MRT)方法进行场景分类。MRT 的划分标准是以平方误差，即回归树对于训练数据的预测误差最小来进行划分。对于考虑协变量的 Wasserstein 模糊集，其目标为

$$\min \sum_{s \in [\mathcal{S}]} \sum_{w \in \Omega_s} (\|\hat{\mathbf{v}}_{js} - \mathbf{v}_s\| - \varepsilon_s)^2 \quad (43)$$

相应地，场景概率 p_s 可由各叶节点的规模求得

$$p_s = |\Omega_s| / N, \quad \forall s \in [\mathcal{S}] \quad (44)$$

各场景下 Wasserstein 半径为

$$\hat{\varepsilon}_s = \frac{1}{|\Omega_s|} \sum_{w \in \Omega_s} \|\hat{\mathbf{v}}_{js} - \mathbf{v}_s\| \quad (45)$$

3 模型求解

3.1 模型线性化

第2节所提模型中，式(3)、(14)和(17)为非线性形式，在求解问题前需先进行线性转化。对式(3)，引入二元变量 $\beta_{j,t}^{\text{BDG}}$ 取代绝对值符号，可将式(3)转化为

$$\begin{cases} C_s = \sum_{j \in J} C_j^{\text{BDG}} \beta_{j,t}^{\text{BDG}} \\ \beta_{j,t}^{\text{BDG}} \geq B_{j,t}^{\text{BDG}} - B_{j,t-1}^{\text{BDG}} \\ \beta_{j,t}^{\text{BDG}} \geq B_{j,t}^{\text{BDG}} - B_{j,t-1}^{\text{BDG}} \end{cases} \quad (46)$$

对式(14)和(17)，采用多边形内近似法(polygonal inner approximation, PIA)进行线性化^[22]，如图2所示。




图2 多边形内近似法示意图

Fig. 2 Schematic diagram of Polygonal inner approximation method

式(14)和(17)可分别转化为

$$(y_i^b - y_i^a) P_{i,t}^{\text{bus}} - (x_i^b - x_i^a) Q_{i,t}^{\text{bus}} \geq x_i^a y_i^b - x_i^b y_i^a, \quad a=1,2,\dots,12; b=2,\dots,12,1 \quad (47)$$

$$(y_j^b - y_j^a) P_{j,t}^{\text{BDG}} - (x_j^b - x_j^a) Q_{j,t}^{\text{BDG}} \geq B_j^{\text{BDG}} (x_j^a y_j^b - x_j^b y_j^a), \quad a=1,2,\dots,12; b=2,\dots,12,1 \quad (48)$$

式中： (x_i^a, y_i^a) 和 (x_i^b, y_i^b) 为以 S_i^{bus} 为半径的圆经正12边形内切割后得到的坐标，非线性约束式(14)可近似转化为12条线性约束(47)；式(17)的线性化方法同理。线性化后的可行域内切于原可行域，满足可行性要求，且文献[22]已验证其计算精度。

3.2 线性决策规则

本文所提考虑协变量因素的分布鲁棒优化调度模型可转化为以下的紧缩形式：

$$\begin{cases} \min_x [c^T x + \sup_{\mathbb{P} \in \mathcal{F}} \mathbb{E}_{\mathbb{P}} (\min d^T y)] \\ \text{s.t. } Ax \leq b \\ Cx + Dy \leq g(v) \end{cases} \quad (49)$$

式中： $x=[B^{\text{BDG}}, H^C, H^D, q^{\text{TS}}, q^C, q^D]^T$ 为日前阶段的决策变量； $y=[P^{\text{BDG}}, P^{\text{CCHP}}, P^{\text{buy}}, P^{\text{sell}}, Q^{\text{BDG}}, Q^{\text{PV}}, q^{\text{AB}}]^T$ 为日内阶段的决策变量； A 、 b 为与日前调度相关的约束的系数矩阵和常数向量，对应式(46)、(27)–(31)； C 、 D 为与日内调度相关的约束的系数矩阵，对应式(9)–(13)、(47)、(15)–(16)、(48)、(18)–(26)、(32)–(37)； g 与不确定量 v 的关系可表示为如下线性形式：

$$g(v) = g^0 + \sum_{s \in [\mathcal{S}]} g_s^v v_s \quad (50)$$

式中： g^0 为常数列向量； g_s^v 为与不确定量 v_s 相关的列向量。

式(49)的优化问题中，由于包含预测误差 v 的部分约束为无限约束，使得求解决策变量 y 是 NP 难(NP-hard)问题。线性决策规则是处理该问题的一种有效方法，其通过建立决策变量与不确定量的线性仿射依赖关系来逼近决策变量：

$$\hat{y}_t(v) = y_t^0 + \sum_{s \in [\mathcal{S}]} y_{ts}^v v_{ts} \quad (51)$$

式中： y_t^0 、 y_{ts}^v 为决定 y 与 v 仿射关系的系数变量，是 y 等维度的列向量。为减少计算复杂度，假设第 t 时段的决策变量 \hat{y}_t 仅与第 t 时段的不确定量 v_t 相关，而不遍历整个日内24h的可能性。基于线性决策规则的仿射关系并不会破坏目标函数的最优性，文献[26]证明即便 $y(v)$ 与仿射关系 $\hat{y}(v)$ 没有严格等价，其最优解仍是相同的。故此，式(49)可进一

步等价如下形式:

$$\begin{cases} \min_x \{c^T x + \sup_{\mathbb{P} \in \mathcal{F}} \mathbb{E}_{\mathbb{P}}[d^T \hat{y}(v)]\} \\ \text{s.t. } Ax \leq b \\ Cx + D\hat{y}(v) \leq g(v) \end{cases} \quad (52)$$

式中 c 、 d 为目标函数关于决策变量 x 和 y 的系数列向量。

3.3 分布鲁棒优化模型的可解形式

上述经过线性决策规则转换的模型, 其内层目标函数可根据强对偶理论^[27]转换为

$$\begin{aligned} \sup_{\mathbb{P} \in \mathcal{F}} \mathbb{E}_{\mathbb{P}}[d^T \hat{y}(v)] = \\ \inf_{\sigma \geq 0} \{ \sum_{s \in [S]} p_s \sup_{v \in V_{js}} (d^T \hat{y}(v) - \sigma \|v - \hat{v}_s\|_1) + \sigma \varepsilon_s \} \end{aligned} \quad (53)$$

式中: σ 为对偶因子; ε_s 为 Wasserstein 球半径。引入辅助变量 β_s , 在支撑集 V_{js} 下的分布鲁棒模型等价于以下形式:

$$\begin{cases} \min_{x, y, \beta_s, \sigma \geq 0} c^T x + \sum_{s \in [S]} p_s (\beta_s + \sigma \varepsilon_s) \\ \text{s.t. } \sup_{v \in V_{js}} (d^T \hat{y}(v) - \sigma \|v - \hat{v}_s\|_1) \leq \beta_s \\ Ax < b \\ Cx + D\hat{y}(v) < g(v) \end{cases} \quad (54)$$

1-范数距离 $\|v - \hat{v}_s\|_1$ 是关于 v 的线性函数, $\hat{y}(v)$ 和 $g(v)$ 也分别与 v 具有线性关系, 根据文献^[27], $\sup_{v \in V_{js}} [d^T \hat{y}(v) - \sigma \|v - \hat{v}_s\|_1]$ 的最优解必定在 v 的上、下界或是 \hat{v}_s 上获得。因此, 式(54)可表示为如下易于求解的混合整数线性规划形式。

$$\begin{cases} \min_{x, y, \beta_s, \sigma \geq 0} c^T x + \sum_{s \in [S]} p_s (\beta_s + \sigma \varepsilon_s) \\ \text{s.t. } d^T y(\hat{v}_s) \leq \beta_s \\ d^T y(\bar{v}) - \sigma 1^T (\bar{v} - \hat{v}_s) \leq \beta_s \\ d^T y(v) - \sigma 1^T (\hat{v}_s - v) \leq \beta_s \\ Ax < b \\ Cx + D\hat{y}(\bar{v}) \leq g(\bar{v}) \\ Cx + D\hat{y}(v) \leq g(v) \end{cases} \quad (55)$$

4 结果与分析

本文采用文献^[22]中的改进 33 节点多能微电网系统进行分布鲁棒优化调度模型的验证, 日前阶段与主网结算的购售电价格及各设备参数如附录 A 所示。光伏出力、电力负荷、环境因素的历史数据样本集来自澳大利亚太阳能中心^[28]和能源市场运营商^[29]。采用 2022 年冬季数据, 不考虑模型中冷负荷的影响。为与微电网参数匹配, 将历史数据的百分比功率特性曲线与微电网各设备额定功率相乘, 进行合理放缩。

4.1 多元决策树回归分析

对澳大利亚 Yulara 太阳能电站 2022 年冬季的光伏数据、电负荷需求和对应的当日平均气温、日照强度进行多元决策树回归。以历史日平均气温、日照强度为输入训练集, 历史 24h 光伏出力、负荷需求为输出训练集, 式(43)的预测误差最小为目标进行多元决策树回归, 调用 Python 中 sklearn 决策树训练得到的结果如图 3 所示。

在回归树中, 从根节点开始以平均温度 9.48 °C




图 3 基于历史光伏、电负荷、气象数据的多元回归树示意图

Fig. 3 Multiple regression tree diagram based on historical PV, electricity load and meteorological data

为界限进行首次划分，随后根据日照强度的不同对子节点进行区分，得到的 3 个叶节点即为引入协变量因素的 Wasserstein 模糊集的 3 个场景。场景 1 到场景 3 可视作是从高温度、高日照场景向低温度、低日照场景变化的过程。相同场景中，光伏出力、电负荷需求曲线的变化趋势表征了在相似协变量因素下源荷不确定量预测值的潜在关联性。场景 3 低温度低日照情况下，较低的光伏出力预测值和较高的电负荷需求预测值有着潜在联系。不同场景中，光伏出力、电负荷需求曲线的变化过程表征了源荷不确定量预测误差波动与协变量因素的内在关联性。由场景 1 到场景 3，随着日平均温度和日照强度的降低，光伏出力逐渐减少，电负荷需求逐渐增加，体现协变量因素对不确定量预测误差的影响。此外，各场景在回归树中的占比即为模糊集中的场景概率。为进一步分析各场景特征，不同场景下的光伏功率和电负荷功率情况如图 4、5 所示。

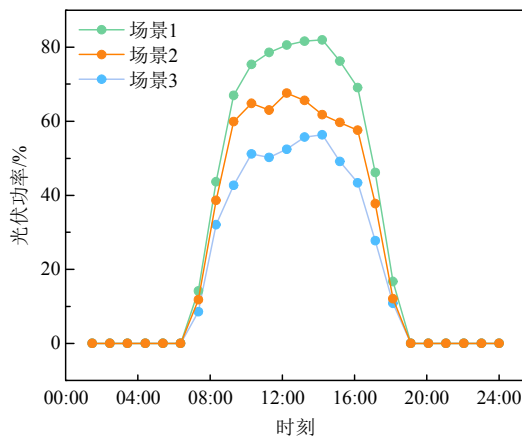


图 4 不同场景下光伏出力情况

Fig. 4 Photovoltaic output in different scenarios




图 5 不同场景下电负荷需求情况

Fig. 5 Power load in different scenarios

图 4 中场景 1 的高日照情况对应着最高的光伏出力，场景 2、3 的光伏出力则依次递减。图 5 中

的电负荷功率对应情况恰好相反，场景 1 对应着最低的电负荷需求，场景 2、3 依次递增。光伏出力与电负荷需求的内在联系通过协变量因素在决策树中的场景回归得以体现。在冬季，高日照往往对应着晴朗的天气和较高的温度，该场景下光伏出力更高，同时用户对电力的需求较少；反之，低日照下光伏出力降低，同时低温度也会导致用户的电力需求增加。基于历史样本的经验概率分布并非固定，通过不断更新的天气预测信息，可对各场景的概率进行修正，使模型求解更符合实际情况。例如，通过天气预测信息得知第二日冷空气来袭，平均气温低于 9.483 °C 的概率达到 90%，则可将场景 3 的概率设为 0.9 以修正模糊集的概率分布，从而获得更符合实际情况的日前调度结果。通过该方式，考虑协变量的分布鲁棒优化模糊集不再局限于历史数据样本，可以依据协变量因素的变化调整模型，更具灵活性。

4.2 分布鲁棒优化结果分析

基于回归树得到的结果建立考虑协变量因素的 Wasserstein 模糊集并进行分布鲁棒优化调度，与确定性优化、鲁棒优化、传统分布鲁棒的对比结果如表 1 所示。

表 1 不同方法的成本比较

Table 1 Cost comparison of different methods

方法	总成本/ 美元	启停 成本/美元	热储能 成本/美元	日内调度 成本/美元
确定性优化	5 294.3	10	133.2	5 151.1
鲁棒优化	5 855.7	20	152.7	5 683.0
传统分布鲁棒优化	5 596.7	20	143.2	5 433.5
改进分布鲁棒优化	5 473.6	20	140.9	5 312.7

确定性优化方法不考虑光伏、电负荷预测误差，求解结果成本最低但牺牲了系统运行可靠性。相较于鲁棒优化和传统分布鲁棒优化方法，本文所提改进分布鲁棒优化的总成本最低，较好地克服了鲁棒优化保守性过高的缺点。其成本降低主要来自于日内调度成本，即通过考虑协变量因素的 Wasserstein 模糊集，改进分布鲁棒对最恶劣情况的刻画更为合理可靠，有效降低了日内调度成本。同时，启停成本和热储能成本两种日前调度成本与另外两种方法相差不大，较好地保留了日前调度结果对不确定量波动的鲁棒性。相比传统分布鲁棒优化，考虑协变量因素的分布鲁棒优化进一步降低了各项成本，并且有着根据协变量因素变化随时调整模型的能力，更具适用性和灵活性。为进一步分析

各设备的工作特性,改进分布鲁棒优化的预调度结果如图6、7所示。

由于冷热电联产机组的电热耦合效应,图6中的机组电功率和图7中的热回收功率变化趋势基本一致。图6中16:00—21:00时段,光伏机组出力趋于0,为满足较高的电负荷需求,冷热电联产机组出力提高,相应热回收功率也增加。此时图7中热回收功率已经超过热负荷需求,多余热量由储热系统进行存储以提高能源利用效率。图7中03:00—07:00时段为热负荷高峰阶段,对应时




图6 电负荷供需情况

Fig. 6 Electricity load and supply

表2 不同预测误差下样本外平均成本

Table 2 Average cost out of sample with different forecast errors

标准差	$\sigma^{PV}=5\% \bar{P}^{PV}$	$\sigma^{EL}=2\% \bar{P}^{EL}$	$\sigma^{PV}=10\% \bar{P}^{PV}$	$\sigma^{EL}=4\% \bar{P}^{EL}$	$\sigma^{PV}=20\% \bar{P}^{PV}$	$\sigma^{EL}=8\% \bar{P}^{EL}$
方法	平均成本/美元	日内调度无解比例/%	平均成本/美元	日内调度无解比例/%	平均成本/美元	日内调度无解比例/%
确定性优化	5294.6	0	5295.7	4.3	5295.9	14.1
分布鲁棒优化	5311.3	0	5312.5	0	5312.6	0

相较于表1, MCS测试中分布鲁棒优化的结果与确定性优化结果更加接近,因为此时日内调度是基于MCS生成的光伏、电负荷样本数据进行优化的,不再考虑最恶劣情况下的调度。3组MCS样本均值为0,主要区别在于波动范围不同,故平均成本的变化幅度不大。随着预测误差波动范围的增加,基于确定性优化结果得到日前调度决策在日内调度中出现无解的比例逐渐增加;相比之下,基于改进分布鲁棒优化得到的日前调度决策则表现出了对预测误差波动的优秀抵抗性,保障了日内调度的安全可靠运行。

5 结论

本文综合考虑可再生能源出力不确定性、需求

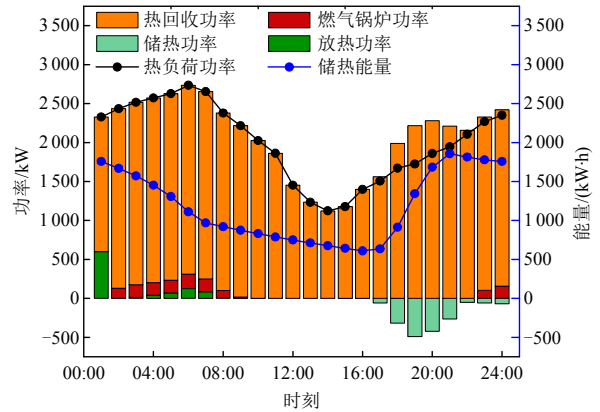


图7 热负荷供需情况

Fig. 7 Thermal load and supply

段的电负荷需求较低,限制冷热电联产机组的出力,故由燃气锅炉及热储能系统放热协助平衡热负荷需求。由于柴油发电机和燃气锅炉成本系数较高,作为备用设备仅在图6、7中电负荷、热负荷高峰时段出力。

4.3 蒙特卡洛可行性验证

为了验证基于分布鲁棒优化结果得到的日前调度决策应对不确定量波动的鲁棒性,采用蒙特卡罗仿真(Monte Carlo simulation, MCS)方法进行样本外测试。假设不确定变量预测误差服从正态分布,均值为0,以不同标准差各生成1000组数据进行MCS测试,其样本外平均运行成本如表2所示。

侧负荷波动对系统运行的影响,建立了考虑协变量因素的多能微电网两阶段分布鲁棒优化调度模型。主要结论如下:

1) 同时考虑源荷不确定性,将光伏出力、电负荷需求的预测误差描述为以历史数据经验分布为中心的模糊集能够有效改善传统鲁棒优化的过度保守性,实现分布鲁棒优化调度模型对经济性和鲁棒性的平衡。

2) 不同不确定量预测误差间的潜在关联性以及不确定量受协变量因素影响的内在依赖性可通过对协变量因素的多元决策树回归方法进行刻画,构建考虑协变量因素的Wasserstein模糊集,进一步提高模型求解结果的可靠性和经济性。通过协变量因素预测信息的不断修正,使模型的调度结果更符

合实际需求。

3) 仿真结果表明, 本文所提多能微电网两阶段分布鲁棒优化调度模型得到的结果相较传统方法有着更好的经济性, 其日前调度决策在蒙特卡洛仿真实验中对不确定量的波动表现出良好的鲁棒性。

需要指出的是, 协变量因素数量及质量对不同不确定量预测误差的潜在关系尚未明确, 如何更加高效合理地建立考虑协变量因素的分布鲁棒优化调度框架将是下一步研究的重点。

参考文献

- [1] ZHU Jizhong. Optimization of power system operation [M]. New York: Wiley-IEEE Press, 2015.
- [2] 杨经纬, 张宁, 王毅, 等. 面向可再生能源消纳的多能源系统: 述评与展望[J]. 电力系统自动化, 2018, 42(4): 11-24.
YANG Jingwei, ZHANG Ning, WANG Yi, et al. Multi-energy system towards renewable energy accommodation: review and prospect[J]. Automation of Electric Power Systems, 2018, 42(4): 11-24(in Chinese).
- [3] MANCARELLA P. MES(multi-energy systems): An overview of concepts and evaluation models[J]. Energy, 2014, 65: 1-17.
- [4] 左逢源, 张玉琼, 赵强, 等. 计及源荷不确定性的综合能源生产单元运行调度与容量配置两阶段随机优化[J]. 中国电机工程学报, 2022, 42(22): 8205-8214.
ZUO Fengyuan, ZHANG Yuqiong, ZHAO Qiang, et al. Two-stage stochastic optimization for operation scheduling and capacity allocation of integrated energy production unit considering supply and demand uncertainty[J]. Proceedings of the CSEE, 2022, 42(22): 8205-8214(in Chinese).
- [5] 孙鹏, 滕云, 回茜, 等. 考虑热惯性不确定性的多能源系统两阶段鲁棒优化调度模型[J]. 中国电机工程学报, 2021, 41(21): 7249-7260.
SUN Peng, TENG Yun, HUI Qian, et al. Two-stage robust optimal scheduling model for multi-energy systems considering thermal inertia uncertainty[J]. Proceedings of the CSEE, 2021, 41(21): 7249-7260(in Chinese).
- [6] 王雅平, 林舜江, 杨智斌, 等. 微电网多目标随机动态优化调度算法[J]. 电工技术学报, 2018, 33(10): 2196-2207.
WANG Yaping, LIN Shunjiang, YANG Zhibin, et al. Multi-objective stochastic dynamic optimal dispatch algorithm of microgrid[J]. Transactions of China Electrotechnical Society, 2018, 33(10): 2196-2207(in Chinese).
- [7] ABUNIMA H, PARK W H, GLICK M B, et al. Two-stage stochastic optimization for operating a renewable-based microgrid[J]. Applied Energy, 2022, 325: 119848.
- [8] 桑博, 张涛, 刘亚杰, 等. 期望场景下的并网型微电网两阶段鲁棒优化调度[J]. 中国电机工程学报, 2020, 40(19): 6161-6172.
SANG Bo, ZHANG Tao, LIU Yajie, et al. Two-stage robust optimal scheduling of grid-connected microgrid under expected scenarios[J]. Proceedings of the CSEE, 2020, 40(19): 6161-6172(in Chinese).
- [9] YANG Nan, QIN Tao, WU Lei, et al. A multi-agent game based joint planning approach for electricity-gas integrated energy systems considering wind power uncertainty[J]. Electric Power Systems Research, 2022, 204: 107673.
- [10] SABERI H, ZHANG Cuo, DONG Zaoyang. Data-driven distributionally robust hierarchical coordination for home energy management[J]. IEEE Transactions on Smart Grid, 2021, 12(5): 4090-4101.
- [11] HUANG Hongxu, LIANG Rui, LV Chaoxian, et al. Two-stage robust stochastic scheduling for energy recovery in coal mine integrated energy system [J]. Applied Energy, 2021, 290: 116759.
- [12] KARIMI H, JADID S. Optimal energy management for multi-microgrid considering demand response programs: A stochastic multi-objective framework[J]. Energy, 2020, 195: 116992.
- [13] 杨策, 孙伟卿, 韩冬, 等. 考虑风电出力不确定的分布鲁棒经济调度[J]. 电网技术, 2020, 44(10): 3649-3655.
YANG Ce, SUN Weiqing, HAN Dong, et al. Distributionally-robust economic dispatch considering uncertain wind power output[J]. Power System Technology, 2020, 44(10): 3649-3655(in Chinese).
- [14] 朱兰, 李孝均, 唐陇军, 等. 考虑相变储能与建筑蓄能特性的微网分布鲁棒优化调度[J]. 电网技术, 2021, 45(6): 2308-2318.
ZHU Lan, LI Xiaojun, TANG Longjun, et al. Distributionally robust optimal operation for microgrid considering phase change storage and building storage[J]. Power System Technology, 2021, 45(6): 2308-2318(in Chinese).
- [15] CAO Yang, WEI Wei, CHEN Laijun, et al. Supply inadequacy risk evaluation of stand-alone renewable powered heat-electricity energy systems: a data-driven robust approach[J]. IEEE Transactions on Industrial Informatics, 2021, 17(3): 1937-1947.
- [16] WANG Yuwei, YANG Yuanjuan, TANG Liu, et al. A Wasserstein based two-stage distributionally robust

- optimization model for optimal operation of CCHP micro-grid under uncertainties[J]. International Journal of Electrical Power & Energy Systems, 2020, 119: 105941.
- [17] 侯慧, 甘铭, 吴细秀, 等. 考虑移动氢能存储的港口多能微网两阶段分布鲁棒优化调度[J]. 中国电机工程学报, 2024, 44(8): 3078-3039.
- HOU Hui, GAN Ming, WU Xixiu, et al. Two-stage distributionally robust optimal scheduling for port multi-energy microgrid considering mobile hydrogen energy storage[J]. Proceedings of the CSEE, 2024, 44(8): 3078-3039 (in Chinese).
- [18] 万灿, 宋永华. 新能源电力系统概率预测理论与方法及其应用[J]. 电力系统自动化, 2021, 45(1): 2-16.
- WAN Can, SONG Yonghua. Theories, methodologies and applications of probabilistic forecasting for power systems with renewable energy sources[J]. Automation of Electric Power Systems, 2021, 45(1): 2-16(in Chinese).
- [19] 杨秀, 陈斌超, 朱兰, 等. 基于相关性分析和长短期记忆网络分位数回归的短期公共楼宇负荷概率密度预测[J]. 电网技术, 2019, 43(9): 3061-3070.
- YANG Xiu, CHEN Binchao, ZHU Lan, et al. Short-term public building load probability density prediction based on correlation analysis and long- and short-term memory network quantile regression[J]. Power System Technology, 2019, 43(9): 3061-3070(in Chinese).
- [20] 朱继忠, 董瀚江, 李盛林, 等. 数据驱动的综合能源系统负荷预测综述[J]. 中国电机工程学报, 2021, 41(23): 7905-7923.
- ZHU Jizhong, DONG Hanjiang, LI Shenglin, et al. Review of data-driven load forecasting for integrated energy system[J]. Proceedings of the CSEE, 2021, 41(23): 7905-7923(in Chinese).
- [21] DONG Hanjiang, ZHU Jizhong, LI Shenglin, et al. Short-term residential household reactive power forecasting considering active power demand via deep Transformer sequence-to-sequence networks[J]. Applied Energy, 2023, 329: 120281.
- [22] ZHANG Cuo, XU Yan, DONG Zhaoyang. Robustly coordinated operation of a multi-energy micro-grid in grid-connected and islanded modes under uncertainties [J]. IEEE Transactions on Sustainable Energy, 2020, 11(2): 640-651.
- [23] YEH H G, GAYME D F, LOW S H. Adaptive VAR control for distribution circuits with photovoltaic generators[J]. IEEE Transactions on Power Systems, 2012, 27(3): 1656-1663.
- [24] ESFAHANI P M, DANIEL K. Data-driven distributionally robust optimization using the Wasserstein metric: performance guarantees and tractable reformulations[J]. Mathematical Programming, 2018, 171(1-2): 115-166.
- [25] BUSINESS M. New Findings from national university of Singapore in manufacturing provides new insights (Robust Vehicle Pre-allocation With Uncertain Covariates) [J]. Journal of Technology, 2020, 29(4): 955-972.
- [26] XIONG P, JIRUTITIJAROEN P, SINGH C. A distributionally robust optimization model for unit commitment considering uncertain wind power generation [J]. IEEE Transactions on Power Systems, 2017, 32(1): 39-49.
- [27] ZHAO Chaoyue, GUAN Yongpei. Data-driven risk-averse stochastic optimization with Wasserstein metric [J]. Operations Research Letters, 2018, 46(2): 262-267.
- [28] DKA Solar Centre. Yulara solar system [EB/OL]. (2023-06-05)[2023-06-05]. <https://dkasolarcentre.com.au/locations/yulara>.
- [29] AEMO. Electricity price & demand [EB/OL]. (2023-06-05) [2023-06-05]. <https://www.aemo.com.au>.

附录 A 算例参数




图 A1 日前调度阶段购售电价

Fig. A1 Electricity price of purchase and sale in pre-dispatch stage

表 A1 热网各设备参数

Table A1 Parameters of each equipment in the heat network

节点位置	冷热电联产	热回收系统	热储能	(热储能充/	热锅炉	热负荷/(kW-h)
	机组出力上/下	产热上限/下限	容量/	放热上限/	上限/	
	kW	(kW-h)	(kW-h)	(kW-h)	(kW-h)	
8	40/400	285	400	75	40	200
14	40/400	285	400	100	40	300
24	60/600	570	600	150	80	600
25	60/600	570	200	50	80	500
30	30/300	285	600	100	40	300
32	50/500	570	400	125	80	400

表 A2 光伏机组参数

Table A2 PV unit parameters

节点位置	基准功率/kW	节点位置	基准功率/kW
7	100	25	250
10	100	29	100
12	50	30	200
16	50	31	150
18	100	32	50
24	300	总功率	1 450

表 A3 各成本和设备系数

Table A3 Cost and equipment coefficients

名称	缩写	数值	
启停成本系数/美元	C^{BDG}	5	
热储能成本系数/(美元/(kW·h))	C^{ES}	0.05	
燃煤成本系数/(美元/(kW·h))	C^{gas}	0.35	
	C^{fuel}	0.145	
运维成本系数/(美元/(kW·h))	O_M^{BDG}	0.008	
	O_M^{CCHP}	0.012	
	O_M^{PV}	0.013	
设备爬坡系数	R^{BDG}	0.5	
	R^{CCHP}	0.5	
煤气转换系数/(kW·h)/m ³)	ρ	9.78	
	η^{TS}	0.95	
	$\eta^{TSC/D}$	0.97	
	能量转换系数	η^{PGU}	0.33
		η^{HR}	0.7
		η^{AB}	0.6



李鸿

在线出版日期：2024-05-08。

收稿日期：2023-06-19。

作者简介：

李鸿(1998)，男，硕士研究生，研究方向为多能微电网系统优化运行及其不确定性调度，202121016981@mail.scut.edu.cn；

*通信作者：朱继忠(1966)，男，意大利博洛尼亚科学院外籍院士，中国电机工程学会会士，教授，博士生导师，IEEE Fellow，主要从事综合智慧能源系统优化运行与控制方面的研究工作，zhujz@scut.edu.cn；

董瀚江(1998)，男，博士研究生，研究方向为综合智慧能源系统优化运行与控制，epdonghj@mail.scut.edu.cn。

(责任编辑 李泽荣)