

DOI: 10.19783/j.cnki.pspc.190158

基于短期预测信息和长期值函数近似的大规模 电动汽车实时随机优化调度算法

王彬¹, 郭文鑫¹, 李世明¹, 赵瑞锋¹, 李波¹, 卢建刚¹, 潘振宁²

(1. 广东电网有限责任公司电力调度控制中心, 广东 广州 510060; 2. 华南理工大学电力学院, 广东 广州 510640)

摘要: 针对大规模电动汽车(Electric Vehicle, EV)和可再生能源接入背景下主动配电网的实时随机调度问题, 提出了一种结合短期预测信息和长期值函数近似的双层实时调度模型。为应对大量 EV 接入后的维数灾问题, 首先提出双层调度框架, 上层建立 EV 集群模型, 下层根据 EV 特性提出功率分配算法对每辆 EV 制定充电计划, 实现上层集群指令的完全消纳并满足各 EV 充电的需求。同时, 为应对 EV 行为、实时电价及可再生能源出力不确定性的问题, 实时优化时采用预测算法预测短期内未来接入的 EV 行为、可再生能源最大出力与实时电价, 并通过值函数近似评估短期决策后系统的值函数, 从而实现 EV 集群充电计划、可再生能源调度计划与购电计划的实时分阶段决策。仿真算例表明, 所提模型可以实现大规模 EV 接入下主动配电网的实时随机调度, 同时具备良好的鲁棒性。

关键词: 电动汽车; 实时优化; 随机优化

Real-time charging optimization for large-scale electric vehicles based on short term forecast information and long term value function approximation

WANG Bin¹, GUO Wenxin¹, LI Shiming¹, ZHAO Ruifeng¹, LI Bo¹, LU Jiangan¹, PAN Zhenning²

(1. Electric Dispatch and Control Center, Guangdong Power Grid Co., Ltd., Guangzhou 510060, China;

2. College of Electric Power, South China University of Technology, Guangzhou 510640, China)

Abstract: This paper proposes a hierarchical framework for the real-time dispatch of Active Distribution Networks (ADN) with high penetration of Electric Vehicles (EVs) and renewable energy, based on near term forecast information and long term value function approximation. To solve the curse of dimensionality after large-scale EVs access, in the upper layer, an equivalent EV cluster model is developed; while in the lower layer, the power allocation algorithm considering the diverse characteristics of EVs is proposed to make specific strategies for each EV while tracking the upper layer instruction. To handle the stochastic EV charging behaviors, maximum output of renewable energy and real-time price, the near term forecast information of those stochastic factors are considered in the proposed method. Further, value function approximations are adopted to evaluate the value function of the system after the near term decision, by which way the real-time dispatches of EV clusters, renewable energy, and electricity purchase can be given stage by stage. Simulation cases verify the effectiveness and the robustness of the proposed model in the real-time coordinated dispatch of ADN with high penetration of EVs.

This work is supported by Science and Technology Project of China Southern Power Grid Co., Ltd. (No. GDKJXM20172831).

Key words: large-scale EVs; real-time optimization; stochastic optimization

0 引言

随着各国电动汽车(Electric Vehicle, EV)产业发

展的不断推动, 可以预见在不久的将来, EV 的渗透率将会持续上升。大量研究表明, 作为一种海量的需求侧分布式资源, 对大规模 EV 负荷进行调控, 可有效提升系统的可靠性与经济性^[1-3]。

按时间尺度可将 EV 参与电网协同运行分为日前优化调度和日内实时优化调度两方面。其中, 日

基金项目: 中国南方电网有限责任公司科技项目资助 (GDKJXM20172831)

前优化通常关注区域内 EV 的总出力计划, 而实时优化需要实时考虑区域内的所有入网 EV 的充电需求, 跟踪日前计划并制定每辆 EV 的充电策略以满足用户的出行需求, 以滚动优化^[4]的方法完成计算。

实时优化需要考虑系统随机性的影响, 在含大规模 EV 的主动配电网实时优化中, 随机性主要包含未来入网的 EV 行为及需求的不确定性、可再生能源出力变化的不确定性、实时电价(Real Time Price, RTP)的不确定性等。另一方面, 含 EV 的优化调度问题将引入大量时段耦合因素, 因此如何在强随机环境下, 通过动态决策最终实现全局最优是解决 EV 实时优化问题的关键。

已有大量文献对含 EV 的协同优化问题进行了研究, 未解决随着 EV 渗透率的增加在计算时可能产生“维数灾难”的问题, 文献[5-8]分别采用了分层优化或集群优化的方法。在考虑随机性方面, 通常采用场景法或风险度量^[9-10]等方式解决, 但上述方法都是站在日前优化的角度进行计算, 然而, EV 实时优化问题规模庞大, 利用上述方法进行计算往往不能够满足实时性要求。模型预测控制(Model Predictive Control, MPC)^[11-12]通过预测短期内系统可能发生变化, 滚动更新决策, 实现了优化的闭环, 适用于具有不确定性系统的实时优化当中, 该方法已在配网、微网多时间尺度运行^[11], 在消纳大规模风电的协调控制^[12]中得到应用。文献[13-14]研究了基于 MPC 的 EV 实时调度优化方法, 但由于传统 MPC 的评价指标是预测时域内的优化效果, 为实现全局最优, 便不得不将预测时域拓展至整个优化时域, 增大了计算量并对预测算法提出了更高的要求。文献[15]提出基于两阶段近似动态规划(Approximate Dynamic Programming, ADP)的 EV 实时优化方法, 通过估计决策后的状态值函数避免引入长时段的预测与计算, 但该方法以单台 EV 进行建模计算, 并不适用于大规模 EV 接入的情况。

基于上述考虑, 本文提出了一种针对大规模 EV 接入下的实时随机充电优化算法, 根据大规模 EV 入网后形成的集群效应, 建立双层实时优化架构实现灵活的集群资源动态优化。上层在传统的 MPC 算法基础上, 基于随机存储器理论, 将 EV 集群可用容量视作存储量, 从而实现 MPC 短期决策后状态值函数的近似评估。下层提出基于优先级的功率分配算法, 在满足单辆 EV 需求的基础上精准实现功率指令的消纳。仿真结果表明, 本文提出的架构和算法能够兼顾实时性和准确性, 所提算法能够比传统的 MPC、ADP 算法更加接近理论最优解, 适用于求解大规模 EV 接入后的实时优化问题。

1 双层实时优化架构

本文提出的双层实时调度模型架构如图 1 所示, 上层包含主动配电网运营商(Active Distributed Network Operator, ADNO)、EV 负荷聚合体(Electric vehicle Aggregator, EVA)和风电机组, 下层则包含大规模的 EV。值得一提的是, 本文提出的模型框架是一种适用于未来大规模分布式可调控资源接入的调控框架, 当其他可控资源接入时(例如可控的空调集群), 该框架仍然适用。ADNO 根据风电出力及 EV 充电需求信息, 确定向电网的购电计划, 以满足 ADN 内部的负荷需求。

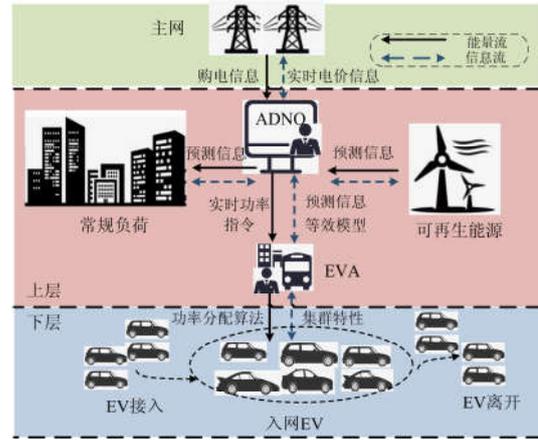


图 1 优化模型架构图

Fig. 1 Architecture diagram of the optimization model

假设 ADNO 作为价格的接受者参与日前和实时电力市场, 具体来说, ADNO 根据日前电价(Day Ahead Price, DAP)和 RTP 的历史信息制定日前购电计划, 并在实时优化阶段根据日前购电计划及实时系统状态确定实际的购电计划。关于日前最优竞价可通过鲁棒优化^[8]、风险度量^[9-10]等方法制定, 本文研究重点是在日前购电策略已制定的情况下, 如何在实时优化阶段实现大规模 EV 资源的动态优化。

2 EV 集群等效模型

单辆 EV 的充电负荷模型由式(1)表示^[4]。

$$\begin{cases} e_t = \eta \sum_{k=t_{\text{start}}}^t p_{EV,k} \cdot \Delta t = e_{t-1} + \eta \cdot p_{EV,t} \cdot \Delta t \\ e_{\min,t_{\text{end}}} = e_{\max,t_{\text{end}}} = D \\ e_{\min,t} \leq e_t \leq e_{\max,t} \\ p_{\max,t} = \min(p_{EV,\max}, (e_{\max,t} - e_{t-1}) / \eta / \Delta t) \\ p_{\min,t} = \max(0, (e_{\min,t} - e_{t-1}) / \eta / \Delta t) \\ p_{\min,t} \leq p_{EV,t} \leq p_{\max,t} \end{cases} \quad (1)$$

式中: EV 于 t_{start} 时刻开始时接入电网, 并计划于 t_{end}

时刻结束时离开; $p_{EV,t}$ 为该 EV 在 t 时刻的充电功率; $p_{EV,max}$ 为电池可接受的最大充电功率; e_t 为 EV 于 t 时刻已经累计注入的能量, 称为能量轨迹; $e_{max,t}$ 与 $e_{min,t}$ 分别为 t 时刻的能量轨迹上下界; D 为该 EV 的充电需求; η 为充电效率; $p_{max,t}$ 和 $p_{min,t}$ 分别为该 EV 在 t 时刻因能量边界约束限制的最大、最小充电功率。

当 EV 接入电网后, 其充电模型式(1)即可确定, 将所有入网 EV 的充电模型累加, 可得到 EVA 内 EV 集群的等效模型, 如式(2)所示。

$$\begin{cases} E_{min,t} \leq E_t \leq E_{max,t} \\ E_t = \eta \sum_{m=1}^t P_{EVA,m} \Delta t = E_{t-1} + \eta P_{EVA,t} \Delta t \\ P_{EVA,t} = \sum_i^n p_{EV,i,t} \\ P_{EVA,min,t} = \sum_i^n p_{min,i,t} \leq P_{EVA,t} \leq \sum_i^n p_{max,i,t} = P_{EVA,max,t} \\ E_{min,i,t} = \sum_i^n e_{min,i,t} \\ E_{max,i,t} = \sum_i^n e_{max,i,t} \end{cases} \quad (2)$$

式中: E_t 为 EV 集群于 t 时刻的能量轨迹; $E_{max,t}$ 与 $E_{min,t}$ 分别为 t 时刻该集群的能量轨迹上下界; n 为 t 时刻所有已经接入 EVA 的 EV 数量; $P_{EVA,t}$ 为 t 时刻 EVA 的充电功率; $P_{EVA,max,t}$ 为最大充电功率。

由于新 EV 负荷的接入, 将导致 EV 集群的能量边界发生动态变化, 如式(3)所示。

$$\begin{cases} E_{min,t+1} = E'_{min,t+1} + \sum_{i=1}^{n_{t+1}} e_{min,i,t+1} \\ E_{max,t+1} = E'_{max,t+1} + \sum_{i=1}^{n_{t+1}} e_{max,i,t+1} \end{cases} \quad (3)$$

式中: n_{t+1} 为 $t+1$ 时刻新接入的 EV 数量; $E'_{min,t+1}$ 和 $E'_{max,t+1}$ 分别为 t 时刻的集群等效模型在 $t+1$ 时刻的能量边界。

定义 EV 集群的 t 时刻的可用容量 R_t 为能量轨迹上边界与已注入能量之差, 即:

$$\begin{cases} R_t = E_{max,t} - E_t \\ 0 \leq R_t \leq E_{max,t} - E_{min,t} \end{cases} \quad (4)$$

EV 集群充电模型注重对大规模 EV 群体对外表现出的整体特性的建模, 单辆 EV 行为的不确定性体现在模型参数的变化当中, 式(2)中的变量与约束个数与式(1)相同, 因此在上层优化计算时不会引入过多的变量及约束, 有效地避免了大规模 EV 接入产生的“维数灾难”问题, 在得到满足式(2)要求的集群充电计划之后, 制定相应的下层分配算法, 便可在满足集群内所有 EV 的充电需求基础上实现对集群充电计划的跟踪。

3 优化目标

ADNO 一日内的实际运行成本 C_{total} 为

$$C_{total} = \sum_{t=1}^T (P_{DA,t} \alpha_{DA,t} + \alpha_{P,t} \cdot (P_{RT,t} - P_{DA,t})) \Delta t \quad (5)$$

式中: T 为总时段数; 右边第一项为参与日前市场的购电成本; 第二项为参与实时市场的成本, 即实际购电策略与日前策略偏差导致的不平衡成本^[9]。

优化目标是通过各时段的实时决策, 使得一天内的实际总运行成本最小, 可表述为

$$\min_{P_{EVA,t}, P_{WT,t}, P_{RT,t}} C_{total} \quad (6)$$

其中,

$$\alpha_{P,t} = \begin{cases} \alpha_{RT,t}, & P_{RT,t} - P_{DA,t} \geq 0 \\ \lambda \alpha_{DA,t}, & P_{RT,t} - P_{DA,t} < 0 \end{cases} \quad (7)$$

式中: $P_{WT,t}$ 、 $P_{DA,t}$ 和 $P_{RT,t}$ 分别为风电出力、ADNO 向主网的日前购电计划和实时购电计划; $\alpha_{DA,t}$ 和 $\alpha_{RT,t}$ 分别为 ADN 向主网购电的 DAP 和 RTP; $\alpha_{P,t}$ 为实际购电计划与日前计划偏差的惩罚电价^[5], $0 < \lambda < 1$, 本文取 0.5。

各时刻 ADN 需满足供需平衡约束及安全约束。

$$\begin{cases} P_{CON,t} + P_{EVA,t} = P_{RT,t} + P_{WT,t} \\ P_{WT,t} \leq P_{WT,max,t} \\ P_{RT,t} \leq P_{RT,max} \end{cases} \quad (8)$$

式中: $P_{CON,t}$ 为常规负荷功率; $P_{WT,max,t}$ 为风电的最大出力; $P_{RT,max}$ 为 ADN 与主网的联络线功率传输极限。

日内优化阶段的决策需要考虑多种随机因素的影响, 本文主要考虑的随机因素有: EV 行为、风电出力和电价信息的不确定性。由于在上层优化中采用了集群模型, 因此下层中单台 EV 的不确定性(包括: 接入和离开时间、充电需求、电池极限功率的不确定性)将体现在上层集群模型参数($E_{max,t}$ 、 $E_{min,t}$ 和 $P_{EVA,max,t}$)的不确定性上。

考虑上述不确定影响之后, 目标函数可转变为求取因实际购电策略与日前策略偏差导致的不平衡成本的期望最小。

$$\max_{X_t \in \Omega} E \sum_{t=1}^T C_t(X_t, S_t) \quad (9)$$

式中, E 表示期望运算算子。

其中,

$$C_t(X_t, S_t) = -\alpha_{P,t} (P_{RT,t} - P_{DA,t}) \cdot \Delta t \quad (10)$$

$$\begin{cases} X_t = (P_{EVA,t}, P_{WT,t}, P_{RT,t}) \\ S_t = (P_{CON,t}, P_{WT,max,t}, \alpha_{RT,t}, P_{EVA,max,t}, R_t) \end{cases} \quad (11)$$

式中: X_t 为时段 t 的决策变量, 包括 EVA、风电机组的调度计划和实际购电计划; Ω 为优化变量的可行域, 需满足式(2)、式(7)和式(8)约束; S_t 为系统在 t 时段的状态, 包括常规负荷功率、风机最大出力、RTP 信息、EVA 的最大充电功率和 EVA 的可用容量。

4 基于短期预测信息和长期值函数近似的上层实时优化调度算法

实现 ADN 最优实时调度的关键在于如何有效地利用 EV 的实时资源, 达到利益的最大化, 但因式(9)中的优化问题是一个随机的混合整数线性规划问题, 传统优化方法难以在满足实时性的基础上做出准确的决策, 因此, 本文提出了基于短期预测信息和长期值函数近似的实时优化调度算法实现上层调度计划的制定。

获取短期预测信息之后, 可以通过 MPC 的方式制定预测时域内 ADN 的调度策略, 其中, k 时刻的优化目标如式(12)所示^[8]。

$$\max_{X \in \Omega} (C_k(X_k, S_k) + \sum_{t=k+1}^{k+t_p} C_t(X_t, \tilde{S}_t)) \quad (12)$$

式中, \tilde{S}_t 为 t 时刻预测的系统状态。

假设模型的预测控制时域长度为 t_p , 在 k 时刻, 可利用超短期预测算法预测 $k+1$ 至 $k+t_p$ 时刻随机量对系统的影响, 由于预测后系统的状态变化是确定的, 实时优化算法可根据 k 时刻的最新系统状态, 并结合 $k+1$ 至 $k+t_p$ 时刻内预测的系统状态, 制定出系统的短期运行策略, 即 k 时刻的真实调度策略和 $k+1$ 至 $k+t_p$ 时刻的预调度策略, 系统仅执行 k 时刻的优化策略。到了 $k+1$ 时刻, 上述过程将不断被重复, 直至所有优化任务完成, 从而形成一个闭环的优化。但由于式(12)的优化目标仅是预测时域内的总目标最优, 决策后的系统状态对长期收益影响往往被忽略, 因此并不能保证策略的全局最优性; 另一方面, 长期并且准确的预测信息通常难以获取。为解决这一问题, 本文借鉴随机存储器理论和 ADP 思想^[16-20], 对短期决策后的系统状态值函数进行近似, 并在优化中充分考虑, 从而提升决策的质量。

在式(11)的系统状态中, 常规负荷功率、风机最大出力与 RTP 的变化均与系统的决策无关, 因此可视为随机量。另一方面, EVA 可用容量 R_t 随着系统每阶段决策和 EV 的随机行为动态变化, R_t 的变化体现了 ADN 内 EV 集群可调用资源的实时变化, 同时也是耦合各时段的状态变量, 因此可依据随机存储器理论, 可将 EVA 视为“虚拟存储器”, 将 R_t 视为存储器中的虚拟资源存储量^[16-18]。

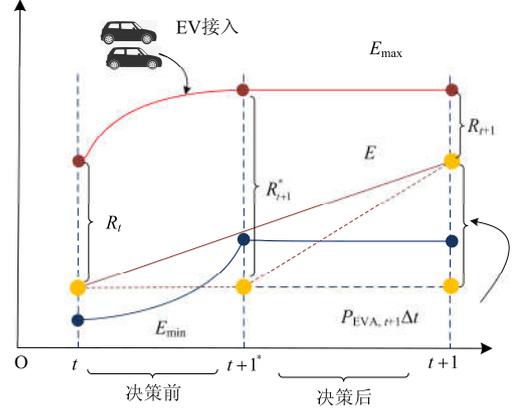


图2 决策过程中的 R_t 变化

Fig. 2 Change of R_t during the decision process

图2描述了依据随机存储器理论建模后, EV 集群资源随着 EV 随机接入与实时决策动态变化的过程, t 时刻至 $t+1$ 时刻的状态变化过程可以分为两阶段描述, 即 t 至 $t+1^*$ 称为决策前阶段, $t+1^*$ 至 $t+1$ 可称为决策后阶段, 对应的虚拟存储量 R^* 和 R 分别称为决策前后的存储量。在决策前阶段, EVA 的注入能量轨迹保持不变, 但由于新时刻有 EV 接入, 将引起 EVA 能量边界的变化(由式(3)求得), 可用容量也从 t 时刻决策后的状态 R_t 转变为 $t+1$ 时刻决策前状态 R_{t+1}^* , 在决策后阶段, 能量边界保持不变, EVA 将接收并执行调度指令 $P_{EVA,t+1}$, 并得到决策后的状态 R_{t+1} 。由文献[17]可知, 在得到决策后状态对值函数的影响后, 可依据 Bellman 最优性原理^[15], 可将式(9)转换为可在实时优化中进行分阶段决策的问题, 如式(13)所示。

$$V_t(S_t) = \max_{X_t \in \Omega} (C_k(X_k, S_k) + \sum_{t=k+1}^{k+t_p} C_t(X_t, \tilde{S}_t) + \gamma E(V_{k+t_p+1}(\tilde{S}_{k+t_p+1}) | \tilde{S}_{k+t_p})) \quad (13)$$

式中: $V_t(S_t)$ 为 t 时刻处于状态 S_t 的值函数; γ 为权重系数, 本文取 1。

相比传统的动态规划(Dynamic programming, DP)算法, 采用 ADP 的思想求取式(13)可获得近似最优决策并避免过长的优化时段数和连续状态空间带来的“维数灾难”问题^[16], 但由于最优值函数 V_{t+1} 通常难以准确获取, 因此求解式(13)需要解决的关键问题是如何求取近似值函数。文献[18-20]指出, 值函数可根据决策后的存储器状态 R , 利用一组分段线性函数进行近似, 表达式如式(14)所示。

$$V_t(S_t) \approx \sum_{b=1}^B v(t, b) y_b \quad (14)$$

需满足

$$\begin{cases} \sum_{b=1}^B y_b = R_{t_p} \\ 0 \leq y_b \leq (E_{\max,t} - E_{\min,t}) / B \end{cases} \quad (15)$$

式中: B 为虚拟存储状态 R 的分段数; $v(t,b)$ 为各分段的估值参数, y_b 为各分段的资源存储量。

获取估值参数的一种可行的思路是: 通过抽样和场景缩减法产生训练样本, 利用训练样本修正估值参数, 使其逼近于真实值函数。本文采用逐次投影近似法(Successive Projective Approximation Routine, SPAR)对估值参数进行求取, 该方法的具体步骤可见文献[18-20], 本文不再赘述。

至此, 可以得到本文提出的算法在 k 时刻的上层实时优化调度决策模型, 如式(16)所示。

$$\max(-\sum_{t=k}^{k+t_p} \alpha_{p,t} (P_{RT,t} - P_{DA,t}) \Delta t + \gamma \sum_{b=1}^B v(k+t_p, b) y_b) \quad (16)$$

需满足约束

$$\begin{cases} P_{CON,t} + P_{EVA,t} = P_{RT,t} + P_{WT,t} \\ P_{WT,t} \leq P_{WT,\max,t} \\ P_{RT,t} \leq P_{RT,\max} \\ E_{\min,t} \leq E_t \leq E_{\max,t} \\ E_{t+1} = \eta P_{EVA,t} \Delta t + E_t \\ R_t = E_{\max,t} - E_t \\ \sum_{b=1}^B y_b = R_{k+t_p} \\ 0 \leq y_b \leq (E_{\max,k+t_p} - E_{\min,k+t_p}) / B \end{cases} \quad (17)$$

式中: t_p 为预测控制时域长度; $v(k+t_p, b)$ 为 $k+t_p$ 时刻值函数各分段的估值参数。

显然, 当预测信息给定之后, 式(16)是一个确定的混合整数线性规划模型, 应用数学方法或求解工具箱可以快速求得最优解, 从而保证了计算的实时性。

5 下层 EV 功率分配算法

制定行之有效的分配策略, 在满足 EV 充电需求的基础上, 将式(14)得到的 t 时刻上层调度指令 $P_{EV,t}$ 分配到入网的所有 EV 上, 是确保模型能够高效准确运行的基础。下层分配中, 只需考虑当前 EV 的接入状况和当前时刻的上层功率指令, 不需要考虑随机性带来的影响。

不同的下层分配方案对上层系统将产生不同的影响, 如图 3 所示。 $t+1$ 时刻, 两种分配方案均能满足消纳 EVA 功率指令的需求, 但由于方案 1 的分配结果使得 EV1 和 EV2 的能量轨迹距离其能

量边界上界、下界很近, 因此 $t+2$ 时段将会产生最小充电功率限制(EV1)和最大充电功率限制(EV2), 减少了 EVA 的功率可调范围。而方案 2 则保证了每辆 EV 都具备充足的功率可调裕度, 因此 EVA 在 $t+2$ 时刻的调控也更加灵活。因此, EVA 希望 t 时刻指令分配后, 下一时刻的功率可调范围尽可能大, EVA 的最大功率可调范围可由式(16)求得。

$$\Delta P_{EVA,\max,t+1} = \max(P_{EVA,\max,t} - P_{EVA,\min,t}) \quad (18)$$

需满足

$$\begin{cases} e_{i,t} = e_{i,t-1} + p_{EV,i,t} \cdot \Delta t \\ e_{\min,i,t} \leq e_{i,t} \leq e_{\max,i,t} \\ p_{\min,i,t} \leq p_{EV,i,t} \leq p_{\max,i,t} \\ \sum_{i=1}^n p_{EV,i,t} = P_{EVA,t} \end{cases} \quad (19)$$

得到最大功率可调范围 $\Delta P_{EVA,\max,t+1}$ 后, 由于每辆 EV 的停留时间、充电需求和已注入的电能都不尽相同, 故在保证下一时刻的功率可调范围的前提下, 希望将功率优先分配给停留时间较短和需求较大的 EV。根据 EV 停留时间和功率分配后的已注入能量状态, 提出的下层功率分配目标可描述为

$$\max \sum_i^n \left(\frac{t_{\text{end},i}}{t_{\text{end},i} - t + 1} \cdot \frac{D_i - e_{i,t}}{P_{EV,\max,i}^2} \cdot p_{EV,i,t} \right) \quad (20)$$

需满足式(17)和式(19)约束:

$$\Delta P_{EVA,t+1} = \Delta P_{EVA,\max,t+1} \quad (21)$$

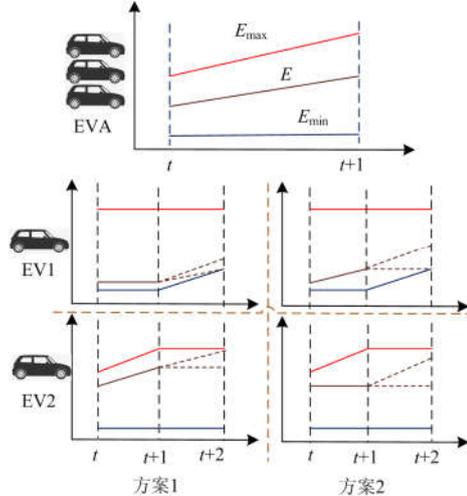


图 3 不同功率分配策略的影响

Fig. 3 Impacts of the different allocation strategies

值得一提的是, 可以采用多种方法实现下层 EV 的功率分配。可根据计算主体的不同将优化方法分为集中式优化和分布式优化两种, 分布式优化在信息隐私保护, 求解复杂大规模问题上相较于集中式优化具有优势, 但是对个体的计算能力以及通信通道提出了很高的要求, 并且难以保证算法的快速收

敛。针对于本文的下层功率分配问题而言，采用分布式计算需要对每个充电桩安装计算芯片同时增加信息传输通道的带宽，投资成本较高，同时，由于式(18)和式(20)分别为线性规划、二次规划模型，可借由求解器快速地实现集中式求解，因此，本文采用集中式方法实现下层分配。若有需要，也可采用文献[6, 21]的方法实现分布式求解。

6 实时优化流程

模型的求解分为离线训练阶段和在线应用阶段。其中，离线训练阶段通过产生场景样本训练估值参数，训练完成之后便可投入到在线应用当中，本文假设各随机变量真实值与期望的误差服从正态分布，采用拉丁超立方抽样产生训练样本进行离线训练。

在线应用阶段，在每一时刻开始前，EVA 更新入网 EV 的信息，生成 EVA 等效充电模型式(2)，得到能量边界及可调功率范围并上传至 ADNO，ADNO 获取系统的最新状态，包括 EVA、常规负荷、风电出力和 RTP 信息，并预测控制时域内系统的状态变化，由式(16)求得当前时段的决策并下发至 EVA，EVA 根据具体功率指令和式(20)，确定所有入网 EV 该时刻的充电计划。

目前关于风电出力预测、RTP 预测和负荷预测的方法已有很多。传统时序分析方法有灰色预测法、倍比平滑法、动平均法等；智能方法有支持向量机、神经网络、综合模型预测法等。本文采用使用方便、不需要大量样本、短期预测准确度较高的灰色预测法对 ADN 内 EVA 等效模型边界变化、风电出力和 RTP 进行预测，具体方法说明和步骤参见文献[11]。

7 算例分析

7.1 算例设置

为验证所提模型及算法的有效性，选取华南地区某配网进行算例仿真分析。实时优化调度的时段间隔选取为 15 min，一天从早上 8 时至次日早上 8 时共分为 96 个时段。各时段的常规负荷、风电出力期望、DAP、RTP 期望、日前购电计划和 EV 行驶规律如图 4—图 8 所示。假设实际风电最大出力、实际 RTP 与期望值的偏差服从 $N(0, 0.2)$ 的正态分布，该区域一天内有 4 000 车次的 EV 接入电网充电，电池参数见表 1 所示，虚拟存储状态的分段数 B 设为 50，利用拉丁超立方抽样产生 50 个样本进行估值参数的训练，若无特殊说明，算例中的短期信息预测的时段数均为 3。

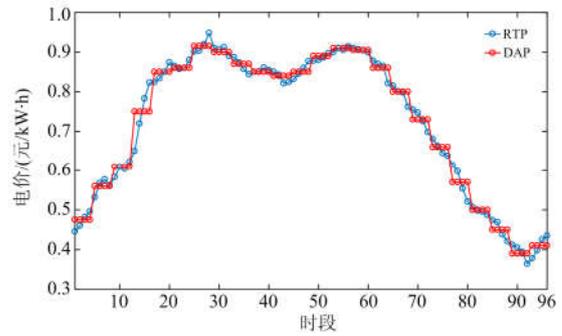


图 4 日前电价和实时电价期望曲线

Fig. 4 Expectation of DAP and RTP

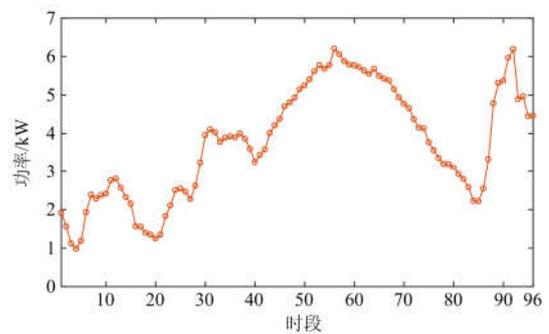


图 5 风机最大出力期望曲线

Fig. 5 Expectation of the wind turbine's maximum output

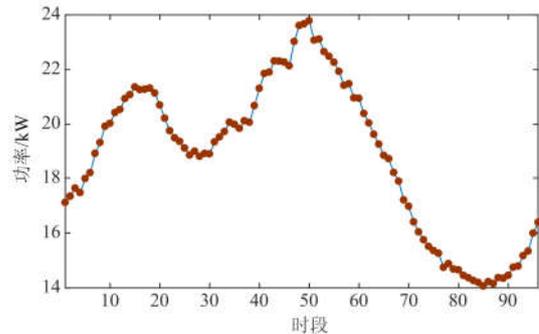


图 6 常规负荷

Fig. 6 Conventional load

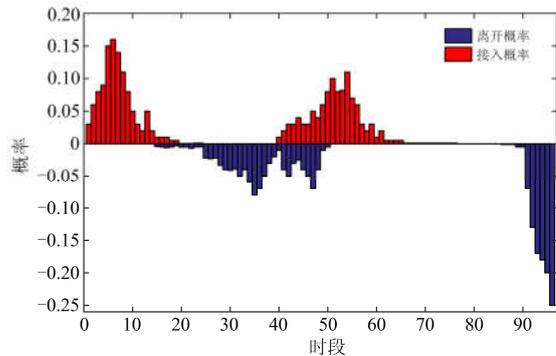


图 7 EV 驾驶行为

Fig. 7 Driven pattern of EVs

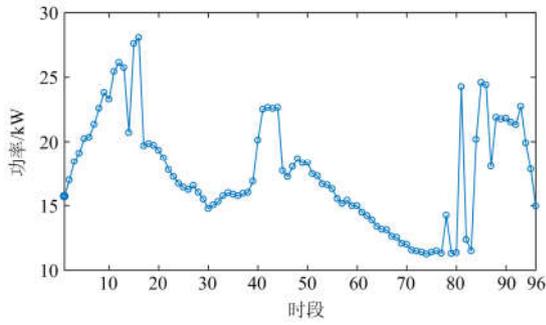


图 8 ADNO 日前购电策略

Fig. 8 Day-ahead electricity purchasing strategy of ADNO

本文的算例均在 CPU 为 inter(R) Core(TM) i7-6700、主频 3.40G Hz、内存为 16 G 的计算机上采用 Matlab R2016a 和 GAMS 建模, 上层优化的各时段子问题通过调用 CPLEX 求解器求解, 下层分配的子问题通过调用 CPLEX 和 CONOPT 求解器求解。

表 1 电动汽车参数

Table 1 Parameters of EVs

电池容量/kWh	最大充电功率/kW	所占比例
36	6	30%
48	8	40%
64	10	30%

7.2 模型优化效果分析

该部分假设实际风电最大出力和 RTP 均为期望值, 分析模型的优化效果。其中, 理论最优解可以通过假设所有的信息均为已知的情况下求得。

图 9 和图 10 为 EVA 的理论最优调度策略与实际调度策略、ADN 理论最优购电与实际购电计划的对比, 图 11 为算例中 4 000 车次 EV 的 SOC 变化曲线, 可以看出, ADN 向电网购电及 EVA 出力的高峰期都集中在 RTP 相对较低的时段, 理论最优的调度策略与实际调度策略的趋势基本一致, 吻合程度较好。仿真得到理论最优的不平衡成本与总运行成本分别为 4 891 元和 306 601 元, 实际的不平衡成本与总运行成本分别为 5 632 元和 307 342 元, 偏差约为 15%和 0.2%。与此同时, 除少部分停留时间不满足充电最低要求时间的 EV 外, 所有的 EV 都能够在停留时间内满足充电需求, 验证了双层实时调度架构、等效模型和功率分配算法的正确性和有效性。另外, 各时段的优化计算时间均不超过 1.5 s, 计算时间完全满足实时性要求, 因此, 所提出的调度架构和算法非常适合求解大规模 EV 接入下的实时充电优化问题。

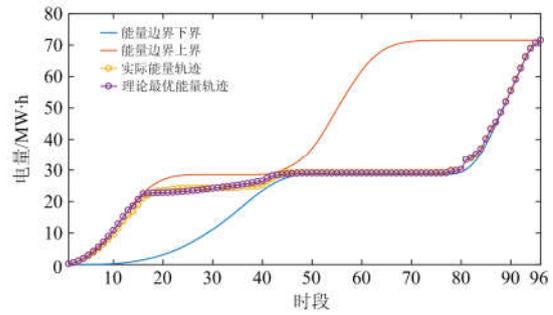


图 9 理论最优与实际能量轨迹

Fig. 9 Theoretically optimal and the actual energy trajectory

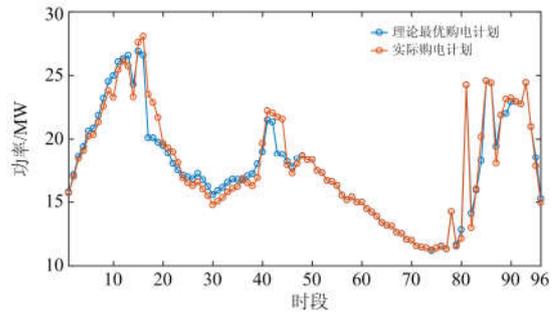


图 10 理论最优与实际购电策略

Fig. 10 Theoretically optimal and the actual electricity purchasing strategies

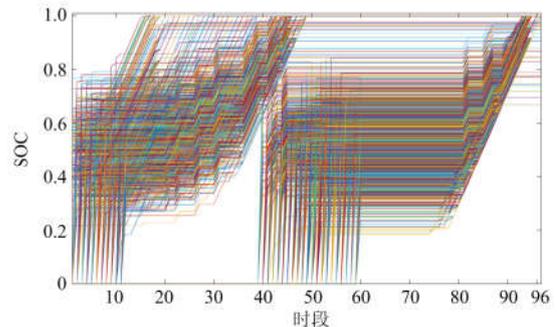


图 11 4 000 辆 EV 的 SOC 曲线

Fig. 11 SOC of the 4 000 EVs

7.3 不同算法、不同情景下的结果对比

为验证本文所提算法在不同场景下的计算结果, 该部分将本文提出的算法与传统 MPC、ADP 算法进行对比(其中, MPC 算法的预测控制时段数为 30 并假设预测误差为 10%, 同时采用拉丁超立方抽样生成 10 个场景作为预测场景)。根据随机量与期望值偏离的程度, 选取高风电出力(W1)、中风电出力(W2)、低风电出力(W3)、随机风电出力(W4)、高 RTP(P1)、中 RTP(P1)、低 RTP(P3)和随机 RTP8 种情况, 如图 12 和图 13 所示, 并组成如表 2 所示

的 16 个测试场景。各算法在各场景下得到的一天内 ADN 因实际购电策略与日前策略偏差导致的不平衡成本(元)如表 3 所示。

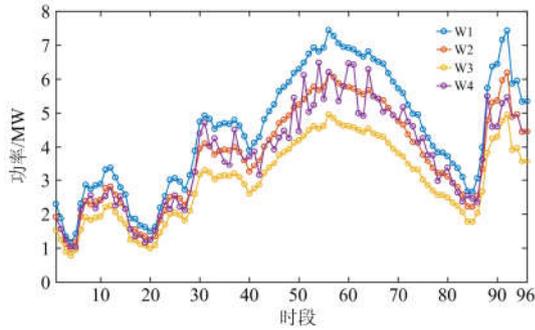


图 12 各场景下的可再生最大出力

Fig. 12 Maximum output of renewable resource in different scenarios

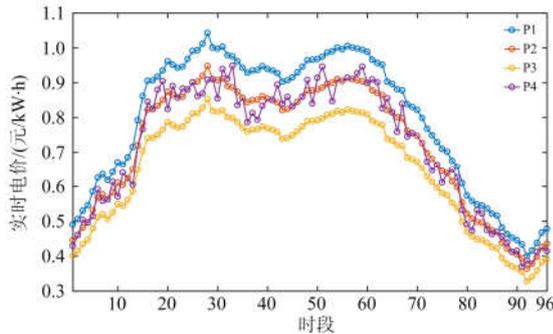


图 13 各场景下的实时电价曲线

Fig. 13 RTP in different scenarios

在 S1-S4 中, 风电的实际最大出力较期望值有明显的提升, 因此 ADNO 可通过降低购电功率节省运行成本, 这就导致 ADND 的日内不平衡成本为负数。可以看出, 在所有场景中, 本文提出的算法求得的日内不平衡成本与理论最优值的平均偏差约为 10%, 最大偏差小于 17%, 考虑到参与日前市场的成本后, 所有场景下的一日内总运行成本与理论最优值的偏差将不超过 0.4%, 算法具备较好的计算精度和较强的鲁棒性。同时, 在所有场景中, 本文提出的算法的计算结果均为最优, 优化效果比 MPC、ADP 算法可提升计算结果 1%~10%不等。

表 2 不同场景的构成

Table 2 Parameters of different scenarios

	P1	P2	P3	P4
W1	S1	S2	S3	S4
W2	S5	S6	S7	S8
W3	S9	S10	S11	S12
W4	S13	S14	S15	S16

表 3 各算法在不同场景下的不平衡成本

Table 3 Imbalance cost of different algorithms in different scenarios

	本文算法	MPC	ADP	理论最优
S1	-3 552	-3 172	-3 401	-4 132
S2	-3 749	-3 310	-3 349	-4 116
S3	-3 836	-3 416	-3 641	-4 249
S4	-3 702	-3 519	-3 497	-4 201
S5	6 240	6 521	6 401	5 349
S6	5 632	6 038	5 880	4 891
S7	4 819	5 055	4 955	4 323
S8	5 334	5 586	5 670	4 806
S9	19 965	20 505	20 287	19 337
S10	18 040	18 545	18 365	17 580
S11	16 120	16 441	16 585	15 820
S12	18 092	18 368	18 345	17 542
S13	6 871	7 217	7 378	6 215
S14	6 251	6 401	6 421	5 481
S15	5 372	5 571	5 560	4 823
S16	6 121	6 208	6 418	5 619

7.4 不同预测控制时段数下的优化效果对比

不同的预测控制时段数对计算结果有一定影响, 表 4 为各场景中不同预测控制时段数 t_p 下的算法输出结果与理论最优值的偏差。理论上来说, 预测控制时段越长, 算法的计算精度越高, 但在实际仿真中发现, 当预测控制时段数较短时(3~5), 增加预测控制时段长度有利于提升计算精度, 但随着预测控制时段数的增加, 继续增加预测控制时段反而

表 4 不同预测控制时段下的计算结果与理论最优值的偏差

Table 4 Deviation of calculated result and theoretical optimal value of different predictive control periods

	3	4	5	8	10
S1	14.04%	13.62%	13.56%	15.26%	18.67%
S2	8.91%	8.76%	8.64%	9.41%	9.65%
S3	9.72%	9.54%	9.48%	10.27%	10.56%
S4	11.88%	11.64%	11.47%	11.89%	12.01%
S5	16.66%	16.51%	16.39%	16.89%	16.90%
S6	15.15%	15.01%	14.89%	15.35%	15.42%
S7	11.47%	11.39%	11.32%	11.67%	11.89%
S8	10.99%	10.89%	10.78%	11.08%	11.20%
S9	3.25%	3.01%	2.93%	3.18%	3.26%
S10	2.62%	2.49%	2.52%	2.73%	2.88%
S11	1.89%	1.88%	1.92%	1.95%	2.11%
S12	3.14%	3.12%	3.10%	3.18%	3.22%
S13	10.56%	10.52%	10.48%	10.64%	10.68%
S14	14.05%	14.01%	13.89%	14.15%	14.21%
S15	11.39%	11.28%	11.09%	11.59%	12.20%
S16	8.93%	8.81%	8.62%	8.91%	8.99%

会降低算法的精度, 这是因为预测算法很难在长期预测中保证较高的精度, 造成系统状态的预测值与实际值偏差较大, 故引起优化效果下降。与此同时, 增加预测控制时段意味着引入更多的求解变量与约束, 模型的求解效率将会下降, 因此, 在实际应用中, 需要综合考虑预测精度与求解速度, 确定预测控制时段数, 保证结果的可靠性和计算的实时性。

8 结论

针对大规模 EV 接入下的实时随机充电优化问题, 本文首先提出双层实时调度架构, 根据入网 EV 形成的集群效应建立等效模型, 并提出基于短期预测信息和长期值函数近似的上层实时调度算法实现实时调度指令的分阶段决策, 下层则提出功率分配算法以满足单辆 EV 充电需求, 仿真结果表明:

1) 提出的模型和算法的优化结果既能满足实时性要求, 又能满足单辆 EV 的具体需求, 适用于大规模分布式设备接入背景下分布式设备集群资源的实时动态决策优化。

2) 在不同场景下, 本文提出的算法具备较好的计算精度和较强的鲁棒性, 计算结果相比于 MPC、ADP 算法有一定改善, 适用于求解不确定性系统的实时优化问题。

后续研究将重点考虑系统拓扑对优化结果的影响^[22], 并研究 EV 和储能协调的实时随机运行策略^[23]。

参考文献

- [1] 钱甜甜, 李亚平, 郭晓蕊, 等. 基于时空活动模型的电动汽车充电功率计算和需求响应潜力评估[J]. 电力系统保护与控制, 2018, 46(23): 127-134.
- QIAN Tiantian, LI Yaping, GUO Xiaorui, et al. Calculation of electric vehicle charging power and evaluation of demand response potential based on spatial and temporal activity model[J]. Power System Protection and Control, 2018, 46(23): 127-134.
- [2] 赵俊华, 文福栓, 杨爱民, 等. 电动汽车对电力系统的影响及其调度与控制问题[J]. 电力系统自动化, 2011, 35(14): 2-10.
- ZHAO Junhua, WEN Fushuan, YANG Aimin, et al. Impacts of electric vehicles on power systems as well as the associated dispatching and control problem[J]. Automation of Electric Power Systems, 2011, 35(14): 2-10.
- [3] 胡道栋, 张娟, 克潇, 等. 电动汽车充换电站换电操作

- 管理单元的设计与实现[J]. 电力系统保护与控制, 2017, 45(7): 136-142.
- HU Daodong, ZHANG Juan, KE Xiao, et al. Design and implementation of the battery-swapping operation control unit at the EV charging/swap station[J]. Power System Protection and Control, 2017, 45(7): 136-142.
- [4] 王鑫, 周步祥, 唐浩. 考虑用户因素的电动汽车有序充放电控制策略[J]. 电力系统保护与控制, 2018, 46(4): 129-137.
- WANG Xin, ZHOU Buxiang, TANG Hao. A coordinated charging/discharging strategy for electric vehicles considering customers' factors[J]. Power System Protection and Control, 2018, 46(4): 129-137.
- [5] XU Z, SU W, HU Z, et al. A hierarchical framework for coordinated charging of plug-in electric vehicles in China[J]. IEEE Transactions on Smart Grid, 2017, 7(1): 428-438.
- [6] 潘振宁, 张孝顺, 余涛, 等. 大规模电动汽车集群分层实时优化调度[J]. 电力系统自动化, 2017, 41(16): 96-104.
- PAN Zhenning, ZHANG Xiaoshun, YU Tao, et al. Hierarchical real-time optimized dispatching for large-scale cluster of electric vehicles[J]. Automation of Electric Power Systems, 2017, 41(16): 96-104.
- [7] 潘振宁, 王克英, 瞿凯平, 等. 考虑大量 EV 接入的一气一热多能耦合系统协同优化调度[J]. 电力系统自动化, 2018, 42(4): 104-112.
- PAN Zhenning, WANG Keying, QU Kaiping, et al. Coordinated optimal dispatch of electricity-gas-heat multi-energy system considering high penetration of electric vehicles[J]. Automation of Electric Power Systems, 2018, 42(4): 104-112.
- [8] 潘振宁, 余涛, 王克英. 考虑多方主体利益的大规模电动汽车分布式实时协同优化[J]. 中国电机工程学报, 2019, 39(12): 3528-3541.
- PAN Zhenning, YU Tao, WANG Keying. Decentralized coordinated dispatch for real-time optimization of massive electric vehicles considering various interests[J]. Proceedings of the CSEE, 2019, 39(12): 3528-3541.
- [9] XU Z, HU Z, SONG Y, et al. Risk-averse optimal bidding strategy for demand-side resource aggregators in day-ahead electricity markets under uncertainty[J]. IEEE Transactions on Smart Grid, 2017, 8(1): 96-105.
- [10] ZHAO J, WAN C, XU Z, et al. Risk-based day-ahead

- scheduling of electric vehicle aggregator using information gap decision theory[J]. IEEE Transactions on Smart Grid, 2017, 8(4): 1609-1618.
- [11] 吴鸣, 骆钊, 季宇, 等. 基于模型预测控制的冷热电联供型微网动态优化调度[J]. 中国电机工程学报, 2017, 37(24): 7174-7184.
WU Ming, LUO Zhao, JI Yu, et al. Optimal dynamic dispatch for combined cooling heating and power microgrid based on model predictive control[J]. Proceedings of the CSEE, 2017, 37(24): 7174-7184.
- [12] 张伯明, 陈建华, 吴文传. 大规模风电接入电网的有功分层模型预测控制方法[J]. 电力系统自动化, 2014, 38(9): 6-14.
ZHANG Boming, CHEN Jianhua, WU Wenchuan. A hierarchical model predictive control method of active power for accommodating large-scale wind power integration[J]. Automation of Electric Power Systems, 2014, 38(9): 6-14.
- [13] 李正烁, 郭庆来, 孙宏斌, 等. 计及电动汽车充电预测的实时充电优化方法[J]. 电力系统自动化, 2014, 38(9): 61-68.
LI Zhengshuo, GUO Qinglai, SUN Hongbin, et al. Real-time charging optimization method considering vehicle charging prediction[J]. Automation of Electric Power Systems, 2014, 38(9): 61-68.
- [14] TANG W, ZHANG Y. A model predictive control approach for low-complexity electric vehicle charging scheduling: optimality and scalability[J]. IEEE Transactions on Power Systems, 2017, 32(2): 1050-1063.
- [15] ZHANG L, LI Y. Optimal management for parking-lot electric vehicle charging by two-stage approximate dynamic programming[J]. IEEE Transactions on Smart Grid, 2017, 32(2): 1-9.
- [16] POWELL W B. Approximate dynamic programming: solving the curse of dimensionality[M]. 2nd ed. New York: JOHN WILEY&SONS, INC, 2011.
- [17] POWELL W B, MEISEL S. Tutorial on stochastic optimization in energy — part I: modeling and policies[J]. IEEE Transactions on Power Systems, 2016, 31(2): 1459-1467.
- [18] POWELL W B, MEISEL S. Tutorial on stochastic optimization in energy — part II: an energy storage illustration[J]. IEEE Transactions on Power Systems, 2016, 31(2): 1468-1475.
- [19] 简淦杨, 刘明波, 林舜江. 随机动态经济调度问题的存储器建模及近似动态规划算法[J]. 中国电机工程学报, 2014, 34(25): 4333-4340.
JIAN Ganyang, LIU Mingbo, LIN Shunjiang. Storage modeling and approximate dynamic programming algorithm for stochastic dynamic economic dispatch problems[J]. Proceedings of the CSEE, 2014, 34(25): 4333-4340.
- [20] 梁振成, 韦化, 李凌, 等. 中长期发电计划的值函数近似动态规划方法[J]. 中国电机工程学报, 2015, 35(20): 5199-5209.
LIANG Zhencheng, WEI Hua, LI Ling, et al. A method of value function approximate dynamic programming for medium/long term generation scheduling[J]. Proceedings of the CSEE, 2015, 35(20): 5199-5209.
- [21] 吕仁周, 白晓清, 李佩杰, 等. 基于交替方向乘子法的电动汽车分散式充电控制[J]. 电力系统自动化, 2016, 40(16): 56-63.
LÜ Renzhou, BAI Xiaoqing, LI Peijie, et al. Decentralized charging control of electric vehicles based on alternate direction method of multiplier[J]. Automation of Electric Power Systems, 2016, 40(16): 56-63.
- [22] ZHANG Jing, LIU Chang, YUAN Ruiming, et al. Design scheme for fast charging station for electric vehicles with distributed photovoltaic power generation[J]. Global Energy Interconnection, 2019, 2(2): 150-159.
- [23] ZHANG Yu, HE Yang, WANG Xudong, et al. Modeling of fast charging station equipped with energy storage[J]. Global Energy Interconnection, 2018, 1(2): 145-152.

收稿日期: 2019-02-12; 修回日期: 2019-06-10

作者简介:

王彬(1987—), 男, 博士, 高级工程师, 研究方向为电力系统调度运行、电力市场; E-mail: wangbin_gd@qq.com

郭文鑫(1985—), 男, 硕士, 高级工程师, 研究方向为电力系统调度运行; E-mail: guowenxin@gddd.csg.cn

李世明(1984—), 男, 硕士, 高级工程师, 研究方向为电力系统调度运行。E-mail: 365419377@qq.com

(编辑 张爱琴)