

基于 CVaR-IGDT 的含电动汽车微电网 多时间尺度优化调度

于永进,贾国志,张玉敏

(山东科技大学 电气与自动化工程学院,山东 青岛 266590)

摘要:电动汽车接入微电网在调度运行中存在多种不确定因素,给系统安全稳定造成一定影响。本研究将条件风险价值理论(CVaR)与信息间隙决策理论(IGDT)相结合,建立了含电动汽车微电网多时间尺度调度模型。在日前阶段,以微电网日运行成本最小为优化目标,首先采用蒙特卡洛模拟和吸引子传播聚类算法对电价和电动汽车行为的不确定性进行建模,并利用 CVaR 量化不确定风险;针对风光出力预测精度较低的问题,采用 IGDT 应对风光出力的不确定性,在保证优化目标满足期望的前提下最大化风光出力的波动范围。在日内阶段,以日前下发的调度计划为参考,基于模型预测控制对含电动汽车微电网进行日内滚动优化,并引入误差系数进行反馈校正,修正日前调度偏差。最后,通过算例验证了本研究模型的有效性,分析了收益偏差系数和风险偏好系数对优化结果的影响。

关键词:微电网;电动汽车;信息间隙决策理论;条件风险价值理论;模型预测控制

中图分类号:TM734

文献标志码:A

Multi-time scale optimal dispatching of microgrid with electric vehicles based on CVaR-IGDT

YU Yongjin, JIA Guozhi, ZHANG Yumin

(College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: There are many uncertain factors in the dispatch and operation of electric vehicles connected to microgrid, which have a certain impact on the safety and stability of the system. In this study, the conditional value-at-risk (CVaR) theory and the information gap decision theory (IGDT) were combined to establish a multi-time scale dispatching model for microgrid with electric vehicles. In the day-ahead stage, with the minimum daily operation cost of the microgrid as the optimization objective, Monte Carlo simulation and attractor propagation clustering algorithm were used to model the uncertainty of electricity price and electric vehicle behavior and CVaR was used to quantify the uncertainty risk. Then, to solve the problem of low prediction accuracy of wind and photovoltaic output, IGDT was used to deal with the uncertainty of wind and photovoltaic output, maximizing the fluctuation range of wind and photovoltaic output while ensuring that the optimization target value was within an acceptable range. In the intra-day stage, with the day-ahead dispatching planning as a reference, the model predictive control was used to optimize the microgrid including electric vehicles in the intra-day rolling, and the error coefficient was introduced for feedback correction to correct the day-ahead dispatching deviation. Finally, the effectiveness of the proposed model was verified by an example, and the effects of the income deviation coefficient and the risk preference coefficient on the optimization results were analyzed.

Key words: microgrid; electric vehicle; information gap decision theory; conditional value-at-risk; model predictive control

收稿日期:2022-11-18

基金项目:国家自然科学基金项目(52107111)

作者简介:于永进(1980—),男,山东烟台人,副教授,博士,主要从事电力系统运行与控制研究。

贾国志(1998—),男,山东泰安人,硕士研究生,主要从事电动汽车充放电调度研究,本文通信作者。

E-mail:bhc0508_jgz@163.com.

电动汽车(electric vehicle, EV)作为一种清洁能源汽车在节能减排方面与传统汽车相比有明显的优势。研究表明,大规模 EV 无序接入电网,会引起电网峰值负荷增长,进而影响电网安全可靠运行^[1]。此外,光伏和风力发电出力具有间歇性和波动性^[2],增加了微电网安全可靠运行的风险。通过汽车到电网(vehicle-to-grid, V2G)技术对 EV 动力电池统一管理,与可再生能源相互协作,共同参与微电网的优化调度,是实现 EV 有序充放电、可再生能源就地消纳的重要途径^[3]。

目前,国内外学者已对 EV 与微电网协同优化策略进行了研究。文献[4]利用 EV 的储能特性,提出了不同的调度策略优化微电网各分布式电源出力,但未考虑到不确定性因素给系统带来的风险。在此基础上部分学者对不确定性因素的处理方法进行了研究:文献[5]针对风电出力不确定性提出风险管理模型,量化预测精度不足导致的风险成本;文献[6]将基于深度卷积生成对抗网络的场景生成和最优规划模型相结合,并利用改进的 k -medoids 算法对生成的场景进行聚类;文献[7]利用概率分布分析方法对风电、光伏和 EV 的不确定性进行建模,利用风险管理策略处理系统中所有不确定性因素。上述研究针对不同特性的不确定因素采用相同的处理方式存在局限性,且大多数未考虑 EV 的不确定性。条件风险价值理论(conditional value-at-risk, CVaR)是一种常用的风险度量指标,已应用于微电网调度优化。文献[8]利用 CVaR 解决 EV 负荷预测随机性带来的风险,文献[9]利用基于 CVaR 的优化框架降低了电价预测误差带来的风险。风光出力概率很难准确预测,若使用传统的基于场景规划的方法需要大量的场景样本来保证预测结果的可靠性,会使问题复杂化。信息间隙决策理论(information gap decision theory, IGDT)作为一种处理随机变量不确定性的方法,与其他优化方法相比,不需要明确随机变量的概率分布。文献[10]利用 IGDT 理论同时处理风电、光伏出力的不确定性,文献[11]利用 IGDT 理论模拟负荷增长的长期不确定性,建立含 EV 微电网的多目标规划模型。但上述研究均局限于日前调度,随机变量预测精度不足,导致日前调度策略与实际运行情况存在一定偏差。文献[12]提出多时间尺度调度模型,但日内阶段采用开环控制;文献[13]提出基于模型预测控制(model predictive control, MPC)的多时间尺度优化策略。

本研究提出基于 CVaR-IGDT 微电网日前优化策略。首先,利用蒙特卡洛模拟和近邻传播(affinity propagation, AP)聚类算法对电价和 EV 行为的不确定性进行建模,并利用 CVaR 量化不确定风险。其次,采用 IGDT 应对风光出力的不确定性,在保证优化目标满足期望的前提下最大化风光出力的波动范围。为了解决日前阶段优化后的调度计划与日内实际情况存在偏差的问题,在日内阶段采用基于 MPC 的控制策略,对日前优化得到的各机组单元出力以及 EV 充放电计划在短时间尺度内进行滚动优化,并引入误差系数进行反馈校正,弥补日前调度开环控制的缺点。最后,通过算例分析验证了所提策略的有效性,并分析了收益偏差系数和风险偏好系数对优化结果的影响。

1 微电网优化模型框架

1.1 微电网系统结构

如图 1 所示,含电动汽车微电网包括风电机组(wind turbine, WT)、光伏发电机组(photovoltaic, PV)、微型燃气轮机(micro turbine, MT)等分布式电源,储能系统(energy storage, ES),基础负荷(Load)以及入网可调度 EV^[14]。

1.2 多时间尺度调度策略描述

多时间尺度调度策略可分为日前和日内两个阶段。

1) 日前阶段。利用 CVaR-IGDT 处理不确定性因素。以 24 h 为控制时域,优化时间步长为 1 h,制定 MT、ES 以及 EV 出力计划,使微电网的日运行成本最小,把得到的日前调度计划作为日内调度的参考值。

2) 日内阶段。基于 MPC 方法,以 15 min 为时间尺度,以日前优化对应时段所得调度计划为基准值,在日内调度中第 t 时段开始时,更新下一控制时域内随机变量的预测信息。根据风光出力超短时期负荷预测

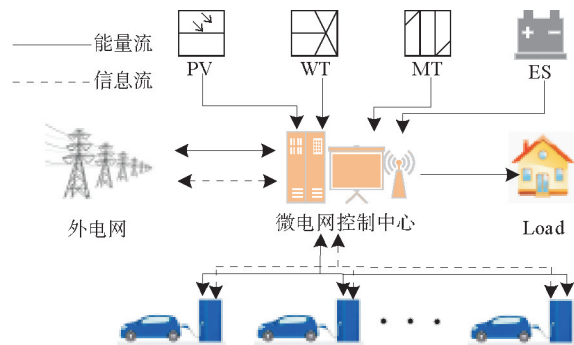


图 1 含电动汽车微电网示意图

Fig. 1 Schematic diagram of microgrid including EV

误差,以日前和日内计划量偏差最小为目标函数,确定时域 t 内各单元出力,但只执行前 15 min 时段的计划。在第 $t + \Delta t$ 时段开始,使用更新后的信息重复优化步骤,实现滚动优化。

2 微电网多时间尺度调度模型

2.1 确定性负荷下日前调度模型

2.1.1 目标函数

考虑含电动汽车微电网的经济性,以微电网日运行成本最小为优化目标:

$$\min F = C_{\text{grid}} + C_G + C_{\text{ES}} + C_E + C_{\text{EV}} \quad (1)$$

目标函数中成本由大电网交互成本 C_{grid} 、微电源发电成本 C_G 、储能系统成本 C_{ES} 、环境成本 C_E 和 EV 综合成本 C_{EV} 几部分组成。

1) 大电网交互成本

$$C_{\text{grid}} = \sum_{t=1}^T (\pi_{\text{buy}}^t P_{\text{grid}}^t L_{\text{grid},t}^c \Delta t + \pi_{\text{sell}}^t P_{\text{grid}}^t L_{\text{grid},t}^d \Delta t) \quad (2)$$

式中: P_{grid}^t 为 t 时刻微电网与外电网的交互功率,其值为正表示向外电网购电,反之为售电; π_{buy}^t 和 π_{sell}^t 分别为微电网与外电网能量交换的购、售电价; $L_{\text{grid},t}^c$ 和 $L_{\text{grid},t}^d$ 分别为 t 时刻的购、售电状态,满足 $L_{\text{grid},t}^c + L_{\text{grid},t}^d \leq 1$ 。

2) 微电源发电成本

$$C_G = \sum_{t=1}^T \left(c_{\text{gas}} \times \frac{P_{\text{MT},t}}{L_{\text{HV_gas}}} \right) + \sum_{t=1}^T \sum_{i=1}^n Y_i \kappa_{G_i} |P_{G_i,t}| + \sum_{t=1}^T \sum_{i=1}^n Y_i \left[\frac{C_{\text{cap_G}_i}}{T_i^y} \times \frac{r(1+r)^{N_i}}{(1+r)^{N_i} - 1} \right] \quad (3)$$

式中: $P_{\text{MT},t}$ 为 t 时刻 MT 发出的电能; c_{gas} 为天然气燃料价格,取 2.03 元/m³; $L_{\text{HV_gas}}$ 为天然气燃料的热值,通常取 9.7 kWh/m³; Y_i 为第 i 类微电源的个数; r 为年利息率; κ_{G_i} 为微电源 i 的运行维护系数, $i=1,2,3$ 分别代表 MT、WT、PV; $P_{G_i,t}$ 为微电源 t 时段的出力; $C_{\text{cap_G}_i}$ 为第 i 类单个微电源的投资成本; n 为微电源的类型数量; N_i 为第 i 类微电源的使用年限; T_i^y 为第 i 类微电源年运行时间。

3) 储能系统成本

$$C_{\text{ES}} = \sum_{t=1}^T \left(\pi_{\text{buy}}^t P_{\text{ES},t} L_{\text{ES},t}^c \eta_{\text{ES}}^c \Delta t + \frac{\pi_{\text{sell}}^t P_{\text{ES},t} L_{\text{ES},t}^d \Delta t}{\eta_{\text{ES}}^d} \right) + \sum_t \kappa_{\text{ES}} |P_{\text{ES},t}| + \left[\frac{C_{\text{cap_ES}}}{T_{\text{ES}}^y} \times \frac{r(1+u)^{N_{\text{ES}}}}{(1+u)^{N_{\text{ES}}} - 1} \right] \times \frac{|P_{\text{ES},t}|}{P_{\text{ESe}}} \quad (4)$$

式中: $P_{\text{ES},t}$ 为 t 时段 ES 的交互功率,售电为正,购电为负; $L_{\text{ES},t}^c$ 和 $L_{\text{ES},t}^d$ 分别为 t 时刻的充、放电状态; η_{ES}^c 与 η_{ES}^d 分别为 ES 充、放电效率; κ_{ES} 为 ES 运行维护系数; u 为折旧成本系数; N_{ES} 为蓄电池的使用年限; T_{ES}^y 为 ES 的年运行时间; P_{ESe} 为 ES 的额定输出功率。

4) 环境成本

$$C_E = \sum_{t=1}^T \sum_{u=1}^U C_u \left(\sum_{i=1}^n \psi_{i,u} |P_{G_i,t}| + \psi_{g,u} |P_{\text{grid}}^t| \right) \quad (5)$$

式中: C_u 为第 u 种污染物的单位处理费用, $\psi_{i,u}$ 和 $\psi_{g,u}$ 分别为第 i 个微电源、主网联络线运行时第 u 种污染物的单位排放量。

5) EV 综合成本

$$C_{\text{EV}} = \sum_{t=1}^T \sum_{m=1}^M \left(\pi_{\text{buy}}^t P_{m,t}^{\text{EV}} L_{m,t}^c \eta_{\text{EV}}^c \Delta t + \frac{\pi_{\text{sell}}^t P_{m,t}^{\text{EV}} L_{m,t}^d \Delta t}{\eta_{\text{EV}}^d} \right) + \sum_{m=1}^M \frac{C_b}{l_c E_{\text{EV}}^{\text{max}} D_{\text{OD}}} \left(\frac{P_{m,t}^{\text{EV}} L_{m,t}^d \Delta t}{\eta_{\text{EV}}^d} + \bar{\omega}_m D_{m,t} \right) \quad (6)$$

式中: $\bar{\omega}_m$ 为 EV 每千米消耗电量; $L_{m,t}^c$ 和 $L_{m,t}^d$ 分别为时刻 t 第 m 辆 EV 的充、放电状态; $D_{m,t}$ 为 t 时刻第 m 辆 EV 行驶里程; η_{EV}^c 与 η_{EV}^d 分别为 EV 充、放电效率; $P_{m,t}^{\text{EV}}$ 为 t 时刻第 m 辆 EV 的功率; C_b 为 EV 电池成本; $E_{\text{EV}}^{\text{max}}$ 为 EV 动力电池容量的最大值; l_c 和 D_{OD} 分别为 EV 充放电循环次数和放电的深度。

2.1.2 约束条件

1) 燃气轮机约束

$$u_{\text{MT},t} P_{\text{MT}}^{\text{min}} \leq P_{\text{MT},t} \leq u_{\text{MT},t} P_{\text{MT}}^{\text{max}}, -R_{\text{MT}}^{\text{D}} \Delta t \leq P_{\text{MT},t} - P_{\text{MT},(t-1)} \leq R_{\text{MT}}^{\text{U}} \Delta t \quad (7)$$

式中: P_{MT}^{\min} 和 P_{MT}^{\max} 分别为 MT 的最小和最大出力; R_{MT}^U 和 R_{MT}^D 分别为 MT 在单位时间内的最大爬坡和滑坡功率。

2) 可再生能源约束

$$P_{Gi,t}^{\min} \leq P_{Gi,t} \leq P_{Gi,t}^{\max}, i=1,2,3. \quad (8)$$

式中: $P_{Gi,t}^{\max}$ 和 $P_{Gi,t}^{\min}$ 分别为微电源 i 的出力上限和下限值。

3) 储能系统约束

$$\begin{cases} S_{OC_ES}^{\min} \leq S_{OC_ES,t} \leq S_{OC_ES}^{\max}, P_{ES_max}^d \leq P_{ES,t} \leq P_{ES_max}^c, 0 \leq L_{ES,t}^c + L_{ES,t}^d \leq 1, L_{ES,t}^c, L_{ES,t}^d \in (0,1); \\ S_{OC_ES,t} = S_{OC_ES,t-1} (1 - u_{ES}) + \frac{P_{ES,t} \eta_{ES,t}^c L_{ES,t}^c \Delta t - P_{ES,t} L_{ES,t}^d \Delta t / \eta_{ES}^d}{E_{ES}^{\max}}. \end{cases} \quad (9)$$

式中: $P_{ES_max}^c$ 、 $P_{ES_max}^d$ 分别为 ES 充、放电功率的最大值; u_{ES} 为 ES 的损耗率; Δt 为日前调度时间步长; E_{ES}^{\max} 为 ES 电池容量; $S_{OC_ES}^{\max}$ 、 $S_{OC_ES}^{\min}$ 分别为 ES 荷电状态的上限、下限; D_{ES} 为 ES 最大放电深度。

4) EV 约束

$$\begin{cases} S_{OCm,\min} \leq S_{OCm,t} \leq S_{OCm,\max}, p_{EV_max}^d \leq p_{m,t}^{EV} \leq P_{EV_max}^c, 0 \leq L_{m,t}^c + L_{m,t}^d \leq 1, L_{m,t}^c, L_{m,t}^d \in (0,1); \\ S_{OCm,t} = S_{OCm,t-1} + \frac{L_{m,t}^c P_{m,t}^{EV} \eta_{EV}^c - L_{m,t}^d P_{m,t}^{EV} / \eta_{EV}^d}{E_{EV}^{\max}}. \end{cases} \quad (10)$$

式中: $P_{EV_max}^c$ 、 $P_{EV_max}^d$ 分别为 EV 充、放电功率的最大值; $S_{OCm,t}$ 为 t 时刻第 m 辆 EV 的荷电状态; $S_{OCm,\min}$ 和 $S_{OCm,\max}$ 分别为第 m 辆 EV 荷电状态的下限和上限值; η_{EV}^c 和 η_{EV}^d 分别为 EV 的充、放电效率。

5) 功率平衡约束

$$P'_{grid} + \sum_{i=1}^J P_{Gi,t} + P_{ES,t} = \sum_{m=1}^M P_{m,t}^{EV} + P_{load,t}. \quad (11)$$

式中, $P_{load,t}$ 为 t 时刻微电网的基础负荷。

2.2 基于 CVaR-IGDT 的不确定模型

微电网调度运行受到不确定因素的影响,包括电价波动、风光出力以及 EV 行驶特性等不确定性。首先利用 CVaR 量化优化过程中电价波动和 EV 随机行为带来的风险成本^[15]。CVaR 作为风险价值(Value-at-risk, VaR)的一种补充,其含义为超过 VaR 部分的条件期望。

根据文献[4]和文献[16]假设,电价预测误差以及 EV 的入网时间 T_{in} 、离网时间 T_{out} 和初始荷电状态 S_{OC0} 服从正态分布。依据各变量的概率分布,首先采用蒙特卡洛模拟法生成大量的电价以及每辆 EV 的 T_{in} 、 T_{out} 和 S_{OC0} 的场景,然后进行场景缩减。与 k -means、FCM 等聚类算法相比,AP 聚类算法不需要初始聚类中心,可靠性高^[17],所以采用 AP 聚类算法将上述场景缩减为一定数量有代表性的场景,再利用 CVaR 量化风险成本:

$$C = \bar{C} + \beta C^{CVaR}, \quad (12)$$

$$\bar{C} = \sum_{t=1}^T \sum_{w=1}^{n_w} \rho_w C_p^w, \quad (13)$$

$$C_p^w = C_{grid,t}^w + C_{ES,t}^w + C_{G,t}^w + C_{E,t}^w + C_{EV,t}^w, \quad (14)$$

$$C^{CVaR} = \delta + \frac{1}{1-\theta} \sum_{w=1}^{n_w} \rho_w [C_p^w - \delta]^+. \quad (15)$$

式中: β 为风险偏好系数; n_w 为缩减后的不确定性场景数; ρ_w 为第 w 组不确定场景的概率; $C_{grid,t}^w$ 、 $C_{ES,t}^w$ 、 $C_{G,t}^w$ 、 $C_{E,t}^w$ 和 $C_{EV,t}^w$ 中的上标 w 表示变量在第 w 组场景下的值; $[C_p^w - \delta]^+$ 表示 $\max [C_p^w - \delta, 0]$; δ 表示置信度水平 θ 下的 VaR 值。设辅助变量 $z_w = [C_p^w - \delta]^+$, 对于每个场景应满足:

$$z_w \geq 0, \quad (16)$$

$$z_w \geq [C_{grid,t}^w + C_{ES,t}^w + C_{gen,t}^w + C_{E,t}^w + C_{EV,t}^w] - \delta. \quad (17)$$

风光出力的概率分布难以准确预测,若采用传统的基于概率分布的随机规划方法会使优化结果存在较

大误差。与基于概率的随机规划方法不同,IGDT 量化不确定性时无需不确定变量的概率分布,优化策略分为风险规避策略和风险偏好策略,本研究采取风险规避策略来规避不确定变量带来的风险,IGDT 基本原理见文献[18]。

当系统中不确定变量取确定值时,求解目标函数式(1)的最小经济成本,记为 Γ_0 。当不确定性量 $\gamma = (1+\alpha)\tilde{\gamma}$ ($\tilde{\gamma}$ 为不确定量的预测值, α 为不确定量的综合系数)时,原目标函数取得最小值,记为 Γ 。为了同时应对风光出力的不确定性,本研究采用权重因子法赋予两种随机变量不同的权重,使 IGDT 可以处理多个不确定变量。考虑多重不确定性的微电网 CVaR-IGDT 日前优化调度模型为:

$$\begin{cases} \max \alpha, \\ \min \Gamma \leq (1+\sigma)\Gamma_0; \\ \Gamma = \sum_{t=1}^T \sum_{w=1}^{n_w} \rho_w (C_{\text{grid},t}^w + C_{\text{ES},t}^w + C_{\text{gen},t}^w + C_{\text{E},t}^w + \sum_{m=1}^M C_{\text{EV},m,t}^w) + \beta \left(\delta + \frac{1}{1-\alpha} \sum_{w=1}^{n_w} \rho_w z_w \right); \\ P_{w,t} = \tilde{P}_{w,t} + \alpha_t^w \tilde{P}_{w,t}, P_{s,t} = \tilde{P}_{s,t} + \alpha_t^s \tilde{P}_{s,t}; \\ \alpha_t^w = \epsilon_t^w \alpha, \alpha_t^s = \epsilon_t^s \alpha, \epsilon_t^w + \epsilon_t^s = 1; \\ \text{式(1) ~ (17)}. \end{cases} \quad (18)$$

式中: σ 为规避系数; $\tilde{P}_{w,t}$ 和 $\tilde{P}_{s,t}$ 分别为风光出力的预测值; α_t^w 、 α_t^s 和 ϵ_t^w 、 ϵ_t^s 分别为 t 时风电、光伏出力的偏差系数及其权重。

2.3 基于 MPC 的日内滚动优化模型

日前阶段下发的调度计划会因随机变量预测精度不足,导致与实际运行情况存在一定偏差。加入日内滚动优化环节,基于日前调度计划和 MPC 方法,以 15 min 为时间尺度,在日内调度中第 t 时段开始时,更新 $t+N\Delta t$ 内各随机变量的信息,日内阶段的目标函数为最小化日前调度计划偏差。MPC 的核心由预测模型、滚动优化与反馈校正组成^[18]。

2.3.1 预测模型

预测模型可预测未来被控对象的状态,即通过模型 t 时刻的状态,预测 $t+1$ 时刻的系统输出:

$$\begin{cases} \mathbf{x}(t+1) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) + \mathbf{C}\mathbf{w}(t), \mathbf{Y}(t) = \mathbf{D}\mathbf{x}(t); \\ \mathbf{x}(t) = [\mathbf{P}_{\text{MT}}(t)\mathbf{P}_{\text{ES}}(t)\mathbf{P}_{\text{EV}}(t)\mathbf{S}_{\text{OC}_{\text{EV}}}(t)\mathbf{S}_{\text{OC}_{\text{ES}}}(t)\mathbf{P}_{\text{PV}}(t)\mathbf{P}_{\text{WT}}(t)\mathbf{P}_{\text{grid}}(t)]^T; \\ \mathbf{u}(t) = [\Delta\mathbf{P}_{\text{MT}}(t)\Delta\mathbf{P}_{\text{ES}}(t)\Delta\mathbf{P}_{\text{EV}}(t)]^T; \\ \mathbf{w}(t) = [\Delta\mathbf{P}_{\text{PV}}(t)\Delta\mathbf{P}_{\text{WT}}(t)]^T. \end{cases} \quad (19)$$

式中: $\mathbf{x}(t)$ 为状态变量, $\mathbf{P}_{\text{MT}}(t)$ 、 $\mathbf{P}_{\text{ES}}(t)$ 、 $\mathbf{P}_{\text{EV}}(t)$ 、 $\mathbf{P}_{\text{PV}}(t)$ 、 $\mathbf{P}_{\text{WT}}(t)$ 和 $\mathbf{P}_{\text{grid}}(t)$ 分别为 t 时刻 MT、ES、EV、PV、WT 的输出功率向量和主网联络线上的功率向量, $\mathbf{S}_{\text{OC}_{\text{ES}}}(t)$ 、 $\mathbf{S}_{\text{OC}_{\text{EV}}}(t)$ 分别为 t 时刻 ES 和 EV 的荷电状态; $\mathbf{u}(t)$ 为控制变量, $\Delta\mathbf{P}_{\text{MT}}(t)$ 、 $\Delta\mathbf{P}_{\text{ES}}(t)$ 、 $\Delta\mathbf{P}_{\text{EV}}(t)$ 分别为 MT、ES、EV 的功率增量向量; $\mathbf{w}(t)$ 为扰动变量, $\Delta\mathbf{P}_{\text{PV}}(t)$ 、 $\Delta\mathbf{P}_{\text{WT}}(t)$ 分别为 PV、WT 的超短时期负荷预测功率增量向量; $\mathbf{Y}(t)$ 为输出变量; \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 、 \mathbf{D} 为定常矩阵。

2.3.2 滚动优化

以日前阶段优化调度所有各单元出力计划为参考值,进行微电网日内滚动优化调整。以最小化日内预测实时输出值与日前计划值之间的偏差为目标,将日内滚动优化问题转化为二次规划问题:

$$\begin{aligned} \min \mathbf{J}(t) &= \|\mathbf{Y}_p(t+n\Delta t|t) - \mathbf{Y}_{\text{ref}}(t+n\Delta t|t)\|_Q^2 + \|\mathbf{u}(t)\|_R^2 \\ &= [\mathbf{Y}_p(t+n\Delta t|t) - \mathbf{Y}_{\text{ref}}(t+n\Delta t|t)]^T \mathbf{Q} [\mathbf{Y}_p(t+n\Delta t|t) - \mathbf{Y}_{\text{ref}}(t+n\Delta t|t)] + \mathbf{u}^T(t) \mathbf{R} \mathbf{u}(t); \\ &\begin{cases} \mathbf{P}_{\text{MT}}^{\min} \leq \mathbf{P}_{\text{MT}}(t) \leq \mathbf{P}_{\text{MT}}^{\max}, \mathbf{P}_{\text{ES}}^{\min}(t) \leq \mathbf{P}_{\text{ES}}(t) \leq \mathbf{P}_{\text{ES}}^{\max}(t), \mathbf{P}_{\text{EV}}^{\min}(t) \leq \mathbf{P}_{\text{EV}}(t) \leq \mathbf{P}_{\text{EV}}^{\max}(t); \\ \mathbf{S}_{\text{OC}_{\text{ES}}}^{\min}(t) \leq \mathbf{S}_{\text{OC}_{\text{ES}}}(t) \leq \mathbf{S}_{\text{OC}_{\text{ES}}}^{\max}(t), \mathbf{S}_{\text{OC}_{\text{EV}}}^{\min}(t) \leq \mathbf{S}_{\text{OC}_{\text{EV}}}(t) \leq \mathbf{S}_{\text{OC}_{\text{EV}}}^{\max}(t); \\ \Delta\mathbf{P}_{\text{MT}}^{\min}(t) \leq \Delta\mathbf{P}_{\text{MT}}(t) \leq \Delta\mathbf{P}_{\text{MT}}^{\max}(t), \Delta\mathbf{P}_{\text{ES}}^{\min}(t) \leq \Delta\mathbf{P}_{\text{ES}}(t) \leq \Delta\mathbf{P}_{\text{ES}}^{\max}(t), \Delta\mathbf{P}_{\text{EV}}^{\min}(t) \leq \Delta\mathbf{P}_{\text{EV}}(t) \leq \Delta\mathbf{P}_{\text{EV}}^{\max}(t). \end{cases} \end{aligned} \quad (20)$$

式中: $\mathbf{Y}_p(t+n\Delta t|t)$ 和 $\mathbf{Y}_{ref}(t+n\Delta t|t)$ 分别为 t 时刻对 $t+n\Delta t$ 时刻各变量出力的日内实时预测输出值和日前计划值; $\mathbf{P}_{MT}^{min}(t)$ 、 $\mathbf{P}_{MT}^{max}(t)$ 、 $\mathbf{P}_{ES}^{min}(t)$ 、 $\mathbf{P}_{ES}^{max}(t)$ 、 $\mathbf{P}_{EV}^{min}(t)$ 、 $\mathbf{P}_{EV}^{max}(t)$ 分别为 MT、ES、EV 的输出功率最大和最小值矩阵; $\mathbf{S}_{OC_ES}^{min}(t)$ 、 $\mathbf{S}_{OC_ES}^{max}(t)$ 、 $\mathbf{S}_{OC_EV}^{min}(t)$ 、 $\mathbf{S}_{OC_EV}^{max}(t)$ 分别为 ES、EV 荷电状态的最大和最小值矩阵, $\Delta\mathbf{P}_{MT}^{min}(t)$ 、 $\Delta\mathbf{P}_{MT}^{max}(t)$ 、 $\Delta\mathbf{P}_{ES}^{min}(t)$ 、 $\Delta\mathbf{P}_{ES}^{max}(t)$ 、 $\Delta\mathbf{P}_{EV}^{min}(t)$ 、 $\Delta\mathbf{P}_{EV}^{max}(t)$ 分别为 MT、ES、EV 功率增量的最大和最小值矩阵。

2.3.3 反馈校正

在 MPC 滚动优化过程中仍会因预测精度、环境等不确定因素使调度计划存在偏差,所以需要引入反馈校正环节增强系统的抗扰动能力。引入误差系数对各个时段内的目标函数偏差进行补偿,以达到准确预测被控对象的未来输出。反馈校正算式为:

$$\begin{cases} \mathbf{e}_k(t) = \mathbf{Y}_R(t) - \mathbf{Y}_R(t|t-1), \\ \mathbf{X}(t+1) = \mathbf{X}(t+1|t) + \boldsymbol{\lambda}_k \mathbf{e}_k(t). \end{cases} \quad (21)$$

式中: $\mathbf{e}_k(t)$ 为系统控制误差; $\boldsymbol{\lambda}_k$ 为误差系数矩阵; \mathbf{Y}_R 是 t 时刻系统实际输出。

3 模型求解及算例分析

3.1 模型求解流程

本研究基于 CVaR-IGDT 的日前优化策略是混合整数线性规划问题,在日内阶段构建的基于 MPC 的滚动优化模型为二次规划模型,借助 CPLEX 求解器对多时间尺度优化模型求解,求解流程如图 2 所示。

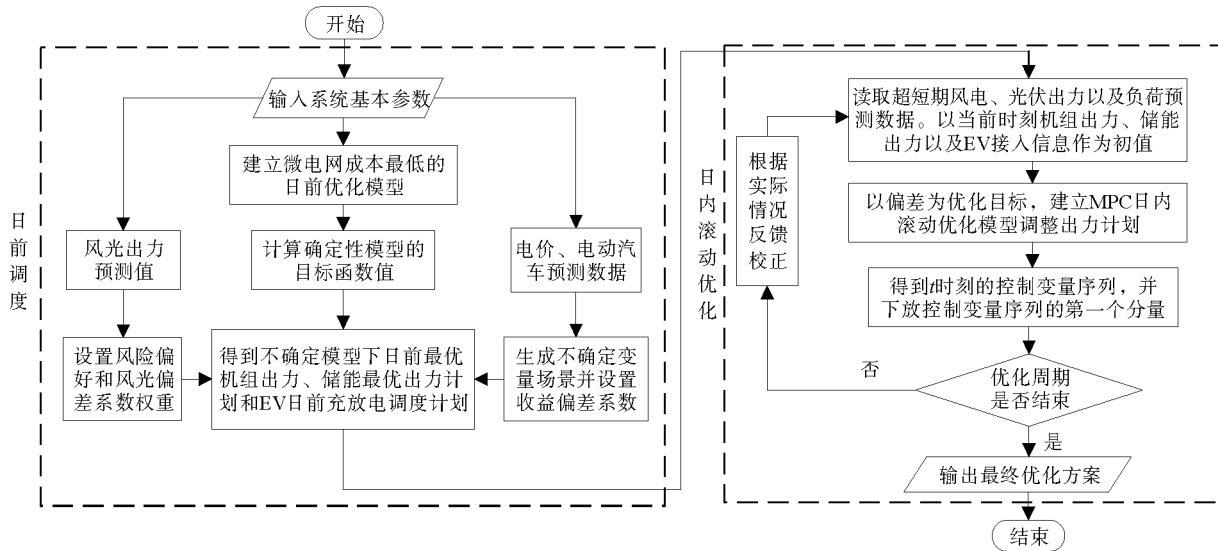


图 2 求解流程图

Fig. 2 Solution flow chart

3.2 仿真参数设置

本研究以实际微电网工程为研究对象,其中接入由 2 台风机、2 台光伏发电机、5 台 Capstone C65 型号的燃气轮机和 5 台铅蓄电池组成的储能系统,风光历史出力以及负荷数据均来自比利时的实际工程数据^[19]。在微电网中接入 100 辆 EV,假设 EV 为同一个型号,最大充电功率 P_{max}^c 和最大放电功率 P_{max}^d 均为 3 kW, EV 充放电效率均为 0.9。EV 接入电网时刻 T_{in} 满足 $\mu_{in}=17.5$ 、 $\sigma_{in}=3.5$ 的正态分布; EV 离开电网时刻 T_{out} 满足 $\mu_{out}=8.92$ 、 $\sigma_{out}=3.24$ 的正态分布, EV 其他参数见表 1。风光出力以及电价曲线如图 3 所示,其中电价根据 PJM 市场的实时电价统计得到^[20]。在日内阶段,风光出力的预测值可能存在误差,其预测曲线是在日前预测值的基础上加入干扰得到,此处误差取 10%,如图 4 所示。依据 EV 及电价参数的概

率分布,采用蒙特卡洛模拟法生成 1 000 个随机场景,然后采用文献[21]的 AP 聚类算法将场景数缩减至 20 个,表 2 列出了某一辆 EV 的随机场景,其余 EV 的行驶特性场景均参考此方法。分布式电源 G_i 和 ES 参数如表 3 所示,环境污染物排放参数参考文献[4]。




图 3 风光出力以及电价曲线

Fig. 3 Curve of wind and photovoltaic power and electricity price

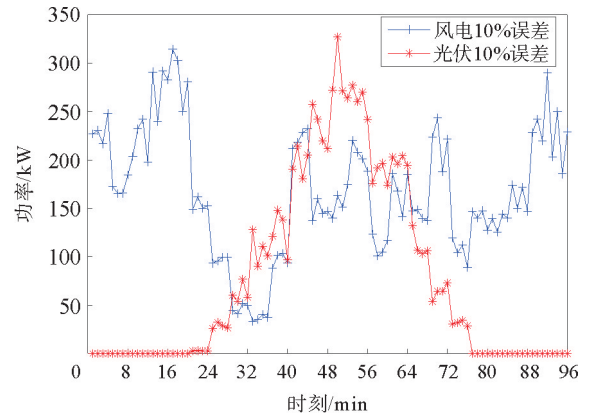


图 4 随机变量预测误差曲线

Fig. 4 Curve of random variable prediction error

3.3 仿真结果分析

3.3.1 灵活性资源对系统调度的影响

系统中的 EV 和 ES 可以通过灵活性充放电对整体负荷进行调整,通过以下 3 种算例研究不同灵活性资源组成对系统调度成本、交互功率波动程度以及可再生能源消纳率的影响,其中交互功率波动是指微电网和外电网联络线交互功率 P_{grid}^t 的波动程度,用交互功率方差表示。其中,算例一仅接入 EV,算例二仅接入 ES,算例三中 EV 和 ES 均接入。3 种算例优化得到结果如表 4 所示。

比较算例一和算例二的结果可知,仅接入 ES 比仅接入 EV 的微电网成本更低,交互功率负荷波动更小,可再生能源消纳率更高,这是由于电动汽车受本身行驶规律的限制,不能全天随时参与源侧需求响应,特别是在 10:00—16:00 时段 EV 大多数处于不可调度阶段,但此时光伏出力处于高峰负荷时段,仅依靠 MT 调节能力有限,导致弃风、弃光现象相对严重,也增加了微电网向外电网的购电量,增加了微电网成本。ES 可以全天时段参与调度,根据负荷波动程度进行灵活响应,但仅靠 ES 进行调节增加了蓄电池的压力,ES

表 1 EV 参数表

Table 1 EV parameter s

E_{EV}^{max}/kW	l_c	$\bar{\omega}_m$	D_{ODmax}	D_{ODmin}	$S_{OCm,min}$	$S_{OCm,max}$
33	5 000	0.25	0.8	0.2	0.2	1

表 2 EV 行驶特性随机场景

Table 2 Scenario of EV driving characteristics

场景	T_{out}	T_{in}	S_{OC0}	场景	T_{out}	T_{in}	S_{OC0}
1	5	20	0.58	11	7	21	0.68
2	7	17	0.57	12	9	20	0.78
3	6	22	0.22	13	10	19	0.31
4	9	19	0.50	14	8	18	0.66
5	8	20	0.20	15	12	21	0.20
6	6	22	0.12	16	6	19	0.46
7	7	17	0.22	17	7	20	0.55
8	10	22	0.41	18	9	18	0.35
9	7	18	0.59	19	10	20	0.40
10	11	18	0.23	20	8	19	0.27

表 3 分布式电源和 ES 参数表

Table 3 Distributed power supply and ES parameters

参数	数值	参数	数值
$P_{G1}^{min}, P_{G1}^{max}/kW$	0.65	η_{ES}^c, η_{ES}^d	0.95, 0.95
K_{G1} 元/(kW·h)	0.035 6	K_{ES}	0.001 2
$r/\%$	6	K_{G2}	0.029 6
$C_{cap,1}$ /万元	15	K_{G3}	0.009 6
N_i /年	15	$C_{cap,ES}$ /万元	0.6
P_{G2}^{max}/kW	50	$E_{ES}^{max}/(kW·h)$	300
P_{G3}^{max}/kW	50	$P_{ES,max}^c, P_{ES,min}^d/kW$	45, -45

以高输出功率频繁在充、放电之间转换也增加了 ES 的损耗。算例三通过 EV 和 ES 协同参与微电网运行,两种灵活性资源优势互补,提高了微电网的经济性和稳定性,也促进了可再生能源的消纳。下面对算例三进行具体分析。

3.3.2 多时间尺度调度结果分析

1) 日前阶段

在随机变量取预测值时,求解日前阶段的确定性模型,得到最优成本为 2 305.5 元,以此为基准值,设定 $\sigma=0.05$,得到 CVaR-IGDT 模型中成本上限为 $1.05 \times 2\ 305.5=2\ 420.8$ 元,利用式(18)优化得到的风光等效偏差系数为 0.231。基于 CVaR-IGDT 理论的前日调度优化结果如图 5 所示。

由图 5 可以看出,在负荷低谷期(0:00—7:00)电价相对较低,此时微电网向大电网购电,并将多余的能量储存在 ES 中。同时,在满足次日出行需求的前提下,EV 也集中于低谷时段充电,降低了运行成本。由于光伏出力几乎为零,导致 MT 出力增加,微电网从主网的购电量保持在较高水平;在 7:00—17:00 时光伏出力增加,MT 的出力减小,EV 不在调度时间内无法进行充放电调度,而 ES 可以持续处于充电状态进行蓄能;负荷高峰时段(17:00—24:00)微电网负荷需求持续处于较高水平,而外电网也正处于负荷高峰期,电价也相对较高,若向外网购电会增加微电网运行成本。由于此时售电电价较高,EV 和 ES 进行集中有序的放电向微电网提供电能,并将多余电量出售给外电网,从而减少日前调度的运行成本,避免峰上加峰。

2) 日内阶段

采用 MPC 滚动优化实时修正日前调度计划,日内 MPC 滚动优化更新后输出的优化结果如图 6 所示。从图 6 可以看出,为应对随机变量预测误差带来的扰动,MPC 对日前调度计划进行了修正,得到的微电网日内阶段调度计划与日前阶段总体上一致,但日内调度策略更为精确。这主要是由于日内优化时间尺度间隔变小提高了预测精度,而且日内阶段充分考虑了微电网系统的实际工作状况,利用反馈校正大大提高了控制策略的精确度。同时,在日前阶段利用 CVaR-IGDT 理论更全面地考虑了各种不确定性因素造成的负面影响,从而减少了日内阶段 MPC 对调度计划的修正量,避免出力机组大幅度的功率修正,使微电网稳定运行并保证了良好的经济效益。

表 4 不同算例优化结果

Table 4 Optimization results of different examples

算例	微电网	交互功率	可再生能
	成本/元	波动/ kW^2	源消纳率/%
算例一	2 513.7	14 652	90.10
算例二	2 481.3	12 719	93.21
算例三	2 321.4	8 476	95.67

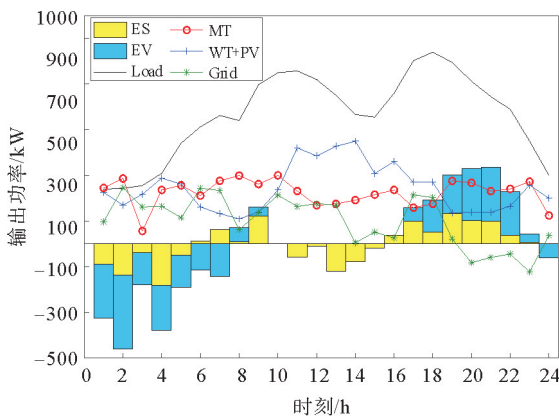


图 5 日前优化结果

Fig. 5 Results of previous optimization

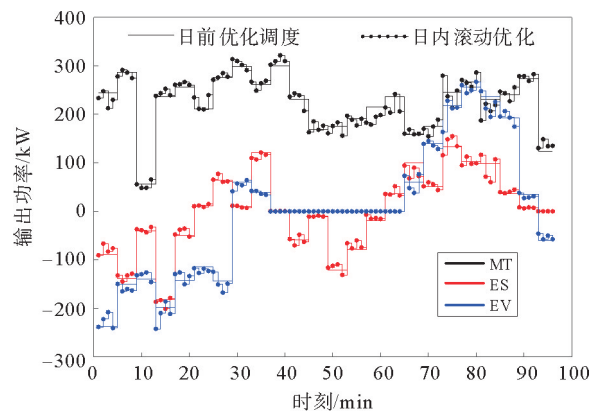


图 6 日内滚动优化结果

Fig. 6 Results of MPC rolling optimization

3.3.3 模型有效性对比

为了说明本研究所提模型的优越性,应用不同的日前优化方法设计了 3 种场景进行对比分析:场景一,确定性模型;场景二,随机规划多场景方法;场景三,IGDT-CVaR 方法。其中,多场景法采用场景生成和 K

均值聚类算法获得随机变量场景集^[22]。日内阶段分别设置开环控制和 MPC 两种控制方法,日内误差分别取 10%、15% 和 20% 时的系统最优成本,如表 5 所示。

由表 5 可以看出,确定性模型采用不确定量的预测值作为控制策略的输入参数,日前调度阶段优化运行成本最低。但由于在日前阶段未考虑随机变量不确定性,与另外两种调度策略相比,在日内调度阶段随着预测误差增加,系统成本增长速率最快。基于场景法和 CVaR-IGDT 的调度策略考虑了系统不确定性,但后者的成本增加速度更慢,这是由于基于 CVaR-IGDT 的调度策略使日前调度场景更加接近日内实际运行场景。同时,对比日内短时间尺度下基于开环与基于 MPC 的优化结果,可以发现开环控制下成本较高,引入日内 MPC 滚动优化机制后,可以更加精细地调整大电网购电计划和各机组出力计划,降低优化调度成本。

3.3.4 灵敏度分析

以上分析了 CVaR-IGDT 模型在系统优化中的作用,显然关键控制参数 σ 和 β 会影响优化结果,本研究探讨了 σ 和 β 在取不同值时对调度计划的影响。由于该分析过程和结论同样适用于日内调度阶段,所以仅对日前阶段灵敏度进行分析。图 7 显示了不同 σ 和 β 取值的优化结果。

图 7(a)中,在求解 CVaR-IGDT 模型时,取 $\beta=0.1$ 保持不变, σ 从 0.05 增加到 0.5,得到综合偏差系数 α 从 0.231 提高到 0.392。这说明随着规避系数 σ 的增加,微电网优化调度的成本增大,生成的调度计划应对风光出力不确定性的能力越强。图 7(b)中,保持 $\sigma=0.05$ 不变, β 从 0 增加到 0.2,得到综合偏差系数 α 从 0.183 增加到 0.291。这是因为随着 β 的增大,系统会越来越倾向于规避电价波动和 EV 充放电行为不确定性带来的运行风险,使得可以接受的风光出力波动范围增大,系统可以接受的最大风光不确定性增加。显然,决策者在制定调度策略时,可灵活调整既定的成本预算以及风险偏好水平,在系统经济性与可靠性之间进行有效地权衡。

4 结论

针对微电网运行过程中的多种不确定性因素,本研究将 CVaR 与 IGDT 相结合,提出了含电动汽车微电网滚动优化策略。在日前阶段,利用 CVaR 处理电价和 EV 行驶特性的不确定性;针对风光处理概率分布难以准确预测的问题,利用 IGDT 对风光出力不确定性进行处理;在日内阶段提出基于 MPC 的滚动优化策略,实现对日前调度偏差的修正。算例结果表明:ES 和 EV 同时接入时两种灵活性资源优势互补,提高了微电网的经济性和稳定性,也促进了可再生能源的消纳;所提出的模型可以合理安排各单元出力,减小不确定性因素给系统带来的负面影响;所提出的优化策略与基于多场景优化和确定性模型优化相比,在开环控制和基于 MPC 的控制模式下有更好的经济性,可以有效跟踪随机变量预测精度不足导致的误差波动;通过灵活选择收益偏差系数和风险偏好系数,决策者可以在系统经济性与可靠性之间进行有效地权衡。

表 5 不同策略下的优化结果

Table 5 Optimization results under different strategies 元

策略	日前调度	日内 10% 误差	日内 15% 误差	日内 20% 误差
场景一/开环	2 305.5	2 778.3	2 861.8	2 945.1
场景一/MPC	2 305.5	2 499.8	2 562.3	2 632.8
场景二/开环	2 415.6	2 725.3	2 793.8	2 863.9
场景二/MPC	2 415.6	2 387.3	2 431.9	2 482.9
场景三/开环	2 520.8	2 574.4	2 628.6	2 686.4
场景三/MPC	2 520.8	2 321.4	2 358.9	2 396.3




图 7 α 随 σ 和 β 的变化曲线

Fig. 7 Curve of α versus σ and β

参考文献:

- [1] 沈国辉,陈光,赵宇,等.基于双目标分层优化和TOPSIS排序的电动汽车有序充电策略[J].电力系统保护与控制,2021,49(11):115-123.
SHEN Guohui, CHEN Guang, ZHAO Yu, et al. Orderly charging optimization strategy of an electric vehicle based on double objective hierarchical optimization and TOPSIS ranking[J]. Power System Protection and Control, 2021, 49(11): 115-123.
- [2] 杨晓东,张有兵,蒋杨昌,等.微电网下考虑分布式电源消纳的电动汽车互动响应控制策略[J].电工技术学报,2018,33(2):390-400.
YANG Xiaodong, ZHANG Youbing, JIANG Yangchang, et al. Renewable energy accommodation-based strategy for electric vehicle considering dynamic interaction in microgrid[J]. Transactions of China Electrotechnical Society, 2018, 33(2): 390-400.
- [3] 姚一鸣,赵溶生,李春燕,等.面向电力系统灵活性的电动汽车控制策略[J].电工技术学报,2022,37(11):2813-2824.
YAO Yiming, ZHAO Rongsheng, LI Chunyan, et al. Control strategy of electric vehicles oriented to power system flexibility[J]. Transactions of China Electrotechnical Society, 2022, 37(11): 2813-2824.
- [4] 程杉,汪业乔,廖玮霖,等.含电动汽车的新能源微电网多目标分层优化调度[J].电力系统保护与控制,2022,50(12):63-71.
CHENG Shan, WANG Yeqiao, LIAO Weilin, et al. Bi-level multi-objective optimization of a new energy microgrid with electric vehicles[J]. Power System Protection and Control, 2022, 50(12): 63-71.
- [5] MANSOURLAKOURAJ M, SHAHABI M, SHAFIE-KHAH M, et al. Optimal power management of dependent microgrid considering distribution market and unused power capacity[J/OL]. Energy, 2020, 200(1). DOI:10.1016/j.energy.2020.117551.
- [6] CHEN X Q, DONG W, YANG Q. Robust optimal capacity planning of grid-connected microgrid considering energy management under multi-dimensional uncertainties[J]. Applied Energy, 2022, 323: 1-14.
- [7] SALKUTI S R. Risk-based optimal operation of hybrid power system using multiobjective optimization[J]. International Journal of Green Energy, 2020, 17(13): 853-863.
- [8] 吴洲洋,艾欣,胡俊杰,等.基于充电行为预测的电动汽车参与系统调频备用:容量挖掘与风险评估[J].电力自动化设备,2022,42(4):18-26.
WU Zhouyang, AI Xin, HU Junjie, et al. EVs' participation in system frequency regulation reserve based on charging behavior prediction: Capacity mining and risk evaluation[J]. Electric Power Automation Equipment, 2022, 42(4): 18-26.
- [9] GHASEMI A, MONFARED H J, LONI A, et al. CVaR-based retail electricity pricing in day-ahead scheduling of microgrids[J/OL]. Energy, 2021, 227(15). DOI:10.1016/j.energy.2021.120529.
- [10] 孙国强,周亦洲,卫志农,等.基于混合随机规划/信息间隙决策理论的虚拟电厂调度优化模型[J].电力自动化设备,2017,37(10):112-118.
SUN Guoqiang, ZHOU Yizhou, WEI Zhinong, et al. Dispatch optimization model of virtual power plant based on hybrid stochastic programming and information gap decision theory[J]. Electric Power Automation Equipment, 2017, 37(10): 112-118.
- [11] 彭巧,王秀丽,邵成成,等.计及信息间隙决策理论的含电动汽车充电负荷的微电网多目标规划[J].电力自动化设备,2021,41(1):128-134.
PENG Qiao, WANG Xiuli, SHAO Chengcheng, et al. Multi-objective planning of microgrid with electric vehicle charging load based on information gap decision theory[J]. Electric Power Automation Equipment, 2021, 41(1): 128-134.
- [12] YAN Q, ZHANG B, KEZUNOVIC M. Optimized operational cost reduction for an EV charging station integrated with battery energy storage and PV generation[J]. IEEE Transactions on Smart Grid, 2019, 10(2): 2096-2106.
- [13] 肖斐,艾芊.基于模型预测控制的微电网多时间尺度需求响应资源优化调度[J].电力自动化设备,2018,38(5):184-190.
XIAO Fei, AI Qian. Multiple time-scale optimal dispatch of demand response resource for microgrid based on model predictive control[J]. Electric Power Automation Equipment, 2018, 38(5): 184-190.
- [14] 孙丛丛,王致杰,江秀臣,等.计及风光预测误差的微电网日前多目标优化控制策略[J].高压电器,2018,54(1):73-81.
SUN Congcong, WANG Zhijie, JIANG Xiuchen, et al. Day-ahead multi-objective optimization control strategy for micro-

- grid considering forecast errors of wind/photovoltaic[J]. High Voltage Apparatus, 2018, 54(1):73-81.
- [15] 阎怀东, 马汝祥, 柳志航, 等. 计及需求响应的电动汽车充电站多时间尺度随机优化调度[J]. 电力系统保护与控制, 2020, 48(10):71-80.
YAN Huaidong, MA Ruxiang, LIU Zhihang, et al. Multi-time scale stochastic optimal dispatch of electric vehicle charging station considering demand response[J]. Power System Protection and Control, 2020, 48(10):71-80.
- [16] YU S Y, FANG F, LIU Y J, et al. Uncertainties of virtual power plant: Problems and countermeasures[J]. Applied Energy, 2019, 239:454-470.
- [17] 刘海涛, 许伦, 郝思鹏, 等. 基于配电网分区的分布式混合储能优化方法[J]. 电力自动化设备, 2020, 40(5):137-145.
LIU Haitao, XU Lun, HAO Sipeng, et al. Optimization method of distributed hybrid energy storage based on distribution network partition[J]. Electric Power Automation Equipment, 2020, 40(5):137-145.
- [18] 孔德政, 张靖, 何宇, 等. 区域综合能源系统 IGDT-MPC 双层能量优化调度[J]. 电网技术, 2022, 46(10):3970-3979.
KONG Dezheng, ZHANG Jing, HE Yu, et al. IGDT-MPC bi-layer energy optimal scheduling of regional integrated energy system[J]. Power System Technology, 2022, 46(10):3970-3979.
- [19] ENTSO-E. Data platform-open power system data[EB/OL]. (2020-10-06)[2022-09-02]. https://data.open-power-system-data.org/time_series/2020-10-06.
- [20] PJM Interconnection. Markets & operations, Energy markets, day-ahead energy market[EB/OL]. [2022-09-01]. <http://www.pjm.com/markets-and-perations/energy/day-ahead.aspx>.
- [21] FREY B J, DUECK D, et al. Clustering by Passing Messages Between Data Points[J]. Science, 2007, 315(5814):972-976.
- [22] 吴宇, 张彼德, 袁国森, 等. 计及电动汽车和风光资源不确定性的微电网优化配置[J]. 电测与仪表, 2016, 53(16):39-44.
WU Yu, ZHANG Bide, YUAN Guosen, et al. Optimal configuration of micro-grid considering uncertainties of electric vehicles and PV/wind sources[J]. Electrical Measurement & Instrumentation, 2016, 53(16):39-44.

(责任编辑:齐敏华)

(上接第 83 页)

- [21] 陈俊, 黄晓明. 沥青路面多尺度结构的荷载响应分析[J]. 建筑材料学报, 2012, 15(1):116-121.
CHEN Jun, HUANG Xiaoming. Numerical analysis on multi-scale structure of asphalt concrete pavement[J]. Journal of Building Materials, 2012, 15(1):116-121.
- [22] 宫兴, 英红, 姜鹏. 基于 BP 神经网络的沥青混合料级配检测研究[J]. 河南理工大学学报(自然科学版), 2022, 41(3):165-171.
GONG Xing, YING Hong, JIANG Peng. Research on asphalt mixture grading detection based on BP neural network[J]. Journal of Henan Polytechnic University (Natural Science), 2022, 41(3):165-171.
- [23] MENG Q X, LV D, LIU Y. Mesoscale computational modeling of concrete-like particle-reinforced composites with non-convex aggregates[J/OL]. Computers & Structures, 2020, 240. DOI:10.1016/j.compstruc.2020.106349.
- [24] YAO X G, LI C X, XU T. Multi-scale studies on interfacial system compatibility between asphalt and SBS modifier using molecular dynamics simulations and experimental methods[J/OL]. Construction and Building Materials, 2022, 346. DOI:10.1016/j.conbuildmat.2022.128502.
- [25] 张海涛, 马盛盛, 于腾江. 不同预测方法的沥青混合料弹性模量对比研究[J]. 重庆交通大学学报(自然科学版), 2018, 37(1):35-39.
ZHANG Haitao, MA Shengsheng, YU Tengjiang. Comparative study on HMA elastic modulus based on different predicting methods[J]. Journal of Chongqing Jiaotong University (Natural Science), 2018, 37(1):35-39.

(责任编辑:齐敏华)