

基于ADMM的智能电网电力调度优化 分布式在线算法

赵峰*, 党亚铮

上海理工大学, 上海

收稿日期: 2021年12月15日; 录用日期: 2022年1月18日; 发布日期: 2022年1月25日

摘要

近年来,随着电网相关参与者和研究人员对智能电网的研究越来越深入,电网的电力调度优化上仍存在很多值得深入研究的方向。本文研究了在智能电网环境中电力调度的分布式算法。在本文中,我们首先介绍电力调度优化问题是凸优化问题,它主要由三个关键因素构成,例如用户的效用函数,电网负载和供电成本。由此,我们提出了基于交替方向乘子(alternation direction method of multipliers, ADMM)的分布式算法,该算法采用历史信息作为影响因子,以此把已有模型的不等式约束改为等式约束。该算法以分布式方式将耦合项分离并实现在线求解。所提的算法在解决问题的同时,也有效地避免了智能电网中信息交互过程中的隐私泄露问题。最后,通过数值实验,说明了该算法较已有算法具有较好的性能和表现。

关键词

凸优化, ADMM, 分布式在线算法, 智能电网

ADMM-Based Distributed Online Algorithm for Power Dispatching Optimization of Smart Grid

Feng Zhao*, Yazheng Dang

University of Shanghai for Science and Technology, Shanghai

Received: Dec. 15th, 2021; accepted: Jan. 18th, 2022; published: Jan. 25th, 2022

*通讯作者。

Abstract

In recent years, with the research of smart grid by relevant participants and researchers, there are still many directions worth studying in power dispatching optimization. This paper studies the distributed algorithm of power dispatching in smart grid environment. In this paper, we first introduce that the power dispatching optimization problem is a convex optimization problem, which is mainly composed of three key factors, such as user utility function, power grid load and power supply cost. From this, we propose a distributed algorithm based on alternating direction multiplier (alternation direction method of multipliers, ADMM), which uses historical information as the influence factor to change the inequality constraint of the existing model into equality constraint. In this algorithm, the coupling terms are separated and solved online in a distributed way, while solving the problem, the proposed algorithm also effectively avoids the privacy disclosure problem in the process of information interaction in smart grid. Finally, the numerical experiment shows that the algorithm has better performance and performance than the existing algorithm.

Keywords

Convex Optimization, ADMM, Distributed Online Algorithm, Smart Grid

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

智能电网是将信息技术、通信技术、计算机技术、先进的电力电子技术、可再生能源发电技术和原有的输配电基础设施高度集成的新型电网, 被世界各国视为推动经济发展和产业革命, 实现可持续发展的新基础和新动力[1]。

近年来, 随着智能电网的发展, 智能电网至今仍存在很多问题有待解决。全面实现电网的智能化建设是一个循序渐进的过程, 而在这过程中, 需要我们去不断地发现问题并解决问题, 使得智能电网的建设慢慢地满足要求和逐步地完善。这样主要是为了对智能电网中各个组成元素实现他们的最大效益, 解决各个层面的矛盾。目前阅读相关文献了解到, 目前智能电网的相关研究仍在为了实现各层间的利益最大化以及解决各个层间隐私泄露问题而极力探索和创新。对于该类问题已经有很多创新性的研究: 研究终端用户与电网的双向能量交易问题, 目的是最大化用户的收益, 采用李雅普诺夫优化理论提出的实时算法复杂度低, 且不需要知道用户能量需求、电价变化和可再生源到达的统计特性[2]、数据聚合技术在加密用户数据后再进行聚合, 比传统的聚合方法成本更低、效率更高; 群签名可以验证用户身份, 保护用户隐私, 并且最小化通信开销[3]、基于遗传算法提出一种多种类型可控电器的 G-DSM 算法, 将负载调度问题定义为成本最小化问题, 并用遗传算法求解, 结合从用户侧获取的电力大数据对用户的电力需求进行规划, 降低了用户的花销以及峰值电力负载, 从而避免电力资源的浪费, 提高了电网的工作效率[4]、采用在线对偶方法求解社会福利最大化模型的拉格朗日乘子, 以此来确定电网电价[5]。针对相关问题, 本文提出了基于 ADMM 的分布式算法, 该模型以历史信息为约束条件, 为下一时刻电量实现分配最优。模型主要通过对各个元素的敏感信息进行分离并求解各个子问题, 既实现有效维护各方隐私信息, 也达到电网中各个关键元素利益最大化的目的。

2. 系统模型

2.1. 系统定义

在智能电网的环境中, 电网分配系统主要由三个关键部分构成: 电网运营商、供电商及用户。这三者之间通过相关智能设备进行信息的交互, 交互的方式是: 所有的智能设备通过一些无线网等相关信息交互方式与电网运营商相连接。在每次的能源分配的时间周期内, 智能设备和电网运营商之间交互智能电网的状态和相关控制信息, 以此来最大化用户的效用函数、最小化运营成本及平滑电网总负载方差。然后, 供电商相应地将电力进行传输并分发给用户。

在本文中, 我们对下面一些变量进行相关的定义:

在智能电网中, 电力分配的时间周期 T 可分为多个时刻 $t \in \bar{T} = \{1, 2, \dots, T\}$, 其中 \bar{T} 为所有时间点的集合。用户 i 在每个 t 时刻的电量为 $p_i(t)$, 同时 $\bar{N} = \{1, 2, \dots, N\}$ 为用户集。设定对于每个用户 i 在每个时刻 t 的电量为 p 消耗为:

$$p = [p_{i,\min}(t), p_{i,\max}(t)] \quad (1)$$

其中 $p_{i,\min}(t)$ 为每个用户 i 在时刻 t 的实际最小需求电量, $p_{i,\max}(t)$ 为每个用户 i 在时刻 t 的实际最大需求电量。我们认为 $p_i(t) \in p$, 且 p 非负凸集。

2.2. 用户效用函数

在本文中, 我们认为在智能电网中用户的行为是相互独立的。在不同的时间内用户有着不同的偏好和用电规律。这主要体现在如天气、不同功率用电器的使用及用电规模等情况。对此, 我们采用效用函数 $U(p_i(t), w_i(t))$ 代表用户的行为偏好[5]。其中 $w_i(t)$ 为用户 i 的偏好参数, 该参数代表不同用户在如上述的不同情况下的不同时间内的偏好, 且在 $[0, 1]$ 区间内随机取值。而对于本文采用的用户效用函数可以用二次函数表示, 即:

$$U(p_i(t), w_i(t)) = \begin{cases} w_i(t)p_i(t) - \frac{1}{8}p_i(t)^2 & 0 \leq p_i(t) \leq 4w_i(t) \\ 4w_i(t) & p_i(t) > 4w_i(t) \end{cases} \quad (2)$$

2.3. 供应成本函数

对于供电商来说, 考虑在满足需求的条件下供应成本问题是首当其冲的。我们通过阅读文献了解到: 在智能电网中, 供电商的成本问题主要与电网负载成正相关。当电网负载越大, 供应成本就越高, 反之亦然。这主要表现在: 当在一些情况下, 用电量逐渐临近点电网负载时, 电网运营商不得要求供电商更多电量的供应以避免用户的用电问题, 这必然增加了供电商的供电成本。因此, 在本文中应用一个递增且严格凸的二次函数近似表示为供电成本函数[6] [7] [8], 具体如下:

$$C(g(t)) = a \cdot g(t)^2 + b \cdot g(t) + c \quad (3)$$

其中, a, b, c 是预先为电网选择的, 且 $a, b, c \geq 0$ 。 $g(t)$ 定义为供电商在时刻 t 的电力总生产量, 即供电商在低供电成本的情况下需要满足用户的足够用电量。

另外, 我们认为供电商在某一时刻 t 满足用户需求电量时的最大电力生产量为 $g_{\max}(t)$, 于是:

$$g(t)_{\min} \leq g(t) \leq g_{\max}(t) \quad (4)$$

在这里我们认为, $g(t) \in G = [g_{i,\min}(t), g_{i,\max}(t)]$, 而 $g_{i,\min}(t) \geq \sum_{i \in \bar{N}} p_i(t)$ 。另外, 由于成本函数 $C(\cdot)$ 为

严格凸且递增的, 所以供电商需要通过调整发电量 $g(t)$ 来控制其成本。

3. 问题构建和方法介绍

在本节中, 我们需要对文献提出的离线算法做一个基本介绍, 以此来引出后文中基于 ADMM 算法的分布式在线算法及其较离线算法和其他研究提出的分布式在线算法, 并进行相关比较。

离线算法

在智能电网环境中, 我们考虑到问题模型中涉及三个关键的因素: 用户、电网运营商和供电商。在这种考虑下, 我们的目的是: 1) 最大化用户的效用函数; 2) 最小化供电成本; 3) 平滑电网总负载。

在离线场景中, 电网运营商需要对用户的偏好参数 $w_i(t)$ 和供电商的总发电量 $g(t)$ 有着预先的信息掌控。在这里, 设 $P_i(t)$ 为用户 i 在 t 时刻的用电量, $P_i^*(t)$ 为用户在 t 时刻的最优用电量, 且 $P_i^*(t), P_i(t) \in p$ 。于是, 对所有时刻 $t \in \bar{T}$, 离线问题为:

$$\begin{aligned} \min: & \sum_{t \in \bar{T}} \left[C(g(t)) - \sum_{i \in N} U(P_i(t), w_i(t)) \right] + \frac{\alpha T}{2} \text{var} \left(\sum_{i \in N} \bar{P}_i \right) \\ \text{s.t.} & \sum_{i \in N} \left[P_i(t) + \frac{\alpha}{\alpha + t} [P_i^*(t-1) - P_i^*(t-2)]^+ \right] = g(t) \end{aligned} \quad (5)$$

令 $R_t = \frac{\alpha}{\alpha + t} \left[\sum_{i \in N} (P_i^*(t-1) - \hat{P}_i^*(t-2)) \right]^+$, 代表把前两次时间的最优用电量作为下一时间的影响因素,

而 $[\cdot]^+$ 表示: 为正时取相应的值, 否则为零。这是用户的历史用电情况。其中 $\text{var}(\cdot)$ 为方差函数, 即:

$$\text{var} \left(\sum_{i \in N} \bar{P}_i \right) = \frac{1}{T} \sum_{t \in \bar{T}} \left(\sum_{i \in N} P_i(t) - \frac{1}{T} \sum_{k \in \bar{T}} \sum_{i \in N} P_i(k) \right)^2 \quad (6)$$

在式(5)中由有三个关键主要部分组成, 分别是供电成本, 用户的效用函数和电网负载方差。在目标函数的第三部分中, 存在一个权衡参数 α , 其作用是在智能电网中对用户权益和电网负载进行权衡。而在约束条件中我们认为前时刻的用电量作为一个影响因子作用于下一时刻的用电量, 由此, 我们构建了如式(5)中的约束。

在离线算法中, 我们在前文中提到各个用户的用电量 $P_i(t)$ 是相互独立的。那么式(6)可以重新写为:

$\text{var} \left(\sum_{i \in N} \bar{P}_i \right) = \sum_{i \in N} \text{var}(\bar{P}_i)$ 。接下来, 说明离线算法是一个凸优化问题, 这是因为目标函数中的效用函数 $U(\cdot)$

是一个凹函数, 供电成本函数 $C(\cdot)$ 和方差函数 $\text{var}(\cdot)$ 均为凸函数。同样, 由于方差函数 $\text{var}(\cdot)$ 的凸性, 文献[9]已给出证明离线函数有唯一解。而在离线算法中, 文献[9]介绍了该算法在满足 KKT 条件下能够得到每时刻 t 每个用户 i 的最优解, 其中用电均值为 $\bar{P}_i^* = \frac{1}{T} \sum_{k=1}^T P_i^*(k)$ 。而在该算法中, 所有信息都是需先

验知的, 但是现实智能电网环境中, 预先获取所有信息是不太可能的。

于是, 对于这类问题, 文献[9]和[10]分别提出了在线算法(Online Algorithm)和分布式在线算法(Distributed Online Algorithm, DOA)。这两种算法分别通过在线方式和分布式解决了离线算法存在的预知信息问题, 而且 DOA 算法通过拉格朗日将原始问题转化为对偶问题, 进一步地解决了在线算法上用户隐私信息泄露的不足, 但是 DOA 方法中仍存在一些性能上的不足。由此, 在下面章节, 我们提出了一种基于 ADMM 的分布式在线算法(Distributed Online Algorithm Based on ADMM, 简称 DOAA), 该算法既继承了在线算法预先不需要所有信息的优点, 同时也达到了 DOA 算法的分布式求解的效果, 并在性能比 DOA 算法更具优势。

4. 基于 ADMM 的分布式在线算法

算法介绍

ADMM 算法是一种用于求解具有可分解结构的凸优化问题的重要方法, 由于其处理速度快、收敛性能好, 所以该算法在很多研究领域都得到广泛的应用和认可[11]。ADMM 算法一般用于等式约束的凸优化问题, 具体如下:

$$\begin{aligned} \min & f(x) + g(z) \\ \text{s.t.} & Ax + Bz = c \end{aligned} \quad (7)$$

其中 $f(x)$ 和 $g(z)$ 均为凸函数, x 、 z 为两组变量。

由此构建增广拉格朗日函数:

$$L(x, z, \lambda) = f(x) + g(z) + \lambda^T (Ax + Bz - c) + \frac{\rho}{2} \|Ax + Bz - c\|_2^2 \quad (8)$$

式(8)中: λ 为增广拉格朗日对偶变量, ρ 为惩罚系数。由此可以把约束问题转化为无约束问题。

根据式(8)可得到 ADMM 的迭代求解方程:

$$\begin{cases} x^{k+1} = \arg \min_x L_\rho(x, z^k, \lambda^k) \\ z^{k+1} = \arg \min_z L_\rho(x^{k+1}, z, \lambda^k) \\ \lambda^{k+1} = \lambda^k + \rho(Ax^{k+1} + Bz^{k+1} - c) \end{cases} \quad (9)$$

不难发现, 在更新 x 的第 $k+1$ 次迭代需要 z 的第 k 次迭代结果, 而在更新 z 的第 $k+1$ 次迭代需要 x 的第 $k+1$ 次迭代结果, 最后更新 λ 的第 $k+1$ 次迭代需要 λ 的第 k 次迭代结果及 x 的第 $k+1$ 次迭代结果和 z 的第 k 次迭代结果。

由此, 我们把离线问题进行更改, 对于整个 $t \in \bar{T} = \{1, 2, \dots, T\}$:

$$\begin{aligned} \min & : \sum_{t \in \bar{T}} C(g(t)) + \frac{\alpha T}{2} \text{var} \left(\sum_{i \in \bar{N}} \bar{P}_i(t) \right) - \sum_{t \in \bar{T}} \sum_{i \in \bar{N}} U(P_i(t), w_i(t)) \\ \text{s.t.} & \sum_{i \in \bar{N}} P_i(t) + R_i = g(t) \end{aligned} \quad (10)$$

根据 ADMM 算法在的优化规则, 可以将总用电量 $g(t)$ 、用电量 $P_i(t)$ 两个目标函数的变量之间相互迭代, 进行求解。然后, 我们结合文献[9]提出的离线问题转化为在线问题的引理和方法, 即:

引理 1: 对于 $T \rightarrow \infty$, 每个用户 i 的实际用电量和最优电力分配的关系:

$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T (p_i^*(t) - \hat{p}_i(T)) = 0 \quad (11)$$

我们知道在时间趋于无穷大时, 最优电力分配量 $p_i^*(t)$ 是逐渐收敛于 $\hat{p}_i(T)$ 。

然后, 对 $\hat{p}_i(t)$ 更新:

$$\hat{p}_i(t) = \hat{p}_i(t-1) + \frac{\alpha}{\alpha+t} (p_i^*(t) - \hat{p}_i(t-1)) \quad (12)$$

从文献[9]得知, 当 $t \rightarrow \infty$ 时, $\hat{p}_i(t)$ 是渐近收敛于定点 \bar{P}_i^* 。

由此我们可以将离线问题转化为在线问题, 具体如下:

对时间序列 $t \in \bar{T} = \{1, 2, \dots, T\}$ 有:

$$\begin{aligned} & \min C(g(t)) + \frac{\alpha}{2} \sum_{i \in \bar{N}} (p_i(t) - \hat{p}_i(t-1))^2 - \sum_{i \in \bar{N}} U(p_i(t), w_i(t)) \\ & \text{s.t. } \sum_{i \in \bar{N}} \left[p_i(t) + \frac{\alpha}{\alpha+t} [p_i^*(t-1) - p_i^*(t-2)]^+ \right] = g(t) \end{aligned} \quad (13)$$

于是增广拉格朗日:

$$\begin{aligned} L_\rho(p_i(t), g(t), \lambda(t)) &= \sum_{i \in \bar{N}} C(g(t)) + \sum_{i \in \bar{N}} \left(\frac{\alpha}{2} (p_i(t) - \hat{p}_i(t-1)) - U(p_i(t), w_i(t)) \right) \\ &+ \lambda(t) \left(\sum_{i \in \bar{N}} \left[p_i(t) + \frac{\alpha}{\alpha+t} [p_i^*(t-1) - \hat{p}_i(t-2)]^+ \right] - g(t) \right) \\ &+ \frac{\rho}{2} \left\| \sum_{i \in \bar{N}} \left[p_i(t) + \frac{\alpha}{\alpha+t} [p_i^*(t-1) - p_i^*(t-2)]^+ \right] - g(t) \right\|_2^2 \end{aligned} \quad (14)$$

该模型中的 $\sum_{i \in \bar{N}} (p_i(t) - \hat{p}_i(t-1))^2$ 与离线算法中的方差 $\text{var}(\bar{P}_i)$ 近似, 这是由于 $\hat{p}_i(t)$ 渐近收敛于定点 \bar{P}_i^* 。而在此模型中, 我们发现尽管该模型与文献[9]中的模型仅在约束条件中加了有关历史信息的变量 $r_i = \frac{\alpha}{\alpha+t} \sum_{i \in \bar{N}} [p_i^*(t-1) - p_i^*(t-2)]^+$, r_i 表示在线情况下随着时间变化的历史信息, 同时也为用户用电需求做一个保障, 而这并未改变模型本身的性质, 所以该模型仍然满足文献[9]的各个条件。同时, 在线最优解也是渐近收敛到离线最优解的, 所以该模型与已有的模型等价。我们从文献[9]了解到在线算法中存在的缺点: 在该模型中前一项包含着电网运营商所需的信息—总用电量 $g(t)$, 而后两项包涉及到用户的用电量 $p_i(t)$ 和偏好系数 $w_i(t)$ 的隐私信息, 再者我们不能很好地对这些耦合信息进行有效分离来分别求解, 这主要由于在约束条件中仍包含着两者的信息。

对此, 本文借鉴文献[10]的对偶分离的思想, 并根据 ADMM 的求解方法和考虑其优化性能, 然后结合式(14)可以得到如下方程:

对于每个时刻 t , 有:

$$\begin{cases} p_i^{k+1} = \arg \min_{p_i \in p} L_\rho(p_i, g^k, \lambda^k) \\ g^{k+1} = \arg \min_{g \in G} L_\rho(p_i^{k+1}, g, \lambda^k) \\ \lambda_i^{k+1} = \lambda_i^k + \rho \left\| \sum_{i \in \bar{N}} p_i^{k+1} + r_i - g^{k+1} \right\|_2^2 \end{cases} \quad (15)$$

然后, 根据 ADMM 算法的原理, 当原始残差 γ^{k+1} 和对偶残差 s^{k+1} 同时小于收敛阈值 ε 时, 上述迭代过程终止。即:

$$\begin{cases} \left\| \gamma^{k+1} \right\|_2 = \left\| \sum_i p_i^{k+1} + r_i - g^{k+1} \right\|_2 \leq \varepsilon_{\text{prim}} \\ \left\| s^{k+1} \right\|_2 = \rho \left\| g^{k+1} - g^k \right\|_2 \leq \varepsilon_{\text{dual}} \end{cases} \quad (16)$$

式中 $\varepsilon_{\text{prim}}$ 、 $\varepsilon_{\text{dual}}$ 分别是原始残差的收敛阈值和对偶残差的收敛阈值, 在后文中均用 ε 表示, 且取值为 10^{-3} 。

由此, 我们看到 ADMM 算法可以很好地将电网运营商的信息和用户信息分离并进行求解, 这不仅可以避免隐私信息泄露问题, 同时该算法较文献[10]提出的 DOA 算法在性能上表现良好, 这将在结果分析中具体说明。算法过程具体如下:

步骤 1: 对于每个用户 i , 初始化参数。迭代次数 $k = 0$, 更新用电量 $\hat{p}_i(0) \in p$, 前时刻的最优用电量 $p_i^*(0), p_i^*(-1) \in p$, 总用电量 g^0 及拉格朗日对偶变量 $\lambda^0 \in (0, 1)$, 权衡参数 α , 罚参数 ρ 和阈值 ε 。

步骤 2: 式(15)子优化问题进行交替计算。由第 k 步的 g^k , 根据式(15)中的第一个子问题求解出用户的用电量 p_i^{k+1} , 然后将该结果传递给电网运营商, 并求解第二个优化子问题, 并计算出 g^{k+1} , 然后将此信息传送给供电商。

步骤 3: 收敛判断。当原始残差 γ^{k+1} 和对偶残差 s^{k+1} 、均小于收敛阈值 ε 时, 算法终止计算, 则步骤 2 得到的解即为最优解; 否则, 进行步骤 4。

步骤 4: 更新增广拉格朗日对偶变量 λ^{k+1} , 令 $k = k + 1$ 。

步骤 5: 更新式(15)的 $\hat{p}_i(t)$, 返回步骤 2, 进行下步迭代过程。

5. 结果分析

在本节中, 我们仿真数据和参数参考于南加州爱迪生(SCE)地区记录的数据[12]。然后将文献[10]中的算法 DOA 和该算法进行比较, 研究两者的性能优劣。

在本文中, 我们认为对于一个小区域的用户数设为 $N = 20$, 在智能设备间交互信息的更新周期是每 15 分钟为一间隔, 总时长为 24 小时。用户 i 的用电需求 $p \in [1, 3]$ 。供电成本函数中的参数设置 $a = 0.05$, $b = c = 0$; 以及权衡参数 $\alpha = 0.1$ 。

在关于用户的用电量 $\hat{p}_i(t)$ 收敛性比较, 我们给出了两个用户进行比较, 如图 1、图 2:




Figure 1. Comparison of the two algorithms for the power consumption $\hat{p}_i(t)$ of different users

图 1. 对于不同用户的用电量 $\hat{p}_i(t)$ 两种算法的比较




Figure 2. Power consumption $\hat{p}_i(t)$ and optimal power consumption $p_i^*(t)$ of different users

图 2. 不同用户的用电量 $\hat{p}_i(t)$ 和最优用电量 $p_i^*(t)$

从图 1 中我们可以看出来, DOA 算法和 DOAA 算法在最后均逐渐收敛于定值 \bar{P}_i^* , 而收敛性能上算法 DOA 的表现不如 DOAA, 这是因为 ADMM 算法较 DOA 算法具有更好的收敛性能以及历史用电信息对后期电量的作用。另一方面, 图中用户 2 和 7 之间的区别在于偏好参数 $w_i(t)$ 的选择, 同时也验证了 DOAA 的可行性。这说明基于 ADMM 的分布在线算法既具备了文献[9]避免隐私泄露的问题, 也表现出较好的性能。图 2 表明分配用户的最优用电量的值是在实际用电量上下波动的, 随着时间 $T \rightarrow \infty$, 最终会逐渐收敛到实际用电量值。

另外, 我们也对电网负载控制上也做出了相应地比较, 这主要通过总量用电量来体现, 具体如图 3:




Figure 3. Comparison of the two algorithms on smooth grid load
图 3. 两个算法在平滑的电网负载上的比较

从图 3 中, 可以看到两个算法在平滑电网负载上, DOAA 的表现较 DOA 更为好些, 主要是因为 DOAA 把前两次用电历史的结果作为下一时间开始的一个影响因子, 这为供电商在供电上提供很好的根据, 由图 3 可以看出该算法在此约束下能更好地降低供电峰值。

6. 结语

在本文中, 我们在相关算法的基础上, 为满足分离变量达到减少隐私信息泄露的问题, 同时我们也调整了约束条件, 使得在电力调度中历史信息作为下一时间的一个影响因子, 以此来提高性能, 所以我们提出基于 ADMM 的分布式在线算法, 并在文中与 DOA 算法作了对比。通过数值实验可知该算法具有较好的收敛性能, 同时在平滑电网负载上也有较好的表现。与此同时也继承了 DOA 算法的优点: 分离运营商与用户之间的敏感信息并分别进行求解, 为有效地规避隐私泄露的问题作出很好的处理。未来将对智能电网场景中考虑多种因素并如何优化电力调度的相关问题进行更深入的研究, 将会为智能电网的建设提供很好的参考。

参考文献

- [1] 于劲松, 秦香春. 智能电网技术应用与发展[J]. 科技风, 2010(21): 255.
- [2] 刘迪迪, 孙浩天, 肖佳文, Frank Jiang, 郑鲲鹏. 智能电网中终端用户的双向能量交易算法[J/OL]. 西安电子科技大学学报: 1-7[2021-03-08]. <http://kns.cnki.net/kcms/detail/61.1076.tn.20210105.1734.014.html>

-
- [3] 吴振铨, 梁宇辉, 康嘉文, 余荣, 何昭水. 基于联盟区块链的智能电网数据安全存储与共享系统[J]. 计算机应用, 2017, 37(10): 2742-2747.
- [4] 吴海伟, 王晓忠, 朱法顺. 一种基于遗传算法的智能电网调度方法[J]. 计算机与现代化, 2020(9): 122-126.
- [5] 高岩. 智能电网实时电价社会福利最大化模型的研究[J]. 中国管理科学, 2020, 28(10): 201-209.
- [6] O'Neill, D., Levorato, M., Goldsmith, A., *et al.* (2010) Residential Demand Response Using Reinforcement Learning. *1st IEEE International Conference on Smart Grid Communications*, Gaithersburg, MD, 4-6 October 2010, 409-414. <https://doi.org/10.1109/SMARTGRID.2010.5622078>
- [7] Samadi, P., Mohsenian-Rad, H., Schober, R., *et al.* (2012) Advanced Demand Side Management for the Future Smart Grid Using Mechanism Design. *IEEE Transactions on Smart Grid*, **3**, 1170-1180. <https://doi.org/10.1109/TSG.2012.2203341>
- [8] Samadi, P., Mohsenian-Rad, A.H., Schober, R., *et al.* (2010) Optimal Real-Time Pricing Algorithm Based on Utility Maximization for Smart Grid. *2010 1st IEEE International Conference on Smart Grid Communications (SmartGrid-Comm)*, Gaithersburg, MD, 4-6 October 2010, 415-420. <https://doi.org/10.1109/SMARTGRID.2010.5622077>
- [9] Wang, Y., Mao, S. and Nelms, R.M. (2013) Online Algorithm for Optimal Real-Time Energy Distribution in the Smart Grid. *IEEE Transactions on Emerging Topics in Computing*, **1**, 10-21. <https://doi.org/10.1109/TETC.2013.2273218>
- [10] Wang, Y., Mao, S. and Nelms, R.M. (2014) Distributed Online Algorithm for Optimal Real-Time Energy Distribution in the Smart Grid. *IEEE Internet of Things Journal*, **1**. <https://doi.org/10.1109/JIOT.2014.2305667>
- [11] Boyd, S., Parikh, N., Chu, E., *et al.* (2011) Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers. *Foundations and Trends® in Machine Learning*, **3**, 1-122. <https://doi.org/10.1561/22000000016>
- [12] SCE, Irvine, CA, USA. (2011) Regulatory Information, SCE Load Profiles, 2011 Static Load Profiles. http://www.sce.com/005_regul_info/eca/DOMSM11.DLP