

7-3-2020

Joint Optimization Control of Energy Storage System Management and Demand Response

Xueying Gao

School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;

Tang Hao

School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;

Gangzhong Miao

School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;

Zhaowu Ping

School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Joint Optimization Control of Energy Storage System Management and Demand Response

Abstract

Abstract: The joint optimization problem of energy management and demand response were studied in order to reduce the long-run cost of electricity users equipped with energy storage unit and smart applications, and to increase their benefits meanwhile. *The goals were achieved by controlling both the energy storage unit (charging, discharging, or idle) and the load service (access or delay). Based on the random nature of solar photovoltaic, load demand electricity and electricity price, the joint optimization problem was modeled as infinite-horizon Markov decision process model, and Q-learning algorithm was proposed to find the optimal solution.* Simulation results show that the joint control increases the user's long-term income.

Keywords

smart grid, management of energy storage, demand response, MDP, reinforcement learning

Recommended Citation

Gao Xueying, Tang Hao, Miao Gangzhong, Ping Zhaowu. Joint Optimization Control of Energy Storage System Management and Demand Response[J]. Journal of System Simulation, 2016, 28(5): 1165-1172.

储能系统能量调度与需求响应联合优化控制

高雪莹, 唐昊, 苗刚中, 平兆武

(合肥工业大学电气与自动化工程学院, 安徽 合肥 230009)

摘要: 为了增加含有储能单元及智能用电设备的用户的长期收益, 研究了储能系统能量调度及需求响应联合优化问题, 对储能单元动作(充电, 放电, 闲置)及可延时负荷动作(接入, 不接入)进行优化控制。建立包括用电经济性及满意度的优化目标函数, 根据太阳能光伏发电、负载用电需求以及电网电价的随机特性, 将该联合优化问题建模为无穷时段马尔可夫决策过程模型, 进而引入 Q 学习算法对优化问题进行求解。仿真结果表明联合优化控制比单独对电池动作控制或者需求响应控制使用户获得了更高的长期收益。

关键词: 智能电网; 储能管理; 需求响应; 马尔可夫决策过程; 强化学习

中图分类号: TP202 文献标识码: A 文章编号: 1004-731X (2016) 05-1165-08

Joint Optimization Control of Energy Storage System Management and Demand Response

Gao Xueying, Tang Hao, Miao Gangzhong, Ping Zhaowu

(School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

Abstract: The joint optimization problem of energy management and demand response were studied in order to reduce the long-run cost of electricity users equipped with energy storage unit and smart applications, and to increase their benefits meanwhile. The goals were achieved by controlling both the energy storage unit (charging, discharging, or idle) and the load service (access or delay). Based on the random nature of solar photovoltaic, load demand electricity and electricity price, the joint optimization problem was modeled as infinite-horizon Markov decision process model, and Q-learning algorithm was proposed to find the optimal solution. Simulation results show that the joint control increases the user's long-term income.

Keywords: smart grid; management of energy storage; demand response; MDP; reinforcement learning

引言

智能电网的兼容性与互动性为储能系统能量管理及需求响应为用户节能用电提供了新的契机。其兼容性表现为支持可再生能源的接入, 适应分布式电源的接入, 实现电网清洁环保。互动性体现在用户与电网的交流互动, 用户可以实时掌握电价, 调整用电计划, 使用价格较低的电能^[1]。



收稿日期: 2014-12-22 修回日期: 2015-03-02;
基金项目: 国家自然科学基金 (61174186, 61374158, 71231004), 高等学校博士学科点专项科研基金(201301111110007), 教育部新世纪优秀人才计划项目(NCET-11-0626);
作者简介: 高雪莹(1990-), 女, 安徽颍上, 硕士生, 研究方向为强化学习在智能电网中的应用。

分布式发电单元对于减少电网负荷有重要作用, 但其受气候和天气影响较大, 发电功率难以保证平稳, 波动性与间歇性明显, 从电网的角度看, 并网运行的分布式发电单元相当于一个强随机性的扰动源。分布式发电直接接入电网会造成配电网的波动和闪变。储能单元的引入可以有效改善电能质量, 为电网提供有功支撑, 增强电网调频、调峰能力, 大幅度提升电网对可再生能源的接纳能力, 同时对于减少负荷峰谷差及保证电网安全稳定有重要作用, 因此太阳能等新能源一般采用分布式电源方式接入配电网^[2]。用户可以根据实时电价信息, 决定对储能单元能量的调度, 在电价较低时储

存电能,而在电力市场需求较高时释放储能,达到削峰填谷的作用^[3]。

基于价格的需求响应管理能有效激励用户参与电网调峰,减少电网安全运行压力,平衡电网负荷,引导用户科学、合理用电,实现资源的优化配置。用户可以根据实时电价及需求调整用电时间,例如将用电时间从用电高峰期转移到非高峰期^[4]。智能用电设备(SA, smart appliance)使用户可以设置用电时间以及期望完成时间。需求响应使得电网及用户同时受益,转移高峰期用电使得电网尖峰用电减少,电网风险降低;对于用户来说,选择在非高峰期用电可以减少用电费用。

综上所述,对分布式电源中的储能系统进行能量调度,同时对需求响应进行优化控制能够有效实现电网负荷削峰填谷,降低用户用电代价,实现电网高效运行。

目前,储能系统能量调度和需求响应控制的研究得到了广泛关注和探索。文献[5]提出了家庭能源系统的控制和管理的自学习模型,该文章描述了住宅能源系统并对电池模型进行了详细的描述,考虑了电池的充放电效率。文献[6]提出了基于自适应算法的新能源和可再生能源管理算法,该文章考虑了环境与负载可能随时间变化,特别是可再生能源的变化。文献[7]提出了接入电动汽车和可再生能源以减少经济花费及环境污染的思想。文献[8]对光伏系统中蓄电池管理策略进行了研究,通过使用推荐策略可实现光伏电能的有效利用,采用分组避免电池长期处于欠充状态。文献[9]进行了基于排队系统模型的空调负载需求侧管理研究,考虑了大厦的空调负载的节能与用户舒适度。文献[10]提出了用强化学习进行居民需求侧响应,建立了含有 M 个负载的模型,将实时电价和负载需求作为马尔可夫过程进行考虑。文献[11]提出了需求响应和分布式电网的一些机遇和挑战。文献[12]研究了价格不确定下的 V-G 系统的实时控制算法,通过控制电动汽车的蓄电池的充放电或者调频获得收益,当电网电价较高电池电量充足时可以对电网卖电

或是调频获得收益,在电价较低的时候对蓄电池充电。文献[13]提出了智能电网中通过能量缓存减少智能家电的用电代价的方法。文献[14]提出了微电网联络线平滑服务的需求响应和电池储能协调算法。文献[15]研究了分布式网络中的最优用户需求管理问题。文献[16]研究了使用强化学习方法使在分布式网络中的用户收益最大化。

然而上述文献均未考虑分布式电源的储能系统能量调度与需求响应控制联合优化问题,智能电网支持清洁能源以分布式电源形式接入并且与用户双向互动的特性使得联合优化控制问题成为有意义的新的问题。

本文考虑将分布式电源中的储能系统能量管理控制与需求响应控制相结合,使用户收获更高的收益。将含有分布式电源与 SA(例如,洗衣机,风干机,空调,热水器,电动汽车等)的微网作为研究对象,优化控制储能单元的充电\放电\闲置与 SA 的接入时间,使系统获得长期最大回报。根据太阳能光伏发电、负载用电需求以及电网电价的随机特性,将该联合优化问题建模为无穷时段马尔可夫决策过程模型,将系统的优化控制问题建模为离散时间马尔可夫决策过程,用策略迭代方法及 Q 学习获得最优策略。

1 物理系统

本文研究的系统由外部电网、分布式电源与多个 SA 组成,如图 1 所示。图中虚线表示信息流,实线为能量流。系统的控制中心接收环境信息,包括电网实时电价、分布式发电单元发电功率等级、电池电量等级以及 SA 信息,并通过控制器对电池及 SA 做出决策。决策时刻 k 是离散的, $k = 1, 2, \dots$, 决策等周期进行。电池可以向电网售电,闲置,或从电网买电储能。SA 可以通过延时使用价格较低的电能,从而减少用户代价,但是延时服务会造成用户的不满意,用户不满意代价随等待时间增加。用户收益由两部分得到,包括通过能量缓存与需求响应获得的经济效益和因延时服务造成的用户满意度代价。




图 1 系统组成及控制示意图

设蓄电池组总容量为 B , 将其等量离散为 L 个等级, 则单位等级的电量大小为 $\Delta w = B/L$ 。离散化后蓄电池组剩余电量状态记为 b , $b \in \{0, 1, 2, \dots, L-1\}$, 在 k 时刻电池电量等级为 $b(k)$, 则剩余电量 $B' = \Delta w \cdot b(k)$ 。

太阳能光伏发电作为发电装置, 文献[17]根据历史数据将太阳能发电能量变化建模为马尔可夫过程。设单位周期光伏发电量上限为 G , 将发电量离散化为单位等级电量为 Δw 的 N 个等级, 则 $N = G/\Delta w$ 。离散化后发电等级状态记为 g , $g \in \{0, 1, 2, \dots, N-1\}$, 在 k 时刻光伏发电等级为 $g(k)$, 则光伏发电量 $G' = \Delta w \cdot g(k)$ 。本文参照文献[18]将太阳能辐射强度变化建模为马尔可夫过程, 设单位周期光伏发电能量等级变化为服从概率矩阵为 P^g 的马尔可夫链, 光伏发电能量等级从状态 i 转移到状态 j 概率为 P_{ij}^g 。

用户拥有 R 个独立可延时 SA。第 i 个 SA 的需求到达为随机过程, $i \in [1, R]$, 所需功率为 θ_i , 所需服务时间为 T_i 个周期, 等待截止周期为 J_i 。SA 可断续服务, 延时一个周期的不满意系数为 α_i , 等待周期为截止周期时必须进行服务。定义 $d_i = 1$ 或 0 分别表示在周期起始点第 i 个负载到达或者没有到达, n_i 表示第 i 个负载需求服务时间, $u_i = 1$ 或 0 分别表示对负载 i 需求进行服务或无服务, 定义负载等待时间为 y_i 。假设用电设备 i 的服务未完成

时, 不会新的需求产生。当设备没有服务请求时, 下一周期需求到达的概率为 λ_i (下文称为负载到达率)。当用户 SA 总用电量为 $w(k)$, 电池充电量为 $v(k)$ 时, 由能量供需平衡可知, 系统需要从电网买进的电能为 $h(k) = w(k) + v(k) \times \Delta w$ 。

电价技术包括分时电价(TOUP), 尖峰电价(CPP), 实时电价(RTP)。本文假设用户接受实时电价。将电网电价 p 离散化为 M 个不同的状态, 那么 k 时刻电价 $p(k) \in \{p^1, p^2, \dots, p^M\}$ 。假设电价状态变化服从转移概率矩阵为 P^p 的马尔可夫链, 从电价状态 i 转移到状态 j 概率为 P_{ij}^p 。

2 数学模型

2.1 系统状态

定义向量 $s = \{p, g, b, \bar{n}, \bar{y}\}$ 表示系统状态, S 为系统状态空间, 那么 $s \in S$ 。其中: $p \in R^+$ 为实时电价, g 表示光伏发电能量等级, b 表示电池电量等级, $\bar{n} = [n_1, n_2, \dots, n_R]$ 表示 R 个 SA 当前需求服务周期, $\bar{y} = [y_1, y_2, \dots, y_R]$ 表示 R 个 SA 的等待周期。

2.2 行动集

行动集 D 是可选行动 $\bar{a}$ 的集合。系统策略 π 为状态空间到行动集的映射, 即 $S \rightarrow D$ 。行动 $\bar{a}$ 包括电池行动 v 和 SA 行动 $\bar{u}$, 即 $\bar{a} = \{v, \bar{u}\}$ 。

电池动作 v 的取值如下, $v=1$ 可以使电池电量增加一个等级:

$$v = \begin{cases} 1 & \text{充电} \\ 0 & \text{闲置} \\ -i & \text{放电}(i=1,2) \end{cases} \quad (1)$$

用电设备行动 $\bar{u}=[u_1, u_2 \dots u_M]$ ，其中 $u_i \in \{0,1\}$ ， $i \in \{1,2,\dots,M\}$ ， $u_i=1$ 表示对用电设备 i 进行服务， $u_i=0$ 表示不对用电设备 i 进行服务。行动约束条件：

- (1) 电池电量等级保持在 $[0, L-1]$ 内，即 $b(k)+g(k)+v(k) \in [0, L-1]$ ；
- (2) SA 有需求，即 $n_i \neq 0$ ，才可以进行服务；
- (3) SA 达到等待截止时间，即 $y_i = J_i$ ，必须进行服务。

2.3 状态转移

设第 k 个决策时刻，系统的状态为 $s(k)=\{p(k), g(k), b(k), \bar{n}(k), \bar{y}(k)\}$ ，经容许行动 $\bar{a}(k)$ ，转移到下一时刻状态 $s(k+1)=\{p(k+1), g(k+1), b(k+1), \bar{n}(k+1), \bar{y}(k+1)\}$ 。各个状态变化如下：

- (1) 电价状态 $p(k)$ ，光伏发电等级 $g(k)$ 按照马尔可夫链变化。

- (2) 电池等级变化为：

$$b(k+1) = b(k) + v(k) + g(k) \quad (2)$$

- (3) 当前需求服务周期变为：

$$\bar{n}(k+1) = \bar{n}(k) - \bar{u}(k) + \bar{d}(k+1) \cdot T_i \quad (3)$$

- (4) 等待周期变为：

$$y_i(k+1) = \begin{cases} 0 & n_i(k)=0 \\ 0 & n_i(k)=1, u_i(k)=1 \\ y_i(k) & n_i(k)>1, u_i(k)=1 \\ y_i(k)+1 & n_i(k)>=1, u_i(k)=0 \end{cases} \quad (4)$$

2.4 状态转移概率

电价状态转移概率为 $P_{p(k)p(k+1)}^p$ ，光伏发电功率等级转移概率为 $P_{g(k)g(k+1)}^g$ ，电池电量按公式(2)变化。负载状态包括需求服务时间及等待周期，负载需求服务时间 $\bar{n}(k)$ 经容许行动 $\bar{u}(k)$ ，转移到下一状态 $\bar{n}(k+1)$ 的概率为

$$P_{\bar{n}(k)\bar{n}(k+1)}^{\bar{u}(k)} = \prod_{i=1}^{i=R} P_{n_i(k)n_i(k+1)}^{u_i(k)} \quad (5)$$

对于任意设备 i ，负载需求服务时间有下列 3 种情况的转移概率：

- (1) $n_i(k)>1$ ，容许行动 $u_i(k) \in \{0,1\}$ ， $n_i(k+1)=n_i(k)-u_i(k)$ 的概率为 1；

- (2) $n_i(k)=1$ ，容许行动 $u_i(k) \in \{0,1\}$ ，若 $u_i(k)=0$ ，那么 $n_i(k+1)=1$ 概率为 1；若 $u_i(k)=1$ ，那么 $n_i(k+1)=T_i$ 的概率为 P_i ， $n_i(k+1)=0$ 概率为 $1-P_i$ ；

- (3) $n_i(k)=0$ ，则容许行动 $u_i(k)=0$ ， $n_i(k+1)=T_i$ 概率为 P_i ， $n_i(k+1)=0$ 概率为 $1-P_i$ 。

由公式(4)可以看出，SA 等待时间的下一状态 $\bar{y}(k+1)$ 由当前状态 $\bar{y}(k)$ ， $\bar{n}(k)$ 及容许行动 $\bar{u}(k)$ 决定，当前状态及行动确定后，对于任意设备 i ， $y_i(k+1)$ 按公式(4)变化。综上所述，状态转移概率 $P_{s(k)s(k+1)}^{\bar{a}(k)}$ 为以上各个状态分量变化概率的乘积。

2.5 周期 k 获得的即时报酬

系统在周期 k 内获得的报酬包括行动获得的经济报酬以及负载等待的满意度报酬：

$$r(k) = r_1(k) + r_2(k) \quad (6)$$

其中经济报酬为系统服务用户获得报酬减去光伏发电代价与系统从电网购电代价：

$$r_1(k) = w(k) \cdot p^d - f_s - h(k) \cdot p^r(k) \quad (7)$$

我们假设从电网买电电价比向电网售电电价高，即：

$$p^r(k) = \begin{cases} p(k) & h(k) \geq 0 \\ p(k) - \xi & h(k) < 0 \end{cases} \quad (8)$$

式中， f_s 为光伏发电装置成本折算到每个决策周期的使用代价， $h(k)=\bar{u}(k) \cdot \bar{\gamma}^T + v(k) \cdot \Delta \omega$ ， $w(k)=\bar{u}(k) \cdot \bar{\gamma}^T$ ， p^d 为服务用户获得的固定收益电价， ξ 为差价。

对于任意用电设备 i ，不满意代价 $f_i(k)$ 是等待周期 $y_i(k)$ 的函数， $f_i(k)$ 越大表示用户越希望尽快服务。 R 个用电设备的服务评价为：

$$r_2(k) = -\sum_{i=1}^R f_i(k) \quad (9)$$

2.6 最优化问题

由于系统当前动作会对将来的报酬产生影响, 因此定义如下无穷时段折扣报酬函数:

$$\eta^\pi = (1-\gamma) \lim_{L \rightarrow \infty} E \left[\sum_{l=0}^{L-1} \gamma^l r(s(k+l), a(k+l)) \right] \quad (10)$$

式中 γ 为折扣值。

本文的优化目标是合理调度储能系统能量和控制负载接入时间, 使整个系统在无穷时段报酬最大, 即实现用户收益最大化。

2.7 Q 学习优化算法

本文采用 Q 学习优化算法对策略进行优化。Q 学习算法是由 Watkins 提出的一种模型无关的强化学习方法^[19], 1992 年, Watkins 与 Dayan 初步证明了它的收敛性^[20]。1994 年, Jaakkola 与 Jordan 等人进行了详细的泛化证明^[21]。Q 学习迭代时采用状态-行动对的奖赏和 $Q^*(s(k), a(k))$ 作为估计函数, 因此系统每一步学习迭代都需要考察每一个行为, 确保学习过程收敛。Q 学习算法基本形式可变化为:

$$Q(s(k), a(k)) = (1-\gamma)Q(s(k), a(k)) + \gamma(r(k) - \eta + \alpha \max_{a(k+1) \in D} Q^*(s(k+1), a(k+1))) \quad (11)$$

式中, η 为平均报酬, γ 为折扣值, α 为学习步长, D 为动作集, $s(k+1)$ 为状态 $s(k)$ 采取行动 $a(k)$ 的下一状态。

Q 学习算法首先初始化 Q 值, 当系统在状态 $s(k)$ 时, 根据 ε -贪心策略确定行动 $a(k)$, 得到经验知识以及训练例 $\langle s(k), a(k), s(k+1), r(k+1) \rangle$, 根据公式(12)更新 Q 值。最优行动为在状态 i 下 Q 值最大的行为。

3 仿真结果分析

在本文考虑的储能系统能量调度与需求响应相结合的优化问题中, 系统的各个参数对长期报酬都有不同程度的影响。取 SA 个数为 2, 取系统参数如表 1 所示, 分别取折扣值 $\gamma=1$ 与 $\gamma=0.98$, 在 MATLAB R2013 环境下进行 Q 学习与理论计算, 得到的系统的平均报酬与折扣报酬如图 2~3。

表 1 部分仿真参数表

参数名	参数值
电池容量最大等级	2
电池容量	1.5 kw·h
发电能量最大等级	2
一周发电代价 f_s (元)	0.1
买电电价(元)	[0.35, 0.6, 0.8]
差价 ξ (元)	0.05
周期时间	30 min
SA1 功率	0.5 kw
SA2 功率	0.4 kw
SA1 到达率	0.6
SA2 到达率	0.6
SA1 等待截止周期	2
SA2 等待截止周期	2
SA1 等待代价	$0.005(1 - e^{0.4a_1})$
SA2 等待代价	$0.002(1 - e^{0.4a_2})$




图 2 联合优化 Q 学习结果图




图 3 联合优化理论计算结果图

由图 2 可以看出平均报酬与折扣报酬值随着 Q 学习步数的增加逐渐增加, 最终稳定。图 2 与图 3 比较可见 Q 学习结果接近理论计算结果, 说明了 Q 学习的有效性。图中状态详细值如表 2 所示。

表 2 部分状态值

状态	p	g	b	n_1	y_1	n_2	y_2
138	1	0	2	2	2	2	1
432	1	2	2	2	2	2	1
907	3	0	0	2	0	2	0
922	3	0	0	2	2	2	1
1 020	3	0	2	2	2	2	1

由表 2 可以看出, 状态 432 较 138 折扣报酬值较大是因为其光伏发电等级较大, 系统拥有更多的电量; 状态 907 较 922 折扣报酬值较大是由于其前者的负载等待时间未到截止时间, 可以进行延时服务, 提高报酬值; 状态 1020 较 907 折扣报酬值较大由于其电池电量等级较高, 可以对电网卖电或者对负载进行服务, 获得收益; 状态 1020 比状态 138 电价状态高, 其余值相等, 状态 138 的折扣报酬值较大, 可见电价对报酬也是有影响的。

分别用优化后的策略与未优化的策略对系统进行仿真, 分别统计运行多步后系统与电网交互总电量以及获得报酬、负载用电量以及所用代价, 得到优化前后的平均售电电价和平均用电电价对比图, 如图 4。




图 4 优化前后经济性对比图

由图 4 可以看到优化后系统向电网售电的平均电价升高约 0.22 元, 而用电设备的平均用电电

价降低了约 0.04 元。因此优化后的系统更具经济性。

下面分析 SA 与储能系统特性对平均报酬的具体影响。

1. SA 特性对平均报酬的影响

(1) SA 可延时周期对平均报酬的影响

为了获得负载可延时周期对报酬的具体影响, $f_1 = 0.005(1 - e^{0.4y_1})$, $f_2 = 0.1(1 - e^{0.4y_2})$, 通过理论计算得到报酬的平均值, 如图 5。




图 5 负载可延时周期对系统经济性影响

由图 5 可以看出, SA 等待代价较小时, 负载等待截止周期变大, 系统的平均报酬增加。随着等待截止周期增加, 平均报酬的增加量越来越小, 我们可以推断负载等待截止周期的影响是有限的, 等待截止周期增加到一定值时, 平均报酬将不再改变。而当等待代价较大时, 增加等待截止周期并不能获得更多的平均报酬, 这是因为系统选择尽快服务负载, 避免产生等待代价。

等待截止周期为 0 时, 系统只有储能系统可以进行优化, 由图 5 可见, 负载等待代价较低时, 联合优化比单独进行储能优化效果要好。

(2) 不同等待代价下 SA 到达率对平均报酬的影响

当等待代价较低时, 系统可以通过延时服务 SA, 使用较低的电价获得报酬; 等待代价较高时, 系统通过延时获得的报酬无法抵消等待代价, 因此会选择尽快处理服务需求, 用电代价较高。下表为

取 SA1 等待代价分别为 $f_1 = 0.001(1 - e^{0.4y_1})$ 和 $f_1' = 0.1(1 - e^{0.4y_1})$, SA1 到达率分别为 0.2, 0.4, 0.6, 0.8, SA2 到达率为 0 时, 系统获得的平均报酬。

表 3 不同等待代价下到达率对系统经济性影响

负载 1 到达率	f_1	f_1'
0.2	0.269 7	0.263 4
0.4	0.270 5	0.259 5
0.6	0.271 0	0.256 6
0.8	0.271 3	0.254 4

由表 3 可以看出, 等待代价较低时, 系统获得的平均报酬随着到达率增大而增大; 等待代价较高时, 到达率增大会使平均报酬降低。这是因为等待代价较低时, 系统可以通过延时对负载服务获得收益, 而等待代价较高则会消除延时带来的收益。

2. 储能系统特性对平均报酬的影响

为了方便优化处理, 本文将蓄电池容量等间距地进行离散。蓄电池容量大小反映了其存储电能的能力, 容量越大, 存储电能能力越强。蓄电池既可以存储分布式发电单元产生的电能, 也可以存储在电价较低时从电网所购电能。当电价较高时, 可以使用蓄电池中的电能为用电设备提供服务, 从而减少用电代价。取电池最大容量等级为 0 到 4, 分别取峰值电价为 0.8, 0.85, 0.9, 0.95 对系统进行仿真, 得到的平均报酬值如图 6; 取光伏发电功率等级稳态变化概率为 [0.2, 0.3, 0.5], [0.2, 0.4, 0.4] 和 [0.2, 0.5, 0.3], 分别表示发电能力优秀、良好和中等, 仿真得到的报酬平均值如图 7 所示。




图 6 电池最大容量等级对系统经济性影响 1




图 7 电池最大容量等级对系统经济性影响 2

由图 6, 电池容量较大时, 峰值电价引起的经济性较明显, 这说明大容量可以更好的利用电价的变化为系统带来收益。由图 7 可以看出, 电池容量确定后, 分布式发电能力变化对经济性的影响是线性的。

图 6~7 说明适量增加电池容量可以增强系统对能量的缓冲能力, 使系统获得的平均报酬增加。电池容量为 0 时, 系统进行需求响应优化, 由仿真结果可以看出联合优化比单纯需求响应优化能获得更高的报酬。

然而平均报酬的增量随着电池容量的变大逐渐降低, 最后为 0, 说明电池的缓冲作用对平均报酬的影响是有限的。由于储能系统的投资代价与其容量基本成正比, 但是系统所需电池容量是有限的, 超出系统所需会造成容量投资的浪费。因此在实际系统中可以根据分布式发电能力及电池使用寿命合理考虑电池容量的大小。

4 结论

智能电网允许多种不同的分布式发电单元接入, 且电价随电力市场变化, 与用户进行双向互动。合理调度储能单元能量及控制需求响应成为实现智能电网用户高效节能用电的重要途径。本文建立了储能系统能量调度与需求响应相结合的联合优化系统模型, 将系统建立为马尔可夫决策过程, 采用 Q 学习算法对策略进行优化。仿真结果显示联合优化效果要比单独进行储能系统能量调度或需

求响应控制效果更好。在后续的研究工作中, 我们考虑减少系统状态, 只用仿真的办法对系统进行优化, 避免陷入维数灾。

参考文献:

- [1] 刘振亚. 智能电网技术 [M]. 北京: 中国电力出版社, 2010: 17-88.
- [2] 刘振亚. 智能电网知识读本 [M]. 北京: 中国电力出版社, 2010: 100-117.
- [3] 秦立军, 马其燕. 智能配电网及其关键技术 [M]. 北京: 中国电力出版社, 2010: 149-184.
- [4] E Hossain, H Zhu, H Vincent Poor. 智能电网通信及组网技术 [M]. 北京: 电子工业出版社, 2013: 38-45.
- [5] T Huang, D R Liu. A Self-learning Scheme for Residential Energy System Control and Management [J]. Neural Comput & Applic (S2161-4393), 2013, 22(2): 259-269.
- [6] S Squartini, M Boaro, D Fuselli, et al. Adaptive Dynamic Programming Algorithm for Renewable Energy Scheduling and Battery Management [J]. Cogn Comput (S1866-9956), 2012, 5(2): 323-328.
- [7] A Saber, G Venayagamoorthy. Plug-in Vehicles and Renewable Energy Sources for Cost and Emission Reductions [J]. IEEE Trans. Industrial Electronics (S0278-0046), 2011, 58(4): 1229-1238.
- [8] 李春华, 朱新坚, 吉小鹏. 光伏系统中蓄电池管理策略研究 [J]. 系统仿真学报, 2012, 24(11): 2378-2382.
- [9] S C Lee, S J Kim, S H Kim. Demand Side Management with Air Conditioner Loads Based on the Queuing System Model [J]. IEEE Trans. Power Systems (S0885-8950), 2011, 26(2): 661-668.
- [10] D O'Neill, M Levorato, A Goldsmith, et al. Residential Demand Response Using Reinforcement Learning [C]// First IEEE Internet Conference on Smart Grid Communications. USA: IEEE, 2011: 409-414.
- [11] J Medina, N Muller, I Roytelman. Demand Response and Distribution Grid Opportunities and Challenges [J]. IEEE Trans. Smart Grid (S1949-3053), 2010, 1(2): 193-197.
- [12] W B Shi, V W S Wong. Real-Time Vehicle-to-Grid Control Algorithm under Price Uncertainty [C]// IEEE Smart Grid Comm. USA: IEEE, 2011: 261-266.
- [13] Y Cao, T Jiang, Q Zhang. Reducing Electricity Cost of Smart Appliances via Energy Buffering Framework in Smart Grid [J]. IEEE Trans on Parallel and Distributed Systems (S1045-9219), 2012, 23(9): 1572-1582.
- [14] D Wang, S Y Ge, H J Jia, et al. A Demand Response and Battery Storage Coordination Algorithm for Providing Microgrid Tie-Line Smoothing Services [J]. IEEE Trans on Sustainable Energy (S1949-3029), 2014, 5(2): 476-486.
- [15] W B Shi, N Li, X R Xie. Optimal Residential Demand Response in Distribution Networks [J]. IEEE Journal on Selected Areas in Communications (S0733-8716), 2014, 32(7): 1441-1450.
- [16] B Li, S Gangadhar, S Cheng, et al. Maximize User Rewards in Distributed Generation Environments using Reinforcement Learning [C]// IEEE Energy Tech. USA: IEEE, 2011: 1-6.
- [17] P Poggi, G Notton, M Muselli, et al. Stochastic Study of Hourly Total Solar Radiation in Corsica Using a Markov Model [J]. Int'l J. Climatology (S1097-0088), 2000, 20(14): 1843-1860.
- [18] D Niyato, E Hossain, A Fallahi. Sleep and Wakeup Strategies in Solar-Powered Wireless Sensor/Mesh Networks: Performance Analysis and Optimization [J]. IEEE Transactions on Mobile Computing (S1536-1233), 2007, 6(2): 221-236.
- [19] 高阳, 陈世福, 陆鑫. 强化学习研究综述 [J]. 自动化学报, 2004, 1(30): 86-97.
- [20] C J C H Watkins, P Dayan. Q-learning [J]. Machine Learning, 1992, 8(3-4): 279-292.
- [21] T Jaakkola, M Jordan, S Singh. On The Convergence of Stochastic Iterative Dynamic Programming Algorithms [J]. Natural Computations (S0899-7667), 1994, 6(6): 1185-1201.