

基于数据驱动的微电网双层鲁棒优化调度

张军¹, 张中丹², 王洲², 彭婧², 王涛²

(1. 国网甘肃省电力公司, 甘肃 兰州 730030;

2. 国网甘肃省电力公司经济技术研究院, 甘肃 兰州 730050)

摘要:提出了一种基于数据驱动的微电网两阶段自适应鲁棒优化调度方法。首先,构建了基于数据驱动的微电网市场调度优化框架,利用K-means聚类方法对微电网大量历史数据进行聚类预处理,选取典型场景代表大量复杂场景来获得准确地风电出力概率分布情况。然后,在阶段一建立微电网日前预调度模型;基于预处理的聚类数据,建立数据驱动的风力发电的不确定性集合,在阶段二建立微电网实时调控模型。通过数据驱动构造的风力发电不确定性集合,排除了部分极端场景,降低了模型的保守度。接着,用列约束生成算法(C&CG)将构建的两阶段自适应鲁棒优化模型分解为主问题和子问题进行交互迭代求解。最后,仿真结果验证了所提方法的有效性,降低了微电网设备运行成本,提高了新能源利用率。

关键词:数据驱动;自适应鲁棒优化;K-means聚类方法;列约束生成算法

中图分类号:TM28 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed22679

Double Layer Robust Optimal Dispatching of Micro-grid Based on Data-driven

ZHANG Jun¹, ZHANG Zhongdan², WANG Zhou², PENG Jing², WANG Tao²

(1. State Grid Gansu Electric Power Company, Lanzhou 730030, Gansu, China;

2. Economic and Technological Research Institute of State Grid Gansu Electric Power Company, Lanzhou 730050, Gansu, China)

Abstract: A two-stage adaptive robust optimization (ARO) dispatching method based on data-driven micro-grid was proposed. First of all, a data-driven market scheduling optimization framework for micro-grid was built. K-means clustering method was used to conduct clustering pretreatment for a large amount of historical data of micro-grid, and typical scenes were selected to represent a large number of complex scenes to obtain accurate probability distribution of wind power output. Then, the day-ahead scheduling model of the micro grid was established in stage 1. Based on the pre-processed clustering data, the uncertainty set of data-driven wind power generation was established, and the real-time regulation model of micro-grid was established in stage 2. Through the uncertainty set of wind power generation constructed by data driving, some extreme scenarios were eliminated and the conservatism of the model was reduced. Then, the two-stage adaptive robust optimization model was decomposed into an interactive iterative solution for the main problem and the subproblem by using the column constraint generation algorithm (C&CG). Finally, simulation results verify the effectiveness of the proposed method, it can reduce the operating cost of micro-grid equipment, and improve the efficiency of new energy.

Key words: data-driven; adaptive robust optimization (ARO); K-means clustering method; column constraint generation algorithm (C&CG)

随着全球人口的急剧增多、工业化迅速发展,煤炭、石油等传统能源急剧消耗,全球变暖、大气污染等环境问题日益严重。为解决传统能源消耗与环境污染之间的突出矛盾,电力能源领

域将目光投向了具有污染小、可再生、高灵活性等优势的可再生能源发电技术^[1]。微电网凭借其供电可靠性高、运行方式灵活等优点,成为可再生能源就地消纳和并网远送的主要模式,并得到

了普遍的关注和研究^[2-3]。

为实现微电网多目标协调优化调度和安全稳定运行,文献[4-6]利用不同的算法对微电网调度做出了一定程度上的优化,但均忽略了可再生能源具有的波动性、间歇性和随机性等不确定性因素对微电网调度及安全运行产生的巨大影响^[7-9]。目前,常用的电力系统不确定性因素调度优化方法主要有两种:随机优化和鲁棒优化。关于电力系统随机优化调度问题的研究,文献[10]考虑风速的不确定性,将每个风电场出力视为一个负的满足威布尔随机分布的负荷,根据历史数据,用方差-协方差矩阵描述不同风电场相关系数,建立最优潮流模型,定量研究随着风电场之间相关性的增强,最优潮流结果各项指标的波动情况。关于电力系统鲁棒优化调度问题的研究,文献[11]提出了一种新的两阶段鲁棒安全约束算法机组组合模型,期望在基本场景中使得运行成本最小化,保证鲁棒解能够根据不确定性自适应、安全地进行风力和负荷调整。随机调度优化方法需要假定随机变量的概率分布模型,但概率分布模型不能准确地刻画实际不确定性因素复杂的变化规律;鲁棒调度优化方法采用不确定集合对不确定性因素变化进行刻画,不需要假定概率分布模型,但在考虑最差场景下的最优解时,可能导致鲁棒优化调度结果偏保守^[12]。近年来,随着微电网量测系统的发展完善,终端采集数据海量增加,基于数据驱动的优化调度方法开始被广泛关注,将其有效地应用在随机优化和鲁棒优化方法上,以解决随机优化不确定因素建模不准确和鲁棒优化保守性强等问题。

基于以上问题,文章设计了基于数据驱动的自适应鲁棒优化(ARO)框架,用于求解风电为主的微电网市场调度优化问题。利用K-means聚类方法构建典型场景代表大量复杂的场景,然后通过数据驱动方法构建风电不确定性集合,对风电出力分布进行描述,有效地排除了不必要的极端场景,降低了模型保守度。考虑风电出力不确定性等因素,建立包括微电网日前预调度模型及实时调度模型的两阶段自适应鲁棒优化模型。利用列约束生成算法(C&CG)将模型解耦分解成主问题和子问题进行迭代求解。最后,算例仿真验证文章所提方法的可行性和有效性。

1 基于数据驱动的微电网市场自适应鲁棒调度优化的理论框架

1.1 数据驱动的微电网市场调度优化框架

考虑到数据驱动的微电网市场优化结果受到训练数据集的直接影响,训练集规模越大,优化结果往往越准确,但其训练时间也越来越长。针对上述问题,文章提出了基于数据驱动的模式预训练(离线训练)和滚动训练(在线训练)的微电网优化调度架构,如图1所示。由图1可以看出,离线训练主要是利用系统在线训练前后的空闲时间,利用K-means聚类方法对微电网历史交互数据和微电网模拟生成数据进行训练,确定不确定参数典型场景来代表大量复杂场景。在线训练主要是利用离线训练预调度阶段的数据,加上微电网实时调度阶段生成的增量样本数据进行实时滚动训练,实现预调度阶段最小成本优化和实时调控阶段额外调控成本及弃风惩罚成本最小的决策优化,得到符合实时工况的优化调度结果。

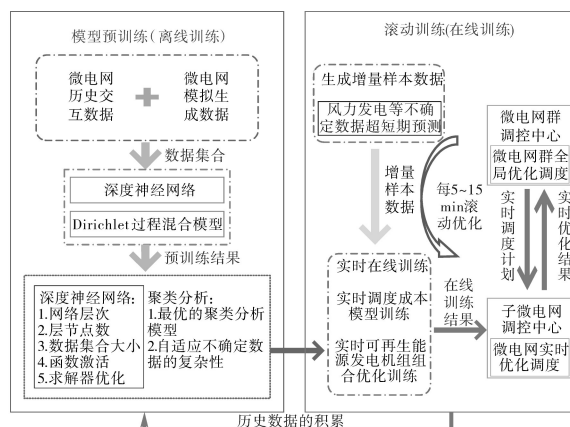


图1 基于数据驱动的微电网优化调度框架

Fig.1 Optimal dispatching framework of micro-grid based on data drive

1.2 微电网市场自适应鲁棒优化模型

鲁棒优化主要采用不确定性集合表示不确定性因素的变化范围,对寻求不确定性因素的所有实现都有良好性能的解。传统鲁棒优化根据不确定性集合中的最差场景直接进行决策,因此优化结果的保守性较强。近年来,ARO在电力系统调度优化方面取得了较好的发展^[13-14],其决策过程是基于随机变量的实际变化来进行调整,基于ARO的两阶段调度优化模型表达式如下:

$$\min_x g(x) + \max_{\xi \in U} [\min_{y \in \Omega(x, \xi)} f(y)] \quad (1)$$

式中: x 为第1阶段决策变量,表示机组启停计划; $g(x)$ 为第1阶段优化问题的目标函数; ζ 为随机变量,表示可再生能源发电与负荷的不确定性; y 为第2阶段决策变量; $f(y)$ 为第2阶段优化问题的目标函数; $\Omega(x, \zeta)$ 为 y 的可行域; U 为随机变量 ζ 的不确定性集合。

在式(1)的基础上,文章研究构建以微电网经济调度成本最小为目标的两阶段自适应调度优化模型,主要包括微电网预调度阶段和微电网实时在线调控阶段。

1.2.1 微电网日前预调度阶段

该阶段主要是确定微电网日前预调度计划,以选取的微电网历史交互数据与风电预测值作为基准场景,考虑微电网市场的奖惩费用和设备的运维成本,确定微电网发电机组的启停计划和发电量、储能系统的充放电计划以及与主电网的购售电计划,实现微电网预调度阶段运行成本最优的调度目标。预调度阶段目标函数表达式为

$$\min G = \sum_{\tau=1}^T (C_{\tau}^C + C_{i,\tau}^{DS} + C_{\tau}^{ES} + C_{\tau}^M + C_{\tau}^{AP}) \quad (2)$$

式中: G 为总成本; T 为时间段总数,预调度阶段取 $T=24$; C_{τ}^C 为常规机组、燃气轮机以及风机在 τ 时间段的运行运行成本; $C_{i,\tau}^{DS}$ 为常规发电机组 i 在 τ 时间段的启、停成本; C_{τ}^{ES} 为储能设备在 τ 时间段的充放电成本; C_{τ}^M 为微电网在 τ 时间段与主电网的交易成本; C_{τ}^{AP} 为奖惩费用。

预调度阶段目标函数中各变量表达式为

$$\begin{cases} C_{\tau}^C = \sum_{i=1}^{N_c} [a_i (P_{i,\tau}^{CG})^2 + b_i P_{i,\tau}^{CG} + c_i] + \sum_{q=1}^{Q_r} g_{q,\tau} + \sum_{j=1}^{N_w} f_{j,\tau} \\ C_{i,\tau}^{DS} = u_{i,\tau} (1 - u_{i,\tau-1}) S_{i,\tau}^{SU} + u_{i,\tau-1} (1 - u_{i,\tau}) S_{i,\tau}^{SD} \\ C_{\tau}^{ES} = C^{\text{ch}} P_{\tau}^{\text{ch}} - C^{\text{dis}} P_{\tau}^{\text{dis}} \\ C_{\tau}^M = \lambda_{\tau}^{\text{in}} P_{\tau}^{\text{in}} - \lambda_{\tau}^{\text{out}} P_{\tau}^{\text{out}} \\ C_{\text{AP}} = K_1 [\min(0, h_1)]^2 + K_2 h_2^2 - (\omega_e - \omega_{e_0}) R_{\tau} + c_{\tau}^{\text{ex}} (H_{\tau} - H_{e_0}) \end{cases} \quad (3)$$

式中: N_c 为 τ 时间段内常规发电机组运行数; $P_{i,\tau}^{CG}$ 为常规发电机组 i 在 τ 时间段的发电功率; a_i, b_i, c_i 为常规发电机组 i 的传统能源消耗系数; $g_{q,\tau}$ 为燃气轮机 q 在 τ 时间段的运行成本; Q_r 为 τ 时间段内运行燃气轮机数; $f_{j,\tau}$ 为风机 j 在 τ 时间段的运行成本; N_w 为 τ 时间段内风机运行数; $u_{i,\tau}$ 为常规发电机组 i 在 τ 时间段的运行状态 ($u=1$ 表示机组正在运行, $u=0$ 表示机组停止运行); $S_{i,\tau}^{SU}$ 和 $S_{i,\tau}^{SD}$ 分别为机组 i 在 τ 时间段的启、停成本; $C^{\text{ch}}, C^{\text{dis}}$ 以及 $P_{\tau}^{\text{ch}}, P_{\tau}^{\text{dis}}$

分别为储能设备的充、放电系数和充、放电功率; $\lambda_{\tau}^{\text{in}}, \lambda_{\tau}^{\text{out}}$ 以及 $P_{\tau}^{\text{in}}, P_{\tau}^{\text{out}}$ 分别为在 τ 时间段,微电网与主电网的交易分时电价和购、售电功率; h_1, h_2 分别为不等式约束条件、等式约束条件; ω_e, ω_{e_0} 为当前阶段能源利用率和标准能源利用率; R_{τ} 为每提高单位标准的能源利用率的奖励收益; c_{τ}^{ex} 为每增加单位标准的污染废气的惩罚费用; H_{τ}, H_{e_0} 分别为运行阶段和允许标准的污染废气排放量; K_1, K_2 分别为不满足条件时的惩罚因子,取较大值以保证满足约束条件。

1.2.2 微电网实时调控阶段

在微电网实时调控阶段,由于风力发电复杂的不确定因素,使得风力发电预测值与实际出力之间存在偏差,导致系统产生不平衡功率,因此需要根据预调度计划,对风力发电进行实时调控,实现实时调控成本和风力发电出力最优化目标。文章考虑到储能设备调控方式灵活,忽略其实时调控时的调控成本,仅考虑对储能设备进行调控时的收益变化,则实时调控阶段的目标函数表达式为

$$\min F = \Delta C^{G,\text{up}} + \Delta C^{G,\text{down}} + \Delta C^{ES} + \Delta C^M + C^{\text{loss}} + \max C^r \quad (4)$$

式中: $\Delta C^{G,\text{up}}$ 为常规发电机组上调成本; $\Delta C^{G,\text{down}}$ 为常规发电机组下调成本; ΔC^{ES} 为储能设备调整成本; ΔC^M 为与主电网购售电交易调整成本; C^{loss} 为风电弃风惩罚调整费用; C^r 为燃气轮机调控不可行惩罚费用,各变量表达式详见下式:

$$\begin{cases} \Delta C^{G,\text{up}} = \sum_{\tau=1}^T \sum_{i=1}^{N_c} \lambda_{i,\tau}^{\text{up}} P_{i,\tau}^{\text{up}} \\ \Delta C^{G,\text{down}} = \sum_{\tau=1}^T \sum_{i=1}^{N_c} \lambda_{i,\tau}^{\text{down}} P_{i,\tau}^{\text{down}} \\ \Delta C^{ES} = \sum_{\tau=1}^T (C^{\text{ch}} \Delta P_{\tau}^{\text{ch}} - C^{\text{dis}} \Delta P_{\tau}^{\text{dis}}) \\ \Delta C^M = \sum_{\tau=1}^T \lambda^M (\Delta P_{\tau}^{\text{in}} - \Delta P_{\tau}^{\text{out}}) \\ \Delta C^{\text{loss}} = \sum_{\tau=1}^T \sum_{j=1}^{N_w} \lambda^{\text{loss}} (P_{j,\tau}^W - P_{j,\tau}^{\text{WS}}) \\ \Delta C^r = \sum_{\tau=1}^T \sum_{q=1}^Q \lambda^r N_{q,\tau}^r \end{cases} \quad (5)$$

式中: $P_{i,\tau}^{\text{up}}, \lambda_{i,\tau}^{\text{up}}$ 为在 τ 时间段内常规发电机组 i 上调功率和上调单位功率的惩罚成本; $P_{i,\tau}^{\text{down}}, \lambda_{i,\tau}^{\text{down}}$ 为在 τ 时间段内常规发电机组 i 的下调功率和下调单位功率的惩罚成本; $\Delta P_{\tau}^{\text{ch}}, \Delta P_{\tau}^{\text{dis}}$ 分别为储能设备充电、放电调整功率; λ^M 为调整电价; $\Delta P_{\tau}^{\text{in}}, \Delta P_{\tau}^{\text{out}}$ 为微

电网向主电网购、售电的电量调整量; λ^{loss} 为风电机组弃风惩罚单价; $P_{j,\tau}^{\text{W}}, P_{j,\tau}^{\text{WS}}$ 分别为风电机组 j 在 τ 时间段出力和调度出力; λ^{r} 为供气不可行惩罚费用; $N_{q,\tau}^{\text{r}}$ 为一个松弛变量,表示为供气调整量。

1.2.3 约束条件

为保证微电网能源供给侧各设备在预调度阶段能协调稳定运行,约束条件主要包括功率平衡约束,风电功率约束,机组爬、滑坡功率约束,储能设备约束以及功率交互等约束。

功率平衡等式约束表达式为

$$\sum_{i=1}^{N_g} P_{i,\tau}^{\text{CG}} + \sum_{q=1}^{Q_s} P_{q,\tau}^{\text{R}} + \sum_{j=1}^{N_w} P_{j,\tau}^{\text{W}} + P_{\tau}^{\text{in}} - P_{\tau}^{\text{out}} + P_{\tau}^{\text{dis}} - P_{\tau}^{\text{ch}} - P_{\tau}^{\text{load}} = 0 \quad (6)$$

不等式约束表达式为

$$\left\{ \begin{array}{l} P_{\tau}^{\text{G,min}} \leq P_{\tau}^{\text{G}} \leq P_{\tau}^{\text{G,max}} \\ (u_{i,\tau-1} - u_{i,\tau})(T_{i,\tau-1}^{\text{on}} - T_{i,\tau}^{\text{on}}) \geq 0 \\ (u_{i,\tau-1} - u_{i,\tau})(T_{i,\tau-1}^{\text{off}} - T_{i,\tau}^{\text{off}}) \geq 0 \\ P_{i,\tau}^{\text{CG}} - P_{i,\tau-1}^{\text{CG}} = r_i^{\text{u}} u_{i,\tau} + P_{i,\tau}^{\text{CG,min}} (1 - u_{i,\tau-1}) \\ P_{i,\tau-1}^{\text{CG}} - P_{i,\tau}^{\text{CG}} = r_i^{\text{d}} u_{i,\tau-1} + P_{i,\tau}^{\text{CG,min}} (1 - u_{i,\tau}) \\ 0 \leq P_{j,\tau}^{\text{WS}} \leq P_{j,\tau}^{\text{W}} \\ S_{\tau}^{\text{ES}} = S_{\tau-1}^{\text{ES}} + \eta_c P_{\tau}^{\text{ch}} - P_{\tau}^{\text{dis}} / \eta_d \\ S_{\tau}^{\text{ES,min}} \leq S_{\tau}^{\text{ES}} \leq S_{\tau}^{\text{ES,max}} \\ 0 \leq P_{\tau}^{\text{ch}} \leq P_{\tau}^{\text{ch,max}} \mu_{\tau}^{\text{ch}} \\ 0 \leq P_{\tau}^{\text{dis}} \leq P_{\tau}^{\text{dis,max}} \mu_{\tau}^{\text{dis}} \\ \mu_{\tau}^{\text{ch}} + \mu_{\tau}^{\text{dis}} \leq 1 \\ 0 \leq P_{\tau}^{\text{in}} \leq P_{\tau}^{\text{in,max}} S_{\tau}^{\text{in}} \\ 0 \leq P_{\tau}^{\text{out}} \leq P_{\tau}^{\text{out,max}} S_{\tau}^{\text{out}} \\ \mu_{\tau}^{\text{in}} + \mu_{\tau}^{\text{out}} \leq 1 \\ S_{i,\tau}^{\text{U}} + S_{i,\tau}^{\text{D}} \leq 1 \end{array} \right. \quad (7)$$

式中: $T_{i,\tau}^{\text{on}}, T_{i,\tau}^{\text{off}}$ 分别为 τ 时间段连续运行、停运时间; $r_i^{\text{u}}, r_i^{\text{d}}$ 分别为常规机组 i 的爬坡速率和滑坡速率; $S_{\tau}^{\text{ES,min}}, S_{\tau}^{\text{ES,max}}$ 分别为储能系统储能量的最小值和最大值; S_{τ}^{ES} 为储能系统 τ 时刻储能量; $S_{\tau}^{\text{in}}, S_{\tau}^{\text{out}}$ 分别为 τ 时刻买入和售出电量; $P_{\tau}^{\text{ch,max}}, P_{\tau}^{\text{dis,max}}$ 分别为储能设备充电最大功率和放电最大功率; η_c, η_d 分别为储能系统充放电系数; $\mu_{\tau}^{\text{in}}, \mu_{\tau}^{\text{out}}$ 为辅助变量,取值为1表示与主电网有电量交易,取值为0表示与主电网没有电量交易; $\mu_{\tau}^{\text{ch}}, \mu_{\tau}^{\text{dis}}$ 分别为储能系统在 τ 时刻的充放电辅助变量。

2 构建数据驱动的不确定性集合

K -means 算法^[15]主要通过衡量样本集内不同样本间的相似度实现样本的划分,该算法计算效率高且伸缩性好,能够使相似度高的样本归为一

簇。考虑到风力发电的复杂不确定性,提出了基于数据驱动的方法描述风电出力,以风电历史数据作为参考来表征风电出力的不确定性。首先对风电出力和负荷需求等的大规模历史样本数据进行训练统计分析,确定日内各时段实际数据与典型数据服从的相应概率分布,然后依据轮盘赌的方式,确定不同场景不同时段下的概率误差。接着基于场景分析法得出不同的场景,并利用经典场景分析法将大量已生成场景缩减至 M 个风电样本场景,最后利用 K -means 聚类算法对 M 个风电样本场景进行缩减聚类,采用距离相似性的评价指标,生成具有不确定性和随机特征的 $K(K < M)$ 类风电时序离散场景 k_1, k_2, \dots, k_s ,每个典型场景 u_k 中都包含 N_s 个原始场景,对应场景标准化概率为 $P_k(s)$, K -means 算法场景缩减优化步骤如图2所示。

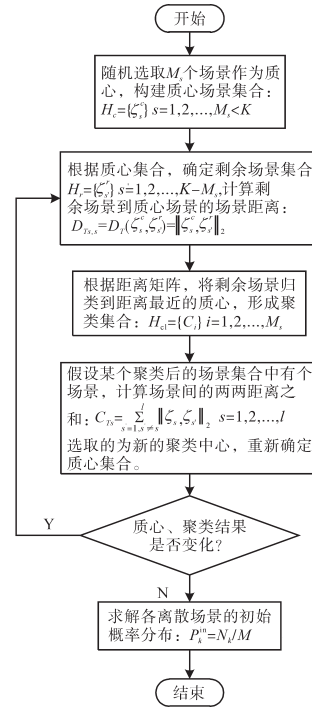


图2 K -means 算法场景缩减流程图

Fig.2 K -means algorithm scene reduction flow chart

通过 K -means 算法对场景进行缩减,利用典型的场景代表大量复杂的场景来获得真实分布的信息,据此构造基于数据驱动的风力发电的不确定性集合来描述风力发电概率分布,文章通过1—范数和 ∞ —范数构建的综合范数约束集合对风力发电概率分布进行约束,基于数据驱动的不确定性集合通过对大量历史信息进行训练,排除了极端不可能场景概率,相较于传统盒式不确定集合,有效地降低了决策的保守度,其约束集合

表达式表示如下:

$$\Omega = \left\{ p_k \begin{cases} p_k \geq 0 & k = 1, 2, \dots, K \\ \sum_{k=1}^K p_k = 1 \\ \sum_{k=1}^K |p_k - p_k^{in}| \leq \theta_1 \\ \max_{k=1, 2, \dots, K} |p_k - p_k^{in}| \leq \theta_\infty \end{cases} \right\} \quad (8)$$

式中: θ_1, θ_∞ 分别为 1 范数、无穷范数概率允许偏差值,具体表达式形式详见文献[16-17]。

3 模型求解

在式(1)的基础上将日前预调度模型和实时调控模型构建为自适应鲁棒两阶段优化模型,考虑搜寻风电出力最恶劣场景下最经济日前调度方案,并同时考虑基于数据驱动的风力发电的不确定概率分布集合,最终目标函数表达式为

$$U = \min_x G + \max_{p_k \in \Omega} \left\{ \sum_{k=1}^K p_k \min_y \{F\} \right\} \quad (9)$$

式中: x 为风电最恶劣场景下最经济日前调度方案; y 为对应于日前调度方案 x 的最经济实时调控方案。文章对于目标函数模型利用列约束生成算法(C&CG)进行求解,将其写成紧凑矩阵形式为

$$\min_x c^T x + \max_{u \in \Omega} \min_{y \in \Theta(x,u)} d^T y \quad (10)$$

$$\Theta(x,u) = \begin{cases} Hx \leq b \\ E(y) \leq u \\ Fx + Gy = Hu \end{cases} \quad (11)$$

式中: $c^T x$ 为日前预调度成本函数; $d^T y$ 为实时调控成本函数; u 为不确定性量。

文章利用列约束生成算法将模型分解成主问题(master problem, MP)和子问题(sub-problem, SP)两个问题进行迭代求解。将两阶段鲁棒优化目标解耦得到主问题(MP)表达式为

$$\begin{cases} \text{MP:} \min c^T x + u \\ \text{s.t.} u \geq \sum_{k=1}^K p_k \min \{d^T y^m\} \\ H_1(x) \leq 0 \\ G_1(x) = 0 \end{cases} \quad (12)$$

式中: m 为迭代次数。

子问题(SP)表达式为

$$\begin{cases} \text{SP:} \max \sum_{k=1}^K p_k (d^T y) \\ \text{s.t.} H_2(x^m, y) \leq 0 \\ G_2(x^m, y) = 0 \\ p_k \in \Omega \end{cases} \quad (13)$$

以上的主问题与子问题均在 Matlab 下调用 CPLEX 求解器直接进行求解,求解流程图如图 3 所示。

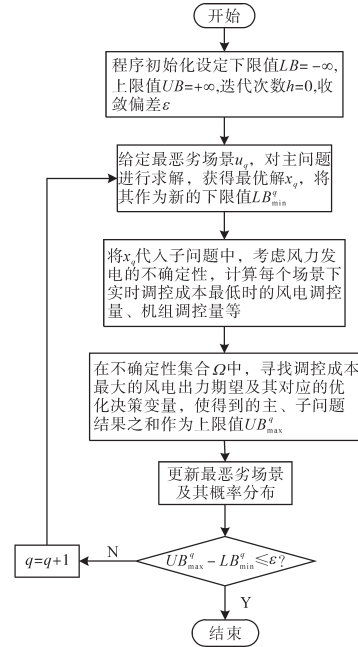


图3 利用C&CG算法的两阶段自适应鲁棒优化模型求解流程图

Fig.3 The two-stage adaptive robust optimization model of C&CG algorithm is used to solve the flow chart

4 算例分析

4.1 仿真设计及基础数据

为了验证文章提出的风电不确定性的两阶段自适应鲁棒优化调度模型的有效性,在 Matlab2017b 的环境下进行仿真。选取 4 台常规机组、6 台风机以及 2 台储能设备,并考虑可转移类需求响应负荷。各类设备运维成本为:风机 0.029 6 元/(kW·h),燃气轮机 0.063 7 元/(kW·h),蓄电池组 0.032 7 元/(kW·h)。风机参数如表 1 所示。储能设备参数为:容量 100 kW·h,充放电效率 95%, $SOC_{min}=0.2, SOC_{max}=0.9$ 。设切负荷的费用为 3 元/(kW·h),弃风费用为 1.2 元/(kW·h)。与主网日前交易的分时电价如图 4 所示。

表 1 风机参数

Tab.1 Wind turbine parameters

风机	切入风速/ ($m \cdot s^{-1}$)	额定风速/ ($m \cdot s^{-1}$)	切出风速/ ($m \cdot s^{-1}$)	额定功率/ kW
1#	3	11	20	200
2#	3	11	20	200
3#	3	11	20	150
4#	3	10	25	150
5#	3	10	25	100
6#	3	10	25	100




图4 微电网与主网日前交易的分时电价图
Fig.4 Time-of-use price of day-trading between the micro grid and the main grid

4.2 优化结果分析

经过 C&CG 算法对主、子问题的 4 次交互迭代求解后,模型最优化解达到收敛,验证了文章提出方法的有效性,其中 C&CG 算法 *UB* 和 *LB* 的收敛曲线图如图 5 所示。






图5 C&CG算法迭代过程中 *UB* 和 *LB* 收敛曲线
Fig.5 *UB* and *LB* convergence curves during C&CG algorithm iteration

各设备调控前后的出力对比图如图 6 所示,在 00:00~06:00 时段内,由于夜间的用电需求较低,常规机组基本上没有出力,微电网与电力市场的交互功率变化不大,风电机组出力满足需求侧用电,储能系统进行充电;在 07:00 以后,常规机组开始启动参与调度,通过图 6a 可以看出,经过实时调控常规机组总体出力有所下降,这是为了消纳最恶劣场景下风力发电增长部分,常规机组会下调出力。由于风电出力的不确定性影响,在 04:00 时刻储能系统减少了充电功率来补充风电波动引起的出力下降部分。在图 6b 实时调控阶段,由于储能系统在 04:00 时刻减少了充电功率,储能系统充电储存了少量电能,使其在 09:00~13:00 时段内,用电需求较大时放电受到限制;在 14:00~23:00 时段内,风电出力明显增大,微电网向主电网出售电量,常规机组减少出力,以提高微电网经济性和新能源消纳。


ARO 方法与传统鲁棒方法优化结果对比表如表 2 所示,ARO 优化方法所获得目标函数结果




(a)常规机组出力两阶段调控对比图



(b)储能系统充放电两阶段调控对比图



(c)微电网与电力市场功率两阶段调控对比图



(d)风电出力两阶段调控对比图

图6 各设备调控前后的出力对比图

Fig.6 Comparison of output of each device before and after control 偏差低于传统鲁棒优化方法的结果,其结果偏差区间在 0.1%~0.85% 之间,传统鲁棒优化要达到收敛条件需要进行更多次的迭代,计算时间更长。

表2 ARO 方法与传统鲁棒方法优化结果对比表

Tab.2 Comparison table of optimization results between ARO method and traditional robust method

优化方法对比	微电网 收益/元	目标函数 偏差比例/%	迭代 次数	计算 时间/s
ARO 方法	8 960	0.13	4	158.3
传统鲁棒优化	4 750	0.75	30	537.5

ARO 调度方法与传统调度方法成本对比表如表 3 所示,传统调度方法总成本要高于文章提出的 ARO 调度总成本。传统调度方法在制定预调度方案时,未能考虑风电不确定性等影响,其

预调度方案鲁棒性差,抵抗风电变化不确定性的能力弱,可以看出在后续调控阶段的调控成本和弃风成本会随之增加。而通过文章提出方法建立的风力发电不确定性集合排除不可能的极端场景,使得最优解在更小、更准确的可行域中求

解,更能反映可能的实际风电场景,抵抗不确定性参数能力较强,使得调控成本和弃风成本较低,从而使ARO调度方法两阶段总成本要低于传统调度方法两阶段总成本,使微电网获得了较好的经济收益。

表3 ARO调度方法与传统调度方法成本对比表

Tab.3 Cost comparison table between ARO scheduling method and traditional scheduling method

调度方法	日前预调度阶段成本/元				实时调控阶段/元				两阶段总成本/元	
	常规机组运行成本	与主电网交互成本	储能系统运行成本	总成本	常规机组调控成本	与主电网交易成本	储能系统调控成本	弃风惩罚费用		
传统调度方法	23 325	-11 783	2 792	14 334	5 703	5 794	2 876	2 036	16 409	30 743
ARO调度方法	25 982	-12 653	1 736	15 065	6 431	2 036	-720	364	8 111	23 176

5 结论

文章提出了一种基于数据驱动的微电网两阶段自适应鲁棒优化调度模型,对微电网历史样本数据利用K-means算法进行场景缩减,用典型场景代表大量复杂场景,基于数据驱动的方法建立风力发电分布的不确定性集合,降低了模型的保守性。通过C&CG算法对模型进行解耦,分成主、子问题进行迭代求解,最后通过算例验证了所提方法的有效性,使得文章所提方法相对于传统的调度方法有着更好的经济性。

参考文献

[1] 艾芊,郝然.多能互补、集成优化能源系统关键技术及挑战[J].电力系统自动化,2018,42(4):2-10.
Ai Qian, Hao Ran. Key technologies and challenges for multi-energy complementarity and optimization of integrated energy-system[J].Automation of Electric Power Systems, 2018, 42(4): 2-10.

[2] 周焯,汪可友,李国杰,等.基于多智能一致性算法的微电网分布式分层控制策略[J].电力系统自动化,2017,41(11):142-149.
Zhou Ye, Wang Keyou, Li Guojie, et al. Distributed hierarchical control for microgrid based on multi-agent consensus algorithm [J]. Automation of Electric Power System, 2017, 41(11): 142-149.

[3] 周步祥,杨明通,史述青,等.基于区块链的微电网市场势博弈模型[J].电力系统自动化,2020,44(07):15-26.
Zhou Buxiang, Yang Mingtong, Shi Shuqing, et al. Blockchain based potential game model of microgrid market[J].Automation of Electric Power Systems, 2020, 44(7): 15-26.

[4] 吴勇,吕林,许立雄,等.考虑分时电价时段划分的微电网优化配置[J].电测与仪表,2020,57(11):55-62.
Wu Yong, Lv Lin, Xu Lixiong, et al. Optimal planning of microgrid considering time division of TOU[J].Electrical Measurement & Instrumentation, 2020, 57(11): 55-62.

[5] 周成,芮涛,王群京.基于模型预测控制的微电网多目标协调优化[J].电测与仪表,2019,56(22):44-50.
Zhou Cheng, Rui Tao, Wang Qunjing. Multi-objective coordination optimization of microgrid based on model predictive control [J].Electrical Measurement & Instrumentation, 2019, 56(22): 44-50.

[6] 林佳,刘涌,陈冰斌,等.基于随机机会约束规划的冷热电联供微电网能量优化调度[J].电测与仪表,2019,56(19):85-90.
Lin Jia, Liu Yong, Chen Bingbin, et al. Stochastic operation of a combined heat and power microgrid[J].Electrical Measurement & Instrumentation, 2019, 56(19): 85-90.

[7] 丁华杰,宋永华,胡泽春,等.基于风电场功率特性的日前风电预测误差概率分布研究[J].中国电机工程学报,2013,33(34):136-144.
Ding Huajie, Song Yonghua, Hu Zechun, et al. Probability density function of day-ahead wind power forecast error based on power curve of wind farm[J]. Proceedings of the CSEE, 2013, 33(34): 136-144(in Chinese).

[8] 赵书强,王扬,徐岩.基于风电预测误差随机性的火储联合相关机会规划调度[J].中国电机工程学报,2014,34(S1):9-16.
Zhao Shuqiang, Wang Yang, Xu Yan. Dependent chance programming dispatching of integrated thermal power generation and energy storage system based on wind power forecasting error[J]. Proceedings of the CSEE, 2014, 34(S1): 9-16.

[9] 刘燕华,刘冲,李伟花,等.基于出力模式匹配的风电集群点多时间尺度基于出力模式匹配的风电集群点多时间尺度功率预测[J].中国电机工程学报,2014,34(25):4350-4358.
Liu Yanhua, Liu Chong, Li Weihua, et al. Multi-time scale power prediction of wind farm cluster based on profile pattern matching[J].Proceedings of the CSEE, 2014, 34(25): 4350-4358.

[10] 潘雄,周明,孔晓民,等.风速相关性对最优潮流的影响[J].电力系统自动化,2013,37(6):37-41.
Pan Xiong, Zhou Ming, KONG Xiaomin, et al. Impact of wind speed correlation on optimal power flow[J]. Automation of Electric Power Systems, 2013, 37(6): 37-41.

- [11] Zhang Z, Chen Y, Liu X, *et al.* Two-stage robust security-constrained unit commitment model considering time autocorrelation of wind/load prediction error and outage contingency probability of units[J]. *IEEE Access*, 2019, 7: 25398–25408.
- [12] 鲁卓欣,徐潇源,严正,等.不确定性环境下数据驱动的电力系统优化调度方法综述[J]. *电力系统自动化*, 2020, 44(21): 172–183.
Lu Zhuoxin, Xu Xiaoyuan, Yan Zheng, *et al.* Overview on data-driven optimal scheduling methods of power system in uncertain environment[J]. *Automation of Electric Power Systems*, 2020, 44(21): 172–183.
- [13] Bertsimas D, Litvinov E, Sun A, *et al.* Adaptive robust optimization for the security constrained unit commitment problem[J]. *IEEE Transactions on Power Systems*, 2012, 28(1): 52–63.
- [14] Verástegui F, Lorca Á, Olivares D E, *et al.* An adaptive robust optimization model for power systems planning with operational uncertainty[J]. *IEEE Transactions on Power Systems*, 2019, 34(6): 4606–4616.
- [15] 林俐,潘险险,张凌云,等.基于免疫离群数据和敏感初始中心的K-means算法的风电场机群划分[J]. *中国电机工程学报*, 2016, 36(20): 5461–5468, 5722.
Lin Li, Pan Xianxian, Zhang Lingyun, *et al.* The K-means clustering algorithm for wind farm based on immune outlier data and immune-sensitive initial center[J]. *Proceedings of the CSEE*, 2016, 36(20): 5461–5468, 5722.
- [16] 任建文,张青青.基于能源区块链的虚拟电厂两阶段鲁棒优化调度[J]. *电力自动化设备*, 2020, 40(08): 23–33.
Ren Jianwen, Zang Qingqing. Two-stage robust optimal scheduling of virtual power plant based on energy blockchain[J]. *Electric Power Automation Equipment*, 2020, 40(8): 23–33.
- [17] Zhao C Y, Guan Y P. Data-driven stochastic unit commitment for integrating wind generation[J]. *IEEE Transactions on Power Systems*, 2016, 31(4): 2587–2596.

收稿日期:2020–11–16

修改稿日期:2020–11–24

(上接第59页)

- 电动汽车恒流恒压无线充电系统特性分析[J]. *电工电能新技术*, 2018, 37(11): 58–68.
Hou Chun, Zhu Wang, Shui Hengqi, *et al.* Characteristic analysis of constant current and voltage wireless charging system for multi-electric vehicles based on LCL-LC/LCL hybrid compensation[J]. *Advanced Technology of Electrical Engineering and Energy*, 2018, 37(11): 58–68.
- [9] Tan L, Guo J, Huang X, *et al.* Coordinated source control for output power stabilization and efficiency optimization in WPT systems[J]. *IEEE Transactions on Power Electronics*, 2018, 33(4): 3613–3621.
- [10] 李洪兴.从模糊控制的数学本质看模糊逻辑的成功——关于“关于模糊逻辑似是而非的争论”的似是而非的介入[J]. *模糊系统与数学*, 1995, 9(4): 1–14.
Li Hongxing. To see the success of fuzzy logic from mathematical essence of fuzzy control——on the paradoxical success of fuzzy logic[J]. *Fuzzy Systems And Mathematics*, 1995, 9(4): 1–14.
- [11] 张叶茂,苏茜.基于变论域自适应模糊PID的压铸机压射速度控制研究[J]. *热加工工艺*, 2020, 49(1): 68–72, 75.
Zhang Yemao, Su Qian. Research on die casting machine injection velocity control based on variable universe adaptive fuzzy PID[J]. *Hot Working Technology*, 2020, 49(1): 68–72, 75.
- [12] 崔家瑞,李擎,张波,等.永磁同步电机变论域自适应模糊PID控制[J]. *中国电机工程学报*, 2013, 33(S1): 190–194.
Cui Jiarui, Li Qing, Zhang Bo, *et al.* Permanent magnet synchronous motor of variable universe adaptive fuzzy PID control[J]. *Proceedings of the CSEE*, 2013, 33(S1): 190–194.
- [13] 张闻宇,丁幼春,廖庆喜,等.拖拉机液压转向变论域模糊控制器设计与试验[J]. *农业机械学报*, 2015, 46(3): 43–50.
Zhang Wenyu, Ding Youchun, Liao Qingxi, *et al.* Variable universe fuzzy controller for tractor hydraulic steering[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2015, 46(3): 43–50.
- [14] 程志远,朱春波,魏国,等.串-并补偿结构大功率感应充电系统谐振变换器[J]. *电工技术学报*, 2014, 29(9): 44–48.
Cheng Zhiyuan, Zhu Chunbo, Wei Guo, *et al.* Resonant converter for high power ICPT system with series-parallel compensation[J]. *Transactions of China Electrotechnical Society*, 2014, 29(9): 44–48.
- [15] 杨丽.变论域自适应模糊控制在机械手轨迹跟踪中的应用研究[D].成都:西南石油大学,2016.
Yang Li. Research on the application of adaptive fuzzy control based on variable universe in manipulator trajectory tracking [D]. Chengdu: Southwest Petroleum University, 2016.

收稿日期:2020–06–03

修改稿日期:2020–06–10