

基于双层优化的电动车与电网实时协同定价机制

王琼, 卢钺, 刘顺, 李清涛, 刘洋, 王洪彪, 刘卫亮

引用本文

王琼, 卢钺, 刘顺, 李清涛, 刘洋, 王洪彪, 刘卫亮. 基于双层优化的电动车与电网实时协同定价机制[J]. 计算机科学, 2024, 51(11A): 240300013-7.

WANG Qiong, LU Yue, LIU Shun, LI Qingtao, LIU Yang, WANG Hongbiao, LIU Weiliang. [Real-time Collaborative Pricing Mechanism of Between Vehicle and Power Grid Based on Bi-level Optimization](#) [J]. Computer Science, 2024, 51(11A): 240300013-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于强化学习考虑电池损耗的电动汽车充放电控制算法](#)

Reinforcement Learning Algorithm for Charging/Discharging Control of Electric Vehicles Considering Battery Loss

计算机科学, 2024, 51(11A): 231200147-7. <https://doi.org/10.11896/jsjx.231200147>

[基于多任务学习的复杂城市遥感图像道路提取](#)

Road Extraction from Complex Urban Remote Sensing Images Based on Multi-task Learning

计算机科学, 2024, 51(11A): 240300095-8. <https://doi.org/10.11896/jsjx.240300095>

[多策略融合改进的斑马优化算法](#)

Zebra Optimization Algorithm Improved by Multi-strategy Fusion

计算机科学, 2024, 51(11A): 240100203-7. <https://doi.org/10.11896/jsjx.240100203>

[基于离散变邻域蜉蝣优化的装配作业车间调度算法](#)

Assembly Job Shop Scheduling Algorithm Based on Discrete Variable Neighborhood Mayfly Optimization

计算机科学, 2024, 51(9): 283-289. <https://doi.org/10.11896/jsjx.230900086>

[基于IMQ惯性权重策略的自适应灰狼优化算法](#)

Adaptive Grey Wolf Optimizer Based on IMQ Inertia Weight Strategy

计算机科学, 2024, 51(7): 354-361. <https://doi.org/10.11896/jsjx.230600181>

基于双层优化的电动车与电网实时协同定价机制

王琼¹ 卢钺² 刘顺² 李清涛² 刘洋² 王洪彪¹ 刘卫亮³

1 国网北京市电力公司 北京 100032

2 国网北京海淀供电公司 北京 100080

3 华北电力大学自动化系 河北 保定 071003

(coycathy@163.com)

摘要 电动车充电行为的非完全竞争性和不完全信息性,以及电力系统的非线性和不确定性,导致电网实时定价问题的建模和求解及其复杂。现有解决方案往往将其建模为一个带约束的优化问题,并且认为效用函数对于电网是已知的,忽略了现实中存在的信息不完全性。为了克服这一局限,在效用函数参数未知的情况下,提出了一种基于双层优化的电动车与电网实时协同定价机制。该机制的创新性在于能够更好地反映电动车充电市场的真实动态;同时,引入电网的潮流方程来反映电网的实时负载。在该模型中,上层模型最大化电网供电商的收益,同时尽可能减小电网的负载压力;下层模型优化电动车充电行为,每一辆电动车的目标是最小化自身的充电成本。通过与固定电价以及峰谷电价情况进行对比,实验仿真数据揭示了所提机制能够更好地平衡电网以及电动车的收益并且增加两者总收益,同时减小电网的负载。

关键词: 智能电网;实时定价;双层优化;优化算法;功率流

中图分类号 TP311

Real-time Collaborative Pricing Mechanism of Between Vehicle and Power Grid Based on Bi-level Optimization

WANG Qiong¹, LU Yue², LIU Shun², LI Qingtao², LIU Yang², WANG Hongbiao¹ and LIU Weiliang³

1 State Grid Beijing Electric Power Company, Beijing 100032, China

2 State Grid Beijing Haidian Power Supply Company, Beijing 100080, China

3 Department of Automation, North China Electric Power University, Baoding, Hebei 071003, China

Abstract Due to the incomplete competition and information on the behavior of electric vehicles, as well as the nonlinearity and uncertainty of power systems, the modeling and solving of real-time pricing problems are highly complex. Existing solutions typically model this as a constrained optimization problem, assuming that the utility function, which is a quantitative representation of the electricity network's economic benefits, is known to the network operators. This overlooks the incomplete information prevalent in actual scenarios. To overcome this limitation, this paper proposes an innovative real-time pricing mechanism for the vehicle-to-grid problem based on a bi-level optimization approach under the condition of unknown utility function parameters. Meanwhile, it considers the power flow equation to reflect the distributed grid's real-time load. This mechanism more accurately reflects the market's real dynamics. In this bi-level model, the upper level represents the optimization problem of the market operators, aiming to maximize their own welfare and minimize the load of the distributed grid. In contrast, the lower level represents the optimization problem of electric vehicles, aiming to maximize their profits or minimize their cost. Through comparative experiment simulations with the fixed pricing and peak-valley pricing methods, the experimental simulation data demonstrates the effectiveness of improving the profit of the grid and vehicles. At the same time, the load of the power grid is reduced.

Keywords Smart grid, Real-time pricing, Bi-level optimization, Optimization algorithm, Powerflow

1 概述

随着用电规模的不断增大,智能电网中的需求侧管理或需求响应已经成为电力系统研究的热点^[1-2]。长期以来,需求侧管理或需求响应的核心目标一直是提高电网效率和降低运行成本^[3]。然而,随着用户对电力质量和供电能力期望的

日益提高,实现这些目标面临着新的挑战:能源资源的有限性和开发新资源的高成本与时间消耗,使得电网的可靠性承受着前所未有的压力。

与此同时,随着电动汽车的不断增多以及电动车入网技术(Vehicle-to-Grid, V2G)的不断发展,电动车的充放电行为对配电网运行的影响越来越大^[26]。电动车可以通过充电行

基金项目:国网北京市电力公司科技项目:电动汽车充电站 V2G/S2G 车网互动及智慧集群调控技术研究及示范(520204220008)

This work was supported by the State Grid Beijing Electric Power Company Technology Project: Research and Demonstration of V2G/S2G Vehicle Network Interaction and Intelligent Cluster Control Technology for Electric Vehicle Charging and Discharging Stations(520204220008).

通信作者:刘卫亮(15933579831@163.com)

为从配电网中获取电量,同时也可以通过放电行为将闲置的电量送入配电网中^[27]。决定电动车充放电行为的关键因素是当前的电价以及电动车当前的电池电量。很显然,在电价较低时,电动车车主充电所需的成本更低;在电价较高时,充电所需的成本更高同时放电给电网的收益更高。与此同时,电动车车主关于充电的决定还受当前电池电量的影响,在电池的电量较低时,无论电价贵与否,车主在有需求的情况下都会选择对电动车进行充电。因此,合理的实时定价策略可以有效地对电动汽车的充放电行为进行调控,从而调节电网的负载,实现更有效的实时需求响应。

电力市场的定价问题一直是影响电网的关键因素^[4-5]。现有的定价通常包含临界峰定价、分时定价、实时定价等定价方案^[9-10,13,15],其中,实时定价可以根据用户实时数据进行反馈,进而计算每一时段的准确价格,因此,实时定价被认为是更适合未来电力市场运行的一种定价机制。实时定价将定价问题建模为一个带有约束的优化问题,其优化目标通常在用户行为约束下最小化电网成本或者最大化电网收益^[13-15,18]。一般情况下,可将该带有约束的优化问题写成对偶形式,基于KKT最优性条件进行求解^[6,16-17]。目前,针对实时定价已有较多研究,例如,文献[7]提出了一种基于效用最大化的实时定价算法,该算法基于智能电表与能源供应商之间的消息交换,并通过控制该信息交换进行实时电价的决策;文献[8]对该方法进行了改进,将二次效用函数替换为对数函数;文献[9]进一步考虑电网负载不确定性对效用最大化的影响,对前述方法进行了扩展;文献[10]提出一种基于收益最大化的实时算法。这些实时定价算法普遍考虑的是先预估下一个时间段的电力负载值,再根据实际的负载值和预估的负载值的差距来调整电价。目前的实时方法通常只考虑短期供需平衡,通过市场清算机制来确定电力的实际交易价格。但是,这种定价方式难以适应负载变化比较灵活的电动车车联网互动场景,并且这些方法往往站在卖方角度考虑而忽略买方需求。优秀的定价策略应该平衡二者的收益,以灵活的定价方式实现二者的双赢。

定价的问题在数学上可以建模为一个斯塔克尔伯格博弈(Stackelberg Game),主方为电网或者供电商,从方为电力消费者^[19,21]。这种基于博弈的定价方法从参与者之间的策略选择和博弈角度出发,通过模拟不同参与者的行为来确定最终的定价策略。它更注重长期策略和参与者之间的互动关系,通过博弈模型来预测和优化市场的运行结果。文献[33]提出了一种电网实时定价的斯塔克尔伯格博弈方法,针对主方采用遗传算法求解,从方使用线性规划求解。文献[34]针对电网实时定价的斯塔克尔伯格博弈方法中的从方提出了一种新颖的满意度函数(Dissatisfaction Function),并且从理论上分析了该问题中斯塔克尔伯格均衡的存在性。与一般的电网负载不同的是,电动车在每一时刻的电量与上一时刻的充放电功率相关,因此在考虑电动车的收益时,应该更加注重长期的收益,因此这种基于博弈的方法更加适合于车联网互动场景。

最近,由于元学习(Meta Learning)、生成式对抗网络(GAN,Generative Adversarial Networks)等技术的不断兴起和发展,针对斯塔克尔伯格博弈的双层优化(Bi-level Optimization)建模逐渐回归人们的视线^[22-25]。双层优化是一种特殊的优化问题,它包含了两个层次的优化任务,一个优化问题嵌

套在另一个优化问题内。通常,外层的优化问题称为上层优化问题,内层的优化问题称为下层优化问题,这两个问题相互耦合,内层问题的最优解是外层问题的约束条件,外层问题的目标函数又依赖于内层问题的解。双层优化问题是 Stackelberg Game 的一种重要的建模方式。目前,双层优化已经被尝试用来解决电力市场中的定价和交易问题,例如,文献[19]提出了一种基于主从博弈双层优化的虚拟电厂动态定价方法。

然而,在现有的大多数电网定价研究中,基于双层优化的工作在求解问题时,往往是将下层问题作为惩罚项加在上层问题中,结合KKT最优性条件,最终将双层优化问题转化为一个单层优化问题来解决^[19]。这种方法通常将实际环境中大量的约束条件抽象为部分数学约束,在实际应用中很难找到理想的映射关系。近年来,研究人员提出了更高效的基于梯度的双层优化算法,大致可分为基于近似隐微分(Approximate Implicit Differentiation, AID)的方法和基于迭代微分(Iterative Differentiation, ITD)的方法^[23]。前者将下层变量看成关于上层变量的隐函数,从而直接计算上层函数的梯度;后者则是基于分步迭代的思想,给定一个上层变量,先使用梯度上升或者下降得到下层问题的一个近似解,再将近似解代入上层问题,使用梯度方法得到上层问题的一个近似解,如此往复。基于梯度的优化方法可以更好地在实际的应用场景下实现,可以直接和各种现有的一阶优化算法相结合,并且保证收敛性。

另一方面,城市的不断发展导致用电量与日俱增,电网的负载越来越大。在这种背景下,在制定电力价格时考虑电网的负载情况是很有必要的。功率流是衡量电网的效率和负载的重要指标^[28]。功率流通常被用于电力系统规划和运行调度等领域,它可以使用电网的潮流方程进行建模,旨在实现经济效益与技术效益的最佳平衡。通过调整发电机输出和节点电压的约束来优化电网的运行。潮流方程需要根据不同的潮流模型来进行建模。常见的潮流模型包括节点潮流模型^[32](Bus Injection Model)、支路潮流模型^[30](Branch Flow Model)以及分布式潮流^[31](Dist Flow Model)。其中,节点潮流模型常用于输电网络中的潮流建模,其基于电压、电流以及当前节点负载的使用情况描述了电网中每一个节点的能量流入流出。而支路潮流模型是一种用于描述电力系统中支路电流和功率之间关系的模型,它考虑了分支电流的相位角差和注入导纳。分布式潮流是一种用于描述分布式电力系统中节点电压和功率之间关系的模型,它是在传统的潮流计算模型基础上针对分布式能源资源进行扩展和改进而得到的。分布式潮流不考虑相位,从而简化了潮流模型。线性分布式潮流方程(Lin Dist Flow)在分布式潮流的基础上不考虑线路损失,这个设置进一步简化了计算过程。与其他的负载衡量指标相比,潮流方程明确考虑了电网的物理结构,包括节点的电压和功率平衡等约束。将潮流方程纳入电网的实时定价问题的考虑中,可以在电网的收益以及负载之间进行有效权衡^[29]。

本文提出了一种基于双层优化 AID 方法的电力市场定价机制,相比已有的工作,本文的主要创新与贡献有以下 3 点。

1)与只考虑电网的收益与发电成本的简单模型相比,本文在供电商的模型中引入了线性分布式潮流方程,在考虑电

网的实际物理模型的同时将电网的实时负载进行了清晰的刻画,使得供电商可以在提高利润和平衡电网负载之间进行有效的权衡。并且,与已有的一些工作相比,本文考虑了电动车的充放电这一具体的应用场景,并且对电动车的电池和效用进行了建模。

2)与传统的双层优化算法相比,本文考虑基于梯度的双层优化 AID 方法,可以通过直接使用梯度优化工具进行求解而无需考虑复杂的 KKT 条件,并且使用辅助变量解决了计算 Hessian 矩阵的逆矩阵的困难,更加适合应用于实际场景中。

3)通过与固定电价以及峰谷定价的对比仿真实验,进一步证明了所提算法对于提升供电商和电动车利润有效性以及能够在电网的收益和负载之间进行权衡的有效性。

2 基于双层优化的电力市场建模

考虑一个具有单个电网供电商和 M 辆电动车构成的电力市场。对于每一辆电动车,假设其实时的充放电功率对于电力供应商是已知的,可以通过局域网和蜂窝网络等通信基础设施与能源供应商进行信息交互。在任意的时间 t 时,供电商预先公布一段长为 K 的时间段的电价之后,电动车充放电的操作的时间周期被划分为 k 个预测时刻, $x_{r,k}$ 表示电动车 $r \in R$ 在第 k 个预测时刻的充放电功率, R 为所有电动车的集合。假设每辆电动车的用电功率是有界的,即 $x_{r,k} \in [\underline{m}_{r,k}, \bar{m}_{r,k}]$,其中 $\underline{m}_{r,k}$ 和 $\bar{m}_{r,k}$ 分别表示电动车 r 在预测时刻 k 允许的最小和最大功率。由于电动车可以在电价高峰时向供电商出售多余电力以谋取利润,因此 $\underline{m}_{r,k}$ 可为负值;最大用电功率表示电动车的最大充电功率。接下来,我们将分别对电动车和供电商进行建模,进而给出最终的定价问题形式。

2.1 电动车建模

电力系统运行中,负载端每个用户都可被看成是一个可以独立运行的实体,用户的用电需求可能由于个体差异或不同的外界因素而发生变化,不同用户对不同价格情景的不同反应可以采用微观经济学中的效用函数概念进行解析建模^[9-10]。在 V2G 场景下,用户考虑具有充放电功能的电动汽车。

对于电动车的电池模型,这里考虑线性的电池模型,即:

$$SoC_{r,k+1} = SoC_{r,k} + \xi_r \cdot x_{r,k} \cdot \Delta t \quad (1)$$

其中, $SoC_{r,k}$ 表示在预测时刻 k 电动车 r 的电池电量百分比(State of Charge),必须满足其取值范围 $[0, 1]$; Δt 表示一个时间步的默认时长; ξ_r 表示电动车 r 的充电效率。在每一个绝对时刻 t , $SoC_{r,0} = SoC_r(t)$ 定义了电动车电池的初始状态。通过将初始状态代入式(1)并进行递归推导,可以得到任意预测时刻 k 时 $SoC_{r,k}$ 的表达式为:

$$SoC_{r,k} = SoC_r(t) + \xi_r \cdot \Delta t \cdot \sum_{\tau=0}^{k-1} x_{r,\tau} \quad (2)$$

本文建模采用模型预测控制的思路,在每一个时间步 t , 供电商会预测下 K 个时刻的电价并传给用户。每一个用户根据电价和效用函数来作出充放电的决策。对于每个用户,效用函数表示将用户的满意程度映射到其功耗的函数,该满意度包含用户的里程焦虑和充电焦虑等。其会随着外界因素以及自身的电池电量的改变而动态变化,但该参数对于供电商而言是未知的。使得效用函数最大的功耗值,代表用户在当前条件下的功耗需求。在预测时刻 k , 对于电动车 r , 为了

保证函数的连续性并且结合实际情况,本文考虑具有边际效益的对数效用函数。

$$U_{1,r}(x_{r,k}, \omega_{r,k}) = \omega_{r,k} \ln(1 + x_{r,k}) \quad (3)$$

其中, $\omega_{r,k}$ 是用户 r 在预测时刻 k 的个性化参数,电动车在 k 时刻以 T_k 元每千瓦时的价格消耗 $x_{r,k} \cdot \Delta t$ 千瓦的电力。因此,将用电费用考虑进收益函数,电动车 r 在预测时刻 k 的成本可以表示为:

$$U_{2,r}(x_{r,k}, T_k) = x_{r,k} \cdot T_k \cdot \Delta t \quad (4)$$

其中, $U_{2,r}(x_{r,k}, T_k)$ 为用户 r 的成本函数, T_k 是每千瓦时电力的价格,满足 $T_k \in [\underline{T}_k, \bar{T}_k]$, $\underline{T}_k, \bar{T}_k$ 表示电价的下限和上限,因为电价不能无限制地变化,应由供电商根据上一时刻的用户反馈决定。在这里,假设成本函数对于每一个用户都是已知的,即每一个用户都可以根据自己的收益函数,结合当前的电力价格,选择使得自身成本函数尽可能小的功耗值。如前文所述,功耗为负值表示电动车出售电力给供电商。假设在同一个时间步中电动车购买和出售电量的价格相同,对于每一个公布的价格值 T_k , 每个用户 r 都试图调整自己的电力消耗 $x_{r,k}$ 以使自己的收益最大化。

结合式(1)一式(4),同时考虑 $SoC \in [0, 1]$ 的取值范围约束,可以得到在 k 时刻电动车 r 的总收益函数为:

$$\begin{aligned} W_r(\{x_{r,\tau}\}_{\tau=0}^k, T_k) \\ = U_{1,r}(x_{r,k}, \omega_{r,k}) - U_{2,r}(x_{r,k}, T_k) + \gamma \cdot (\log(SoC_{r,k}) + \\ \log(1 - SoC_{r,k})) \end{aligned} \quad (5)$$

其中, $\log(SoC_{r,k}) + \log(1 - SoC_{r,k})$ 为一个惩罚项,目的是将 $SoC_{r,k}$ 的取值限制在 $[0, 1]$ 范围内。 γ 表示惩罚项的系数。可以看到,总收益是一个与前面所有预测时刻的功率相关的函数,这是因为电动车在当前时刻的 SoC 与上一个时刻相关,因此需要考虑当前时刻前面每一个时间步的功率。可以通过凸函数的二阶条件判断, $W_r(\{x_{r,\tau}\}_{\tau=0}^k, T_k)$ 的二阶导数恒为负值,说明它是一个凹函数。同时,也可以根据强凹函数和光滑的定义判断 $W_r(\{x_{r,\tau}\}_{\tau=0}^k, T_k)$ 是强凹以及利普席茨光滑的。

2.2 供电商建模

在制定电价时,一个重要的参考就是当前电网的负载量。由于大部分的用户具有价格敏感性,倾向于在价格较低时充电。通过合理地制定电价,供电商可以有效地调整电网的负载,实现电网的安全稳定运行。用户的充放电行为通过作用在所连接的对应的配电网节点的有功功率来反映到整个电网的功率平衡中。由于阻抗以及传输损耗等,配电网上的不同节点对配电网的影响能力不同。因此,将配电网的物理模型考虑进来是必要的。在这里,我们通过建立潮流方程来表示电网的物理模型。考虑一个辐射形电网 $G = (\mathcal{N}, \mathcal{E})$, 其中 \mathcal{N} 和 \mathcal{E} 分别为电网上节点和支路的集合, $|\mathcal{N}| = N + 1$, $|\mathcal{E}| = N$ 。对于预测时刻 k 的分布式潮流方程(DistFlow), 令 $l_{nj} = |I_{nj}|^2$, $v_n = |V_n|^2$, 其中 I_{nj}, V_i 分别表示支路 (n, j) 的电流以及节点 i 的电压。得到:

$$\begin{aligned} p_j(k) &= P_{j_n}(k) + P_{agg_j}(k) - \sum_{h \in \pi_j} (P_{hj}(k) - r_{hj} l_{hj}(k)), \\ &\quad \forall j \in \mathcal{N} \\ q_j(k) &= Q_{j_n}(k) - \sum_{h \in \pi_j} (Q_{hj}(k) - s_{hj} l_{hj}(k)), \quad \forall j \in \mathcal{N} \\ l_{nj}(k) &= \frac{P_{nj}^2(k) + Q_{nj}^2(k)}{v_n(k)} \end{aligned}$$

$$v_j(k) = v_n(k) - 2(r_{nj}P_{nj}(k) + x_{nj}Q_{nj}(k)) + (r_{nj}^2 + s_{nj}^2)l_{nj}(k)$$

其中, p_j 和 q_j 分别表示在节点 j 注入的有功和无功功率, $P_{jn}(k)$ 和 $Q_{jn}(k)$ 分别表示预测时刻 k 支路 (j, n) 的有功和无功功率, r_{hj} 和 s_{hj} 分别表示表示预测时刻 k 支路 (h, j) 的电阻和电抗, $P_{agg_j}(k)$ 表示预测时刻 k 连接到节点 j 的聚合器的充电功率, π_j 表示节点 j 的子节点。在分布式潮流方程的基础上, 进一步假设电网中的线路损耗为 0, 即 $l_{ij} = 0, \forall j, i \in \mathcal{N}$ 。这样就得到了线性分布式潮流方程(LinDistFlow):

$$p_j(k) = P_{jn}(k) + P_{agg_j}(k) - \sum_{h \in \pi_j} P_{hj}(k), \forall j \in \mathcal{N}$$

$$q_j(k) = Q_{jn}(k) - \sum_{h \in \pi_j} Q_{hj}(k), \forall j \in \mathcal{N}$$

$$v_j(k) = v_n(k) - 2(r_{nj}P_{nj}(k) + s_{nj}Q_{nj}(k))$$

同时, 对于电网上的根节点(Substation), 其满足:

$$p_0(k) = P_{agg_0}(k) - \sum_{h \in \pi_0} (P_{h0}(k))$$

$$q_0(k) = - \sum_{h \in \pi_0} Q_{h0}(k)$$

$$v_0(k) = 0$$

其中, $r_{hj} = r_{jh}, P_{nj}(k) = -P_{jn}(k)$ 。聚合器上连接着许多电动车, 其有功功率等于所有连接到聚合器的电动车的有功功率之和。对于在 k 时刻的节点 j 而言, 有:

$$P_{agg_j}(k) = \sum_{r \in N_j} x_{r,k} \quad (7)$$

其中, P_0 表示节点 b 上一些固有电器的功率, 比如冰箱等, 这里考虑它是一个常量; N_j 表示与节点 j 相连的电动车。为了将这个线性的潮流方程纳入定价问题的考虑中, 将它作为惩罚项加在供电商成本函数的后面, 通常称为基于潮流限制的成本问题。为了问题表达的简明性, 令 x_k 表示预测时刻 k 所有电动车的功率的向量, 并且设本文中后面出现的粗体变量都为向量。惩罚项形式为:

$$M_k(x_k, p(k), q(k)) = \sum_{j=1}^N (\max\{0, \underline{v}_j(k) - v_j(k)\} + \max\{0, v_j(k) - \bar{v}_j(k)\}) \quad (8)$$

其中, $\underline{v}_j(k)$ 和 $\bar{v}_j(k)$ 分别是 k 时刻节点 j 的电压的最小和最大允许值。这个惩罚项的含义是, 如果某个节点的电压超过了允许范围, 就会对目标函数产生一定的惩罚。同时, 这里的 $p(k), q(k)$ 也有约束, 即 $p(k) \in [\underline{p}(k), \bar{p}(k)], q(k) \in [\underline{q}(k), \bar{q}(k)]$, 其中 $\underline{p}(k), \bar{p}(k), \underline{q}(k), \bar{q}(k)$ 分别表示 k 时刻所有节点有功功率和无功功率的下限和上限。

如前文所述, 在第 k 个预测时刻, 电力系统供电商制定的电价为 T_k , 通过电价, 供电商可以间接对消费者的用电量进行一定的调控, 进而控制电网负荷, 最终实现在尽可能最大化自身收益的同时, 保证电网的安全稳定运行。由此可见, 合适的电价可以使消费者与供电商实现双赢。供电商生产电力需要花费成本, 基于文献[10], 本文采用二次成本函数:

$$C_k(p(k)) = \sum_{j \in \mathcal{N}} a_k p_j^2(k) + b_k p_j(k) + c_k$$

其中, a_k, b_k, c_k 为 k 预测时刻的成本系数。这样, 供电商在 k 预测时刻的整体利润可以表示为:

$$Q_k(x_k, p(k), q(k), T_k) = T_k \cdot \Delta t \cdot \sum_{r=1}^M x_{r,k} - C_k(p(k)) - \alpha \cdot M_k(x_k, p(k), q(k)) \quad (12)$$

其中, α 是调节惩罚程度的参数, $p(k), q(k)$ 分别是 k 预测时刻所有节点的有功功率和无功功率构成的向量。通过调整 α 的值, 可以控制潮流限制对目标函数的影响程度, 从而在收益和电网负载之间进行权衡。

2.3 定价问题建模

在得到电动车和供电商的建模之后, 我们将电力市场中的定价问题建模为一个双层优化问题。其中, 上层问题为供电商的所有时间步的利益函数之和最大化; 下层问题为所有电动车的每一个时间步利益函数之和最大化。考虑到电动车之间的利益没有耦合性, 该问题可以表示为:

$$\begin{aligned} & \text{Maximize } \Phi(p, q, T) = Q(x^*(T), p, q, T) \\ & \quad (T, p, q) \in \mathcal{B} \\ & = \sum_{k=1}^K Q_k(x_k, p(k), q(k), T_k) \\ & \text{s. t. } x^*(T) = \operatorname{argmax}_x W(x(T), T) \end{aligned}$$

其中, $W(x(T), T) = \sum_{r=1}^M \sum_{k=1}^K W_{r,k}(\{x_{r,t}\}_{t=1}^k, T_k)$ 。 $x^*(T)$ 表示所有电动车的用电量的集合, 它本质上是一个关于电价 T 的隐函数, T 电价构成的向量, 里面的每一个元素为每一个时刻的电价。 \mathcal{B} 是一个约束的集合, 包含了 T, p, q 的上下限的约束, 即 $T_k \in [\underline{T}_k, \bar{T}_k], p(k) \in [\underline{p}(k), \bar{p}(k)], q(k) \in [\underline{q}(k), \bar{q}(k)], k=1, \dots, K$ 。该问题是一个双层优化问题, 下层函数的最优解由上层问题的电价 T 所决定, 同时下层问题的用电量 $x^*(T)$ 也会影响上层的电价制定。通过求解该问题, 供电商可以制定合理的电价, 在收益和电网的压力之间进行权衡, 用户也可以最大化自身的收益, 实现供电商和用户的双赢。可以看到, 在这个双层优化问题中, 上层和下层的变量在时间和空间上都具有很强的耦合关系, 因此这个问题很难使用一般的优化方法求解。通过使用正则函数将下层问题的不等式约束作为惩罚项, 这个问题表示为如下形式:

$$\begin{aligned} & \text{Maximize } \Phi(p, q, T) = Q(x^*(T), p, q, T) \\ & \quad (p, q, T) \in \mathcal{B} \\ & \text{s. t. } x^*(T) = \operatorname{argmax}_x W(x(T), T) \end{aligned}$$

该问题本质上是一个混杂着双层优化和滚动优化(Receding Horizon)的复杂优化问题, 下面将介绍本文所提出的该问题的求解算法。

3 基于双层优化的实时定价算法

3.1 双层优化求解

在 2.3 节中, 我们将定价问题建模为一个双层优化问题, 由于上下层问题的相互嵌套耦合, 传统优化方法难以解决该问题, 基于梯度的 AID 双层优化是求解该双层优化问题的典型方法。相比 ITD 算法, AID 的收敛性能够更好地得到保证。在这个过程中, 需要计算上层的目标函数对于下层变量的偏导数 $\frac{\partial \Phi(p, q, T)}{\partial T}$ 。然而, 由于 $x(T)$ 本质上是电价 T 的一个隐函数, 这个偏导数包含复杂的结构。在求解问题之前, 先对问题进行分析。上层问题是一个强凹性的函数, 下层问题也是一个强凹性的函数, 同时它们也都是利普希思光滑的, 意味着可以直接对函数进行求导操作, 这给分析带来了很大便利。并且, 因为 p, q 与 $x(T)$ 和 T 无关, 所以在对 T 求导时可以忽略这两个变量。基于上面的定义, 我们给出命题 1。

命题 1 偏导数 $\frac{\partial \Phi(p, q, T)}{\partial T}$ 的形式为:

$$\begin{aligned} \frac{\partial \Phi(p, q, T)}{\partial T} &= \frac{\partial Q(x^*(T), p, q, T)}{\partial T} - \frac{\partial^2 W(x^*(T), T)}{\partial T \partial x(T)} \cdot \\ & \quad \left(\frac{\partial^2 W(x^*(T), T)}{\partial x(T)^2} \right)^{-1} \frac{\partial Q(x^*(T), p, q, T)}{\partial T} \end{aligned}$$

其中, $\frac{\partial^2 W(x^*(T), T)}{\partial T \partial x(T)}$ 表示下层函数的 Jacob 矩阵,

$\frac{\partial^2 W(\mathbf{x}^*(\mathbf{T}), \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})^2}$ 是下层函数的 Hessian 矩阵。注意,由于下层函数 $W(\mathbf{x}(\mathbf{T}), \mathbf{T})$ 是一个强凹性的函数,因此它的 Hessian 矩阵是可逆的。

证明:

$$\frac{\partial \Phi(\mathbf{p}, \mathbf{q}, \mathbf{T})}{\partial \mathbf{T}} = \frac{\partial Q(\mathbf{x}^*(\mathbf{T}), \mathbf{p}, \mathbf{q}, \mathbf{T})}{\partial \mathbf{T}} + \frac{\partial Q(\mathbf{x}^*(\mathbf{T}), \mathbf{p}, \mathbf{q}, \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})} \frac{d\mathbf{x}(\mathbf{T})}{d\mathbf{T}}$$

根据 $\mathbf{x}^*(\mathbf{T})$ 是下层问题的最优解的一阶最优性条件,可以得到 $\frac{\partial W(\mathbf{x}^*(\mathbf{T}), \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})} = 0$, 再根据隐函数的微分定理,可以得到:

$$\frac{\partial^2 W(\mathbf{x}^*(\mathbf{T}), \mathbf{T})}{\partial \mathbf{T} \partial \mathbf{x}(\mathbf{T})} + \frac{\partial^2 W(\mathbf{x}^*(\mathbf{T}), \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})^2} \frac{d\mathbf{x}(\mathbf{T})}{d\mathbf{T}} = 0$$

即:

$$\frac{d\mathbf{x}(\mathbf{T})}{d\mathbf{T}} = - \left(\frac{\partial^2 W(\mathbf{x}^*(\mathbf{T}), \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})^2} \right)^{-1} \frac{\partial^2 W(\mathbf{x}^*(\mathbf{T}), \mathbf{T})}{\partial \mathbf{T} \partial \mathbf{x}(\mathbf{T})}$$

将所得到的式子代入上式,可以得到命题 1 的形式。至此,命题 1 得证。

由于超梯度涉及二阶导数矩阵的逆矩阵计算,并且其高计算复杂度以及需要满足正定性的严格条件,这在实际的求解过程中往往是难以实现的,因此使用基于一阶泰勒级数展开的线性近似方法来近似计算二阶导数的逆和导数的乘积。将二者看作一个整体来进行近似,从而避免直接计算 Hessian 矩阵的逆矩阵。如命题 2 所示。

命题 2 引入辅助变量 v_k , 可以将该偏导数的形式改为:

$$\frac{\partial \Phi(\mathbf{p}, \mathbf{q}, \mathbf{T})}{\partial \mathbf{T}} = \frac{\partial Q(\mathbf{x}^*(\mathbf{T}), \mathbf{p}, \mathbf{q}, \mathbf{T})}{\partial \mathbf{T}} - \frac{\partial^2 W(\mathbf{x}^*(\mathbf{T}), \mathbf{T})}{\partial \mathbf{T} \partial \mathbf{x}(\mathbf{T})} v^*$$

其中, v^* 是如下线性系统的解:

$$\frac{\partial^2 W(\mathbf{x}^*(\mathbf{T}), \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})^2} v = \frac{\partial Q(\mathbf{x}^*(\mathbf{T}), \mathbf{p}, \mathbf{q}, \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})}$$

通过引入辅助变量,无需计算二阶导数的逆,从而可以更方便地进行求解。文献[23]证明了该方法的收敛性。

3.2 实时定价算法

在上面的两个命题中,我们都需要使用下层问题的精确解来计算,这在现实问题中往往是难以实现或者低效率的。因此,我们使用 D 步梯度上升来获得下层问题的近似解 $\mathbf{x}^D(\mathbf{T})$ 来代替精确解 $\mathbf{x}^*(\mathbf{T})$, 使用 B 步梯度下降得到 v^* 的近似解 v^B 。文献[23]中证明,使用所得到的近似解与使用真实解对于上层问题的求解的误差是有界的。在得到梯度之后,为了满足变量的约束条件,通过投影梯度上升方法对上层问题进行迭代求解。在这里,我们给出求解算法 1。算法的具体流程图如图 1 所示,其中 $\mathbf{T}^k[0]$ 表示第一个时间步的电价向量的第一个元素。在每一个时间步,供电商公布后面 K 步的电价,下层的用户在收到电价之后根据自身的收益函数进行充放电决策,并且将功耗 $\mathbf{x}^D(\mathbf{T}^k)$ 和辅助变量 v_k^B 的值传回给供电商。供电商根据返回的 $\mathbf{x}^D(\mathbf{T}^k)$ 和 v_k^B 进行梯度上升迭代得到下一个时刻的电价向量 \mathbf{T}^{k+1} , 并且为了满足变量的约束条件,使用了投影梯度下降法。可以看到,该算法相比传统的求解双层优化问题的算法更加简单,并且避免了直接计算矩阵的逆矩阵的问题,提高了求解的稳定性和效率。并且,其基于梯度的优化方法也可以适用于许多现有的求解器,更加具有实用价值。

算法 1 基于 AID 的实时定价算法

1. 固定上层的变量 \mathbf{T}^k , 对于下层问题进行 D 步的梯度上升, 对 $t = 1, \dots, D$: $\mathbf{x}^t(\mathbf{T}^k) = \mathbf{x}^{t-1}(\mathbf{T}^k) + \eta \nabla_{\mathbf{x}(\mathbf{T})} W(\mathbf{x}^{t-1}(\mathbf{T}^k), \mathbf{T}^k)$, 获得下层问题的近似解 $\mathbf{x}^D(\mathbf{T}^k)$, 若 $\mathbf{x}^D(\mathbf{T}^k)$ 中的每一个元素超出 $[\underline{m}_{r,k}, \bar{m}_{r,k}]$, $r = 1, \dots, M$, 则将其缩放到这个区间。
2. 通过 B 步的梯度下降求解线性方程 $\frac{\partial^2 W(\mathbf{x}^D(\mathbf{T}^k), \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})^2} v_k = \frac{\partial Q(\mathbf{x}^D(\mathbf{T}^k), \mathbf{p}, \mathbf{q}, \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})}$ 获得辅助变量 v_k 的近似值 v_k^B , 即对于 $t = 1, \dots, B$: $v_k^t = v_k^{t-1} - \eta \frac{\partial^2 W(\mathbf{x}^D(\mathbf{T}^k), \mathbf{T})}{\partial \mathbf{x}(\mathbf{T})^2} v_k^t$
3. 计算偏导数 $\frac{\partial \Phi(\mathbf{p}, \mathbf{q}, \mathbf{T}^k)}{\partial \mathbf{T}} = \frac{\partial Q(\mathbf{x}^D(\mathbf{T}^k), \mathbf{p}, \mathbf{q}, \mathbf{T})}{\partial \mathbf{T}} - \frac{\partial^2 W(\mathbf{x}^D(\mathbf{T}^k), \mathbf{T})}{\partial \mathbf{T} \partial \mathbf{x}(\mathbf{T})} v_k^B$
4. 用投影梯度上升法更新下一步上层变量 $\mathbf{T}^{k+1} = \text{proj}_{\mathcal{B}} \left(\mathbf{T}^k + \eta \frac{\partial \Phi(\mathbf{p}, \mathbf{q}, \mathbf{T}^k)}{\partial \mathbf{T}} \right)$, $\mathbf{p}(k+1) = \text{proj}_{\mathcal{B}} \left(\mathbf{p}(k) + \eta \frac{\partial \Phi(\mathbf{p}(k), \mathbf{q}(k), \mathbf{T}^k)}{\partial \mathbf{p}} \right)$, $\mathbf{q}(k+1) = \text{proj}_{\mathcal{B}} \left(\mathbf{q}(k) + \eta \frac{\partial \Phi(\mathbf{p}(k), \mathbf{q}(k), \mathbf{T}^k)}{\partial \mathbf{q}} \right)$
5. 转到下一个时间步, 重复以上步骤

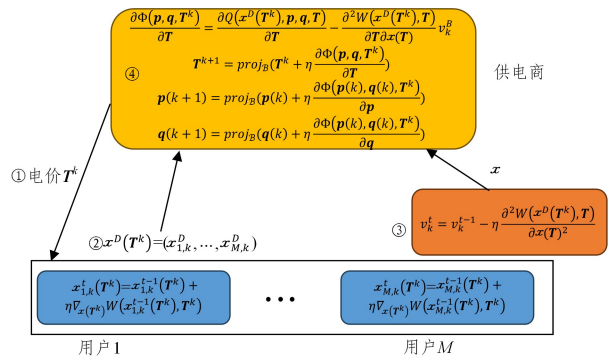


图 2 算法流程图例

Fig. 2 Algorithm flowchart

4 实验与仿真

4.1 实验参数设置

我们将一天划分为 24 个时间步, $K = 24, \Delta t = 1 \text{ h}$, 对于供电商的成本函数的参数, 取 $a_k = 0.01, b_k = 0, c_k = 0$ 。对于用户的效用函数, $\omega_{r,k} \in [1, 4]$ 在不同的时间步随机选取, 但在一个时间步长内不会发生变化, 且其功耗范围满足 $m_{r,k} = -5, M_{r,k} = 20$ 。对于每一辆电动车, 我们假设其型号相同, 即所有车的电池容量、充放电效率以及功率的边界约束相同。在每天开始时初始化电动车的电池电量比例 $\text{SoC}_{r,0} = 0.5$, 惩罚系数 $\gamma = 0.1, \alpha = 0.1, 0.2$ 。学习率 $\eta = 0.001$ 。对于实时定价实验, 使用所提出的 AID 算法。对于固定电价, 设定电价固定为初始功耗响应的最优值, 并且用户在每一个时刻也会根据当前的效用函数的参数和电价做出最优响应。对于峰谷电价, 考虑最常见的设置, 即在白天高峰时段 7-18 点为高峰电价, 其他时间为低谷电价, 高峰电价是低谷电价的两倍。我们使用了 python 进行了 24 h 的仿真实验, 并且使用 pypower 建模电网模型。针对于电网模型, 本文考虑 IEEE-15 bus 的电网模型, 其结构如图 3 所示。所有的电动车随机初始化连接在某一个节点上, 并且在一天之内所连接的节点位置不会发生变化。




图3 电网结构图

Fig. 3 Structure of IEEE-15 bus grid

4.2 实验结果与分析

实验结果如图4—图6所示。其中,图4给出了每一个时间步骤的供电商利益;图5给出了每一个时间步的总利益,即供电商的利益加上用户的利益;图6给出了每一个时间步的电价。本文考虑的所有收益都是指与电动车相关的收益,而不考虑电网上的其他负载。可以看到,对于实时定价,电价在每一个时间步会进行调整,在最初的时候变化较大,后面逐渐稳定。对于绝大部分时间步,无论是供电商的利益还是全局利益,实时定价算法都取得了更好的效果。但是,由于算法的近似误差以及梯度方法迭代轮次和学习率的偏差,可能会在某些时间步由于陷入局部最优或者在最优点周围振荡从而使得性能变差。表1列出了不同设置下不同定价方式的总收益和总负载。可以看到,所提出的实时定价方法在收益和负载上都取得了更好的效果,并且,通过调整惩罚系数,可以有效地在收益和电网负载之间进行权衡。




图4 供电商收益随时间的变化

Fig. 4 Electrical supplier earnings over time




图5 总收益随时间的变化

Fig. 5 Total earnings over time




图6 电价随时间的变化

Fig. 6 Price changes over time

表1 不同设置下的总收益和电网负载

Table 1 Global profit and load of grid under different setting

	实时电价	峰谷电价	固定电价
24h 总收益/元($\alpha=0.1$)	69.46	59.12	20.72
24h 总负载/kW($\alpha=0.1$)	195	202	276
24h 总收益/元($\alpha=0.2$)	43.12	32.67	9.62
24h 总负载/kW($\alpha=0.2$)	102.1	113.54	130.92

结束语 本文提出了一种基于双层优化 AID 方法的电力市场定价算法。与之前的一些方法相比,本文通过引入潮流方程将电网的负载加入成本中,更加符合实际情况。同时, AID 方法可以直接使用梯度方法求解双层优化问题而不需要使用传统的优化求解器,求解的速度和简洁性大大提高。同时,仿真实验表明,所提出的算法可以实现实时的动态定价,并且比固定电价方法和峰谷电价方法实现了更高的供电商收益以及总收益。在未来,可以使用更加高效和智能的梯度算法(如最速梯度下降算法、共轭梯度下降算法)来代替传统的梯度下降算法,并且可以动态的调整学习率,使得问题快速收敛并且不会在最优点附近震荡。从现实考虑,用户个人不会有明确的收益函数,因此在未来可以考虑使用神经网络来对用户和供应商进行精确的建模。

参考文献

- [1] WANG Y, YANG Z F, YU J, et al. Pricing in non-convex electricity markets with flexible trade-off of pricing properties[J]. Energy, 2023, 274: 127382.
- [2] FOGSTAD M D, KJERSTI B, SIGURD B, et al. Local electricity market pricing mechanisms' impact on welfare distribution, privacy and transparency[J]. Applied Energy, 2023, 341: 121112.
- [3] AMOUNTZIAS C, DAGDEVIREN H, PATOKOS T. Pricing decisions and market power in the UK electricity market: A VECM approach[J]. Energy Policy, 2017, 108: 467-473.
- [4] DEY B, BHATTACHARYYA B. Comparison of various electricity market pricing strategies to reduce generation cost of a microgrid system using hybrid WOA-SCA[J]. Evolutionary Intelligence, 2021, 15(3): 1587-1604.
- [5] SHIRI A, AFSHAR M, RAHIMI-KIAN A, et al. Electricity price forecasting using Support Vector Machines by considering oil and natural gas price impacts[C]// IEEE International Conference on Smart Energy Grid Engineering. IEEE, 2015.
- [6] HOGAN W W. Electricity market design: Multi-interval pricing models[J]. Harvard University, 2002.
- [7] SAMADI P, MOHSENIAN-RAD A H, SCHOBBER R, et al. Optimal Real-Time Pricing Algorithm Based on Utility Maximization for Smart Grid[C]// 2010 First IEEE International Conference on Smart Grid Communications(SmartGridComm). IEEE, 2010.
- [8] SONG X, QU J. An improved real-time pricing algorithm based on utility maximization for smart grid[C]// Proceeding of the 11th World Congress on Intelligent Control and Automation, 2023.
- [9] TARASAK P. Optimal real-time pricing under load uncertainty based on utility maximization for smart grid[C]// IEEE International Conference on Smart Grid Communications. IEEE, 2011.
- [10] AHMADZADEH S, YANG K. Optimal Real Time Pricing Based on Income Maximization for Smart Grid[C]// IEEE International Conference on Computer & Information Technology

- Ubiquitous Computing & Communications Dependable. IEEE, 2015.
- [11] LI W, BECKER D M. Day-ahead electricity price prediction applying hybrid models of LSTM-based deep learning methods and feature selection algorithms under consideration of market coupling[J]. arXiv:2101.05249, 2021.
- [12] HOGAN W W. Electricity market design: Market models for coordination and pricing[J/OL]. Energy Information Administration, 2008. https://www.eia.gov/conference/2008/conf_pdfs/Tuesday/Hogan.pdf. https://www.eia.gov/conference/2008/conf_pdfs/Tuesday/Hogan.pdf.
- [13] LI X G, YAN M S, XIE X Y. Inducing Mechanism of Three Pricing Methods on Bidding Strategies of Power Generation Companies[J]. Automation of Electric Power Systems, 2003(5): 20-25.
- [14] LUO Y H, XING L D, WANG Q, et al. Least Squares Estimation of Parameter in Peak-Valley Time-of-Use Electricity Price User Response Model[J]. East China Electric Power, 2009, 37(1): 67-69.
- [15] YUAN G X, GAO Y, WANG H J. Real-time Electricity Price Algorithm for Smart Grid Based on Utility Classification[J]. Journal of University of Shanghai for Science and Technology, 2020, 42(1): 29-35.
- [16] HUANG H T, HU X Y, LI X, et al. Practical Incentive-based Optimal Compensation Pricing Model for Interruptible Loads [J]. Power System Technology, 2014, 38(8): 2149-2154.
- [17] ZHANG L Z, LI Y A, LI G H, et al. Discussion on the Reactive Power Pricing Method in Power Generation Side Electricity Market[J]. Electric Power in China, 2002(1): 32-36.
- [18] LUO Y H, XING L D, WANG Q, et al. Overview of User Response Modeling and Pricing Decision in Peak-Valley Time-of-Use Electricity Price[J]. East China Electric Power, 2008(6): 24-27.
- [19] DONG L, TU S Q, LI Y, et al. Dynamic Pricing and Energy Management of Multi-Virtual Power Plants Based on Meta-model Optimization Algorithm in Master-Slave Game[J]. Power System Technology, 2020, 44(3): 973-983.
- [20] ZENG Q Y. Pricing Mechanism of Wholesale Electricity Market with Demand-side Participation[J]. Power System Technology, 2004(17): 6-10.
- [21] SHU Z, MEI S, WANG P W. The Game-Theoretic Approach to Pricing in China's Semi-Deregulated Electricity Market[J]. Advanced Materials Research, 2013, 2694: 805-806.
- [22] JI K, YING L. Network utility maximization with unknown utility functions: A distributed, data-driven bilevel optimization approach[J]. arXiv:2301.01801, 2023.
- [23] JI K, YANG J, LIANG Y. Bilevel optimization : Convergence analysis and enhanced design[C]// International Conference on Machine Learning. PMLR, 2021: 4882-4892.
- [24] LIU R, LIU X, ZENG S, et al. Value-function-based sequential minimization for bi-level optimization [J]. arXiv: 2110.04974, 2021.
- [25] LIU R, LIU X, YUAN X, et al. A value-function-based interior-point method for non-convex bi-level optimization[C]// International Conference on Machine Learning. PMLR, 2021: 6882-6892.
- [26] CLEMENT-NYNS K, HAESEN E, DRIESEN J. The impact of charging plug-in hybrid electric vehicles on a residential distribution grid [J]. IEEE Transactions on Power Systems, 2009, 25(1): 371-380.
- [27] KEMPTON W, TOMIĆ J. Vehicle-to-grid power implementation: From stabilizing the grid to supporting large-scale renewable energy[J]. Journal of Power Sources, 2005, 144(1): 280-294.
- [28] LOW S H. Convex relaxation of optimal power flow—Part I: Formulations and equivalence[J]. IEEE Transactions on Control of Network Systems, 2014, 1(1): 15-27.
- [29] GAN L, TOPCU U, LOW S H. Optimal decentralized protocol for electric vehicle charging[J]. IEEE Transactions on Power Systems, 2012, 28(2): 940-951.
- [30] FARIVAR M, LOW S H. Branch flow model: Relaxations and convexification—Part I[J]. IEEE Transactions on Power Systems, 2013, 28(3): 2554-2564.
- [31] WANG D, TURITSYN K, CHERTKOV M. DistFlow ODE: Modeling, analyzing and controlling long distribution feeder [C]// 2012 IEEE 51st IEEE Conference on Decision and Control (CDC). IEEE, 2012: 5613-5618.
- [32] CHAKRABARTI A, HALDER S. Power system analysis: operation and control[M]. PHI Learning Pvt. Ltd., 2022.
- [33] MENG F L, ZENG X J. A Stackelberg game-theoretic approach to optimal real-time pricing for the smart grid[J]. Soft Computing, 2013, 17: 2365-2380.
- [34] YU M, HONG S H. A real-time demand-response algorithm for smart grids: A stackelberg game approach[J]. IEEE Transactions on Smart Grid, 2015, 7(2): 879-888.
- [35] WANG Y, MA Z M, TAN Y K, et al. Day-ahead power market design and market simulation in Guangdong province[J]. Power Demand Side Management, 2018, 20(1): 10-14.
- [36] WEI X M, YU K, CHEN X Y, et al. Analysis of power large user segmentation based on Affinity propagation and K-means algorithm[J]. Power Demand Side Management, 2018, 20(1): 15-19, 35.
- [37] ZHOU L, WU H, JI W L, et al. Vulnerability pre-assessment method for microgrid [J]. Power Demand Side Management, 2018, 20(1): 20-24.



WANG Qiong, born in 1983, Ph.D candidate, engineer. Her main research interests include development of software and hardware for charging stations and power-side infrastructure, alongside the integration of advanced security initiatives in

vehicle networking platforms.



LIU Weiliang, born in 1983, Ph.D, associate professor. His main research interests include modeling, simulation and optimal control of integrated energy system.