

新型配电系统分布式源网荷储资源 广域电压自趋优管控方法

卢宇¹, 向月¹, 刘俊勇¹, 曾平良²

- (1. 智能电网四川省重点实验室(四川大学), 四川 成都 610065;
2. 区域能源互联网技术浙江省工程实验室(杭州电子科技大学), 浙江 杭州 310018)

摘要:不同于单纯电能分配的传统配电网,新型配电系统逐步展现出源-网-荷-储等众多资源的强耦合强关联复杂大系统形态,其各类资源呈现出“点多、面广、量少”的广域分布特征。挖掘可再生能源发电、分布式储能及柔性负荷等分布式资源的广域电压调控潜力对构建源网荷储深度融合的新型配电系统具有重要意义。文中提出了一种基于数据驱动的新型配电系统分布式源网荷储资源广域电压自趋优管控方法,通过可再生能源发电、储能及柔性负荷等分布式资源的综合协同控制,在保证储能后备容量和降低网损的同时能够提高配电网广域电压质量。最后,以某城市配电网为例验证了所提方法的有效性和先进性,比传统调压方法更加契合新型配电系统的电压调控需求。

关键词:新型配电系统; 广域电压控制; 分布式源网荷储资源; 深度强化学习

中图分类号: TM 761 文献标志码: A 文章编号: 1003-6954(2023)03-0001-08

DOI: 10.16527/j.issn.1003-6954.20230301

Wide-area Voltage Self-optimization Control of Distributed Generation-Grid-Load-Storage Resources in Novel Distribution Systems

LU Yu¹, XIANG Yue¹, LIU Junyong¹, ZENG Pingliang²

- (1. Sichuan Province Key Lab of Smart Grid (Sichuan University), Chengdu 610065, Sichuan, China; 2. Engineering Laboratory of Regional Energy Internet Technology (Hangzhou Dianzi University), Hangzhou 310018, Zhejiang, China)

Abstract: Differing from the traditional distribution network which is a pure power distribution system, the novel distribution system gradually shows the form of a large complex system with strong coupling and strong correlation of generation-grid-load-storage. These resources show the characteristics of wide-area distribution with many points, wide area and small amount. It is of great significance to explore the wide-area voltage regulation potential of distributed resources such as renewable energy generation, distributed energy storage and flexible load to the novel distribution system. A wide-area voltage self-optimization control method considering distributed generation-grid-load-storage for data-driven novel distribution system is proposed, the wide-area voltage quality of distribution network is improved through integrated cooperative control of these distributed resources, which can ensure backup capacity of energy storage and reduce network loss at the same time. Finally, taking an urban distribution network for example, the effectiveness and advancement of the proposed method are verified, which is more suitable for the voltage regulation requirements of novel distribution system than the traditional voltage regulation method.

Key words: novel distribution system; wide-area voltage control; distributed generation-grid-load-storage resources; deep reinforcement learning

0 引言

在全球能源“低碳”大趋势下,以风光为主的可再生分布式发电(renewable distribution generation, RDG)、分布式储能(energy storage system, ESS)及柔性负荷(flexible load, FL)等分布式资源在配电网中的渗透率逐年升高^[1]。2021年3月,中央财经委员会第九次会议提出要构建以新能源为主体的新型电力系统^[2];2022年8月,四川省提出积极推进源网荷储一体化,积极构建源网荷储深度融合的新型电力系统发展模式^[3]。

然而,作为新型电力系统的重要物理载体和基石,新型配电系统中众多可调控资源不确定性、开放性、复杂性的增加给上述目标的实现,特别是保证配电系统电压质量带来巨大挑战,比如电压越限、电压突变等事故的发生^[3]。因此,充分挖掘源网荷储等分布式资源的广域电压调控潜力对建立源网荷储灵活高效、互动互济的新型配电系统可靠运行体系具有重要意义。

就调控设备而言,传统的电压调控主要是通过控制电网中的无功调节设备如有载调压变压器(on-line tap changer, OLTC)、并联电容器(parallel capacitor bank, PCB)组和静止无功补偿器(static var compensator, SVC)调节。这些机械装置通过改变配电网的潮流分布进行电压管控,调控能力与其在配电网中的安装位置强相关,因此无法有效调节馈线远端的电压^[4];另外,由于设备动作周期较长、动作较慢而无法适应新型配电系统中RDG和负荷的快速波动^[5]。随着新型电力电子器件的发展,新型电压调控设备如风光逆变器和ESS应运而生,风光通过新型逆变器可以为电网提供快速灵活的无功电压支撑^[6],另外配电网中较高的R/X比使得有功功率在电压控制方面和无功功率同样有效,因此ESS通过调节充放电功率能够补偿RDG的有功出力间接性,提高电压质量^[7-8]。

就调控方法而言,现有电压调控模型多为基于最优潮流^[9]的混合整数非线性规划问题,由于系统中存在整数和非线性状态变量,该模型通常是非凸的和NP-hard问题^[10]。但是这些方法存在计算速度慢^[11]、优化模型复杂^[12]等问题,一方面这些方法具有较高的建模依赖性,而另一方面准确描述某些

非线性电力电子器件特性的系统模型非常困难^[13]。当以上基于模型的方法遇到瓶颈时,不需要精确的系统模型且具有快速响应速度的数据驱动方法应运而生,其中,深度强化学习(deep reinforcement learning, DRL)正成为研究者关注的热点^[14]。文献[15]提出了利用深度神经网络技术求解配电网动态最优潮流问题。文献[16]将自动电压无功控制(automatic voltage control, AVC)问题通过启发式分割智能体方法建模为马尔可夫博弈过程。文献[8]将储能运行行为建模为马尔可夫决策过程并使用DRL方法进行求解,算例仿真表明储能可以控制配电网有功功率的动态平衡以有效改善系统电压分布。上述研究虽然使用了数据驱动的方法,但未充分挖掘配电系统中多种分布式资源的综合协调互动在配电网广域电压调控中的巨大潜力。

因此,下面提出一种基于数据驱动的新型配电系统分布式源网荷储广域电压自趋优管控方法,通过源-网-荷-储的综合协同控制实现配电网的广域电压调控。首先,考虑新型电力系统中广域分布式资源模型,以保证储能后备容量、降低网损、提高电压质量为目标函数,提出了分布式源-网-荷-储广域电压管控模型;然后,将该模型建模为非中心部分可观马尔可夫决策过程(decentralized partially observable markov decision process, Dec-POMDP),使用基于数据驱动的多智能体深度确定性策略梯度(multi-agent deep deterministic policy gradient, MADDPG)算法求解;最后,以某中型城市配电网算例对所提方法的有效性和先进性进行验证。

1 广域分布式资源模型

1.1 光伏发电系统

光伏发电系统利用光伏板将太阳能转换成电能,由电池阵列、控制器、电力电子逆变器等元件组成。其中,逆变器是光伏并网发电系统的核心,通过控制逆变器实现光伏有功无功解耦控制。有功无功解耦模型如下:

$$Q_{PV} = a_{PV} \sqrt{S_{PV}^2 - P_{PV}^2} \quad (1)$$

$$a_{PV}^{\min} \leq a_{PV} \leq a_{PV}^{\max} \quad (2)$$

式中: S_{PV} 为光伏逆变器的最大容量; a_{PV} 为光伏逆变器的无功系数。当 $a_{PV} > 0$ 时,逆变器发出无功;当

$a_{PV} < 0$ 时,逆变器吸收无功。夜间逆变器基于静止同步补偿器 (static synchronous compensator, STATCOM) 模式产生无功功率^[17]。

1.2 风力发电系统

风力发电系统通过风力发电机将风能转化为电能。随着新型电力电子器件的发展,风力发电同样可以通过控制逆变器实现有功无功的解耦控制。有功无功解耦模型如下:

$$Q_{WT} = a_{PV} \sqrt{S_{WT}^2 - P_{WT}^2} \quad (3)$$

$$a_{WT}^{\min} \leq a_{WT} \leq a_{WT}^{\max} \quad (4)$$

式中: S_{WT} 为风电逆变器的最大容量; a_{WT} 为风电逆变器的无功系数。当 $a_{WT} > 0$ 时,逆变器发出无功功率;当 $a_{WT} < 0$ 时,逆变器吸收无功功率。

1.3 分布式储能模型

分布式储能系统具有负荷与电源的双重特性,可以通过自身的充放电吸收过剩电能或补充功率缺额。分布式储能模型主要包括容量递推模型、充放电功率模型和容量模型,如式(5)~式(9)所示。

$$E_{ESS}(t+1) = E_{ESS}(t)(1 - \sigma_{sdr}) + P_{ESS}(t)a_{ESS} \quad (5)$$

$$S_{oc}(t) = \frac{E_{ESS}(t)}{E_{ESS}^{\max}} \quad (6)$$

$$P_{dc}^{\max} \leq P_{ESS}(t) \leq P_c^{\max} \quad (7)$$

$$a_{ESS}^{\min} \leq a_{ESS} \leq a_{ESS}^{\max} \quad (8)$$

$$E_{ESS}^{\min} \leq E_{ESS}(t) \leq E_{ESS}^{\max} \quad (9)$$

式中: $E_{ESS}(t)$ 、 $P_{ESS}(t)$ 、 $S_{oc}(t)$ 分别为分布式储能在时刻 t 的容量、充放电功率、荷电状态 (state of charge, SOC); σ_{sdr} 为储能介质的自放电率; a_{ESS} 为分布式储能的充放电系数; P_c^{\max} 、 P_{dc}^{\max} 为 ESS 最大充、放电功率; E_{ESS}^{\min} 、 E_{ESS}^{\max} 为 ESS 容量上、下限。

1.4 柔性负荷模型

随着电动汽车、智能空调和热控负荷等设备的发展,为新型配电系统提供了众多可控的柔性负荷资源。柔性负荷可以通过主动调整自身的用电量和用电时段来提高配电网运行可靠性,按照调整方式的不同可分为可平移负荷、可转移负荷和可削减负荷,这里主要考虑可削减负荷。可削减负荷是指时间上不可转移,但在一定时间内的需求量可以灵活增减的负荷^[18],模型为:

$$P_{FL}^{\text{after}} = (1 + a_{FL})P_{FL}^{\text{before}} \quad (10)$$

$$a_{FL}^{\min} \leq a_{FL} \leq a_{FL}^{\max} \quad (11)$$

式中: P_{FL}^{before} 、 P_{FL}^{after} 分别为柔性负荷参与需求响应前、

后的需求量; a_{FL} 为柔性负荷的需求响应系数。

2 分布式源网荷储广域电压管控模型

在 RDG、ESS、柔性负荷等分布式资源大规模接入的新型配电系统中,通过调控 RDG 逆变器的无功输出为配电网提供无功支撑,通过调控储能充放电功率和柔性负荷参与需求侧响应实现配电网有功平衡,达到源网荷储的协调互动,保证各节点电压在安全范围内。下面构建了以保留储能后备容量、降低网损和使各节点电压始终在安全范围为目标的分布式源网荷储广域电压管控模型,所提模型包含的目标函数和约束条件如下所示。

2.1 目标函数

广域电压管控的目标函数是在保证储能后备容量和最小化网络无功损耗的同时,使各节点电压始终在安全范围内。

$$\min F(P(i,t), Q(i,t)) = \partial_1 F_v + \partial_2 F_{ESS} + \partial_3 F_{P_{loss}} \quad (12)$$

$$F_v = \sum_{i \in T} \frac{1}{N} \left[\sum_{i \in N} 2(v(i,t) - v_{ref})^2 \right] \quad (13)$$

$$F_{ESS} = \sum_{i \in V_{ESS}} |S_{oc}(i,t) - S_{oc}(i,0)| \quad (14)$$

$$F_{P_{loss}} = \sum_{i \in T} \frac{P_{loss}(t)}{S_N} = \sum_{i \in T} \frac{|I_{ij}(t)|^2 r_{ij}}{S_N} \quad (15)$$

$$\partial_1 + \partial_2 + \partial_3 = 1 \quad (16)$$

式中: $P(i,t)$ 、 $Q(i,t)$ 、 $v(i,t)$ 分别为节点 i 在时刻 t 的有功功率、无功功率和电压幅值; F_v 、 F_{ESS} 、 $F_{P_{loss}}$ 分别为对应节点电压质量目标函数、储能后备容量目标函数和网络有功损耗目标函数; ∂_{1-3} 为权重系数; $S_{oc}(i,t)$ 和 $S_{oc}(i,0)$ 分别为安装在节点 i 上的 ESS 在时刻 t 和初始时的荷电状态; N 、 T 、 V_{ESS} 分别为配电节点集合、电压调控周期和 ESS 安装节点集合; $I_{ij}(t)$ 和 r_{ij} 为支路 (i,j) 上时刻 t 的电流幅值和支路电阻; S_N 为网络参考视在功率。

2.2 约束条件

约束条件包括配电网拓扑约束、配电网潮流约束、分布式 RDG 的无功出力约束、ESS 充放电功率和容量约束、柔性负荷参与需求响应的功率约束。

1) 配电网拓扑约束

$$K = (V, E) \quad (17)$$

配电网拓扑约束包括配电网拓扑 K 中所有的

节点 V 和支路 E 集合。

2) 配电网潮流约束

$$P_S(t) + P_{PV}(i,t) + P_{WT}(i,t) + P_{ESS}(i,t) - P_{FL}^{after}(i,t) - P_{Load}(i,t) = v^2(i,t) \sum_{j \in V_i} g_{ij} - v(i,t) \sum_{j \in V_i} v(j,t) (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (18)$$

$$Q_S(t) + Q_{PV}(i,t) + Q_{WT}(i,t) - Q_{Load}(i,t) = -v^2(i,t) \sum_{j \in V_i} b_{ij} + v(i,t) \sum_{j \in V_i} v(j,t) (g_{ij} \sin \theta_{ij} + b_{ij} \cos \theta_{ij}) \quad (19)$$

式中: $P_S(t)$ 、 $Q_S(t)$ 分别为平衡节点注入有功、无功功率; $P_{PV}(i,t)$ 、 $Q_{PV}(i,t)$ 分别为节点 i 上 PV 在时刻 t 的有功、无功出力; $P_{WT}(i,t)$ 、 $Q_{WT}(i,t)$ 分别为节点 i 上 WT 在时刻 t 的有功、无功出力; $P_{ESS}(i,t)$ 为安装在节点 i 上的 ESS 在时刻 t 的充放电功率; $P_{FL}^{after}(i,t)$ 为节点 i 上的柔性负荷参与需求侧响应后的有功功率; $P_{Load}(i,t)$ 、 $Q_{Load}(i,t)$ 为分别节点 i 上负荷在时刻 t 的有功、无功需求; j 为与节点 i 相连的节点集合, $j \in V_i$; g_{ij} 、 b_{ij} 分别为支路 ij 上的电导、电纳; θ_{ij} 为节点 i 、 j 之间的相位差。

3) 分布式 RDG 的无功出力约束

$$Q_{PV}^{\min}(i,t) \leq Q_{PV}(i,t) \leq Q_{PV}^{\max}(i,t) \quad (20)$$

$$Q_{WT}^{\min}(i,t) \leq Q_{WT}(i,t) \leq Q_{WT}^{\max}(i,t) \quad (21)$$

式中: $Q_{PV}^{\max}(i,t)$ 、 $Q_{PV}^{\min}(i,t)$ 分别为节点 i 上 PV 在时刻 t 的无功出力上、下限; $Q_{WT}^{\max}(i,t)$ 、 $Q_{WT}^{\min}(i,t)$ 分别为节点 i 上 WT 在时刻 t 的无功出力上、下限。

4) ESS 充放电功率和容量约束

$$P_{dc}^{\max} \leq P_{ESS}(i,t) \leq P_{dc}^{\max} \quad (22)$$

$$E_{ESS}^{\min} \leq E_{ESS}(i,t) \leq E_{ESS}^{\max} \quad (23)$$

5) 柔性负荷参与需求响应的功率约束

$$P_{FL}^{\min} \leq P_{FL}^{after} \leq P_{FL}^{\max} \quad (24)$$

3 基于 MADRL 的电压管控方法

所提出的基于多智能体深度强化学习 (multi-agent deep reinforcement learning, MADRL) 的电压管控方法, 将 PV、WT、ESS、柔性负荷等分布式资源建模为神经网络组成的智能体, 将配电网建模为多智能体环境。多智能体通过与环境交互感知并适应配电网中源网荷储状态的变化并调节自身动作, 最终实现对配电网电压的广域分布式控制。

广域分布式控制如图 1 所示。首先, 将配电网

通过网络分区的方法建模为多智能体环境; 然后, 将分布式广域电压管控问题建模为 Dec-POMDP; 最后, 使用 MADDPG 算法求解所提 Dec-POMDP。

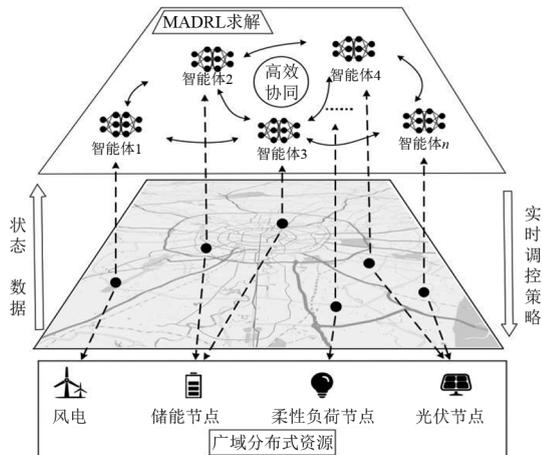


图 1 广域分布式控制

3.1 网络分区

新型配电系统中的分布式资源具有“点多、面广、量少”的特征。如果对所有分布式资源采取传统集中控制, 会导致变量过多、控制过程复杂等问题。另外, 传统集中式控制难以有效保障新型配电系统中源网荷储的高效协同运行。因此, 将配电网划分为若干控制区, 每个控制区含有一个或多个分布式资源, 不同区域内分布式资源的控制相互独立, 即每个控制区内的分布式资源只观测本地信息并接收反映全局电压状态的反馈, 可以实现对分布式资源的广域分布式控制。

网络分区过程为: 首先, 确定配电内部的电压等级, 不同电压等级的区域属于不同控制区; 然后, 在相同电压等级的区域, 按照最短路径的分区方法, 先确定一条主馈线, 将其他馈线的终端节点到主馈线的最短路径视为一个控制区, 保证每个控制区包含一个或多个分布式资源。

3.2 Dec-POMDP 建模

MADRL 是对深度强化学习问题的扩展, 环境有多个智能体, 依靠智能体之间的协调互动探索环境并完成共同目标。多智能体之间合作的 DRL 问题通常被表述为 Dec-POMDP。Dec-POMDP 通常由一组元组表示, 即 $\langle I, S, A, O, T, \rho, \gamma \rangle$ 。其中: I 为智能体集; S 为状态集; A 为联合动作集, $A = \{A_r, r \in I\}$, A_r 为智能体 r 的动作集; O 为联合观测集, $O = \{O_r, r \in I\}$, O_r 为智能体 r 的动作集; $T: S \times A \times S \rightarrow [0, 1]$ 为描述环境动态变化的状态转移函数; R

为描述所有智能体在当前动作下的全局奖励函数; $\rho: S \rightarrow [0, 1]$ 为描述初始状态的概率函数; γ 为折扣系数,描述未来状态对当前奖励的影响。Dec-POMDP 框架中,所有智能体的目标是找到一个最优的联合策略以获得最大折扣奖励。分布式广域电压管控问题中 Dec-POMDP 模型如下所示。

1) 智能体集

将配电网中的 PV、WT、ESS 和柔性负荷等分布式资源视为智能体, PV、WT 通过控制逆变器来调节输出无功; ESS 通过控制自身充放电功率来调节与电网的交换有功; 柔性负荷通过控制需求响应系数来调节其参与需求响应的功率, 智能体集表示为

$$I = \{I_1, I_2, \dots, I_N\}, N = N_{PV} + N_{WT} + N_{ESS} + N_{FL} \quad (25)$$

式中: N 为全部智能体数量; N_{PV} 、 N_{WT} 、 N_{ESS} 、 N_{FL} 分别为 PV、WT、ESS、FL 的数量。

2) 状态集和观测集

状态集 S^t 包括所有智能体在时刻 t 的状态量。对于智能体 r , 状态集 S_r^t 包含智能体 r 在时刻 t 的状态量, 包括本区域内 PV 和 WT 有功无功出力、节点电压、有功无功负荷、ESS 充放电功率、SOC、柔性负荷参与需求响应后的有功功率。

$$S_r^t = \{P_{PV}(i, t), Q_{PV}(i, t), P_{WT}(i, t), Q_{WT}(i, t), v(i, t), P_{Load}(i, t), Q_{Load}(i, t), P_{ESS}(i, t), S_{oc}(i, t), P_{FL}^{after}(i, t)\} \quad (26)$$

式中, i 为对应分布式资源所在节点, $i \in Z_r$, Z_r 为智能体 r 所在区域。

观测集 O^t 包括所有智能体在时刻 t 的观测测量, 与状态集一致。

3) 动作集

动作集 A^t 包括所有智能体在时刻 t 的动作集。对于智能体 r , 动作集 A_r^t 包含智能体 r 在时刻 t 的动作。

$$A_r^t = \left\{ a_{PV}^1, \dots, a_{PV}^{N_{PV}}, a_{WT}^1, \dots, a_{WT}^{N_{WT}}, a_{ESS}^1, \dots, a_{ESS}^{N_{ESS}}, a_{FL}^1, \dots, a_{FL}^{N_{FL}} \right\} \quad (27)$$

$$a_{PV}^{\min} \leq a_{PV}^i \leq a_{PV}^{\max}, 1 \leq i \leq N_{PV} \quad (28)$$

$$a_{WT}^{\min} \leq a_{WT}^i \leq a_{WT}^{\max}, 1 \leq i \leq N_{WT} \quad (29)$$

$$a_{ESS}^{\min} \leq a_{ESS}^i \leq a_{ESS}^{\max}, 1 \leq i \leq N_{ESS} \quad (30)$$

$$a_{FL}^{\min} \leq a_{FL}^i \leq a_{FL}^{\max}, 1 \leq i \leq N_{FL} \quad (31)$$

式中: a_{PV}^i 为 PV 逆变器的无功容量系数; a_{WT}^i 为 WT 逆变器的无功容量系数; a_{ESS}^i 为 ESS 的充放电功率

系数; a_{FL}^i 为柔性负荷的需求响应系数。

4) 奖励函数

奖励函数 R^t 为时刻 t 所有智能体在状态 S^t 下执行动作 A^t 获得的实时奖励, 参考优化目标式 (12)~式 (16), 奖励函数为:

$$R_1^t = - \sum_{i \in T} \frac{1}{N} \left[\sum_{i \in N} 2 (v(i, t) - v_{ref})^2 \right] \quad (32)$$

$$R_2^t = - \sum_{i \in V_{ESS}} \frac{1}{N_{ESS}} |S_{oc}(i, t) - S_{oc}(i, 0)| \quad (33)$$

$$R_3^t = - \sum_{i \in T} P_{loss}(t) \quad (34)$$

$$R^t = \begin{cases} \partial_1 R_1^t + \partial_2 R_2^t + \partial_3 R_3^t & 0 \leq S_{oc}(i, t) \leq 1 \\ R_{done} & \text{else} \end{cases} \quad (35)$$

式中: R_1^t 为节点电压奖励; v_{ref} 为节点参考电压; R_2^t 为 ESS 中 SOC 奖励; R_3^t 为网络损耗奖励; R_{done} 为一个很大的惩罚项。

3.3 MADDPG 算法求解

MADDPG 算法是一种基于 Actor-Critic 框架的多智能体深度强化学习算法, 每个智能体有自己的 Actor 网络和 Critic 网络。Actor 网络以智能体观测集 O_r^t 为输入, 做出的最优动作集为输出。Critic 网络以智能体状态集和动作集为输入, 对 Actor 网络决策的评价为输出。整个算法结构可以解释为使用 Actor 网络进行策略探索, 使用 Critic 网络作为策略的评价者, 对 Actor 网络的探索策略进行评估比较并得出最终的优质策略。

1) 在 Actor 网络中, 智能体 r 的动作探索可以表示为

$$A_r^t = \pi_r(O_r^t | \theta_r^r) + N(0, \sigma_r^t) \quad (36)$$

式中: $\pi_r(O_r^t | \theta_r^r)$ 为智能体 r 的动作函数; $N(0, \sigma_r^t)$ 为正态分布噪声。

根据所提广域分布式电压调控模型, 目标动作值函数定义为

$$Q_r(S^t, A^t) = - (\partial_1 R_1^t + \partial_2 R_2^t + \partial_3 R_3^t), S^t \in D \quad (37)$$

式中: D 为经验回放池; ∂_1 、 ∂_2 和 ∂_3 分别为奖励权重因子。

以智能体 r 为例, 在每一次智能体 r 与环境交互过程中, 以动作值函数期望最大化为目标, 通过实现梯度上升方法更新 Actor 网络, 目标函数和梯度解析式为:

$$J(\theta_r^\pi) = \max_{S^t \sim D} E [Q_r(S^t, A^t)] \quad (38)$$

$$\nabla_{\theta_r^\pi} J(\theta_r^\pi) \approx E_{S^t \sim D} [\nabla_{\theta_r^\pi} Q_r(S^t, A_r^t = \pi_r(O_r^t | \theta_r^\pi), A_{-r}^t)] \quad (39)$$

式中: A_{-r}^t 为除 r 外其他智能体的动作集; θ_r^π 为智能体 r 的 Actor 网络参数。

2) 在 Critic 网络中, 以最小化损失函数为目标优化 Critic 网络参数 θ_r^Q , 表示为:

$$L(\theta_r^Q) = E_{S^t \sim D} [(Q_r(S^t, A_r^t, A_{-r}^t | \theta_r^Q) - y_r^t)^2] \quad (40)$$

$$y_r^t = rd_r^t + \gamma Q_r(S^t, A_r^t, A_{-r}^t | \theta_r^Q) \quad (41)$$

式中: θ_r^Q 为智能体的 Critic 网络参数; γ 为折扣系数。

为了提高学习的稳定性, 引入了 Target 网络^[19], Target 网络中包括参数 $\theta_r^{\pi'}$ 、 $\theta_r^{Q'}$, 分别与 Actor 网络参数 θ_r^π 和 Critic 网络参数 θ_r^Q 相对应。目标网络中的参数通过缓慢跟踪的方式更新到 Actor 和 Critic 网络, 更新表达式为:

$$\tau \theta_r^Q + (1 - \tau) \theta_r^{Q'} \rightarrow \theta_r^{Q'} \quad (42)$$

$$\tau \theta_r^\pi + (1 - \tau) \theta_r^{\pi'} \rightarrow \theta_r^{\pi'} \quad (43)$$

式中, τ 是一个接近于 0 的小值, 用于更新 Target 网络。

MADDPG 算法的集中训练过程如表 1 所示。

表 1 MADDPG 算法训练过程

步骤	训练过程
1)	For episode = 1, 2, ..., M do
2)	初始化环境, 包括 $t=0, rd^t=0, S^0, A^0$
3)	将 S^0, A^0 带入环境进行潮流计算, 并反馈给智能体
4)	For $t = 1, 2, \dots, T$ do
5)	通过式 (36) 获取 A^t , 通过潮流计算获取 S^{t+1}, A^t, rd^t 并反馈给智能体
6)	For agent = 1, 2, ..., J do
7)	将经验集 $\{S_r^t, A_r^t, r_r^t, S_r^{t+1}\}$ 放入回放经验池 D
8)	通过式 (38)、式 (39) 更新 Actor 网络参数
9)	通过式 (40)、式 (41) 更新 Critic 网络参数
10)	通过式 (42)、式 (43) 更新 Target 网络参数
11)	End if agent=R
12)	End if $t=T$
13)	End if episode=M

4 算例分析

4.1 场景与参数设置

算例采用四川某中型城市配电网拓扑结构, 如图 2 所示, 由一座 110 kV 变电站连接上级电网, 电

网供电面积约 79 km², 共 3 个电压等级, 不同电压等级之间通过变压器连接。该电网包括 6 台变压器、5 个 PV、5 个 WT、5 个 ESS 和 2 个柔性负荷。各类分布式资源的安装位置如表 2 所示, ESS 参数如表 3 所示。各节点负荷选自 3 年 152 位用户负荷有功数据, 在默认功率因数的基础上随机扰动 5% 产生实时无功损耗, 然后将负荷和 RDG 数据^[20-21] 以 3 min 分辨率进行插值。从 3 年数据中选取其中 2 年数据作为训练集, 1 年数据作为测试集。

所用 MADDPG 算法的超参数设置如表 4 所示, 每个智能体的 Actor 网络和 Critic 网络架构相同, 包含 1 个输入层、2 个隐藏层和 1 个输出层。Actor 网络输入层为 1×114 维的状态向量, 隐藏层包含 128 个神经元, 输出层为 1×23 维的动作向量; Critic 网络输入层为 1×137 维的状态-动作向量。训练过程中使用 5 个随机种子随机抽取每个回合的初始状态, 每回合持续 12 h 即 240 个时间步。

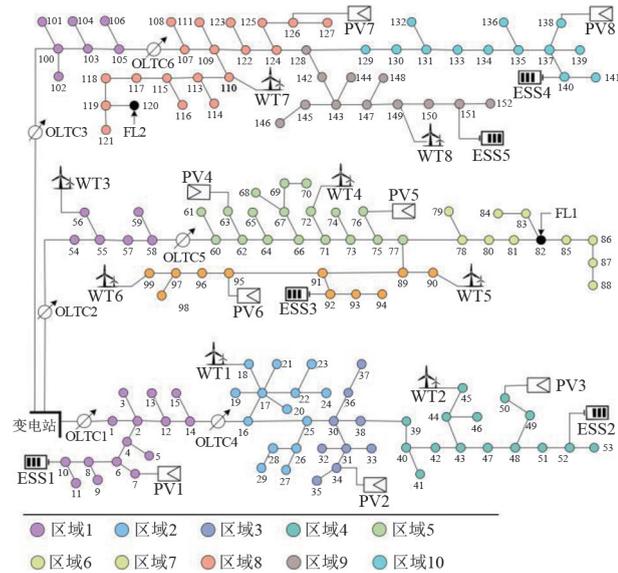


图 2 算例配电网拓扑结构

表 2 分布式资源参数

设备类型	数量	安装节点/支路
PV	8	7, 34, 50, 63, 76, 95, 126, 138
WT	8	18, 45, 56, 72, 90, 99, 110, 149
ESS	5	10, 52, 92, 140, 151
FL	2	82, 120

表 3 ESS 参数

E_{ESS}^{\max}	P_c^{\max}	P_{dc}^{\max}	σ_{sdr}	$S_{oc}(i, 0)$
1.2	0.025	-0.025	0.01	0.5

表 4 MADDPG 算法参数

参数类型	值
∂_1	0.8
∂_2	0.1
∂_3	0.1
γ	0.99
R_{done}	-50
τ	0.000 1
学习率	0.000 1
D 规模	5000
最大回合数	8000
最大时间步	240
激活函数	ReLU
$(a_{PV}^{min}, a_{PV}^{max})$	(-0.6, 0.6)
$(a_{WT}^{min}, a_{WT}^{max})$	(-0.6, 0.6)
$(a_{ESS}^{min}, a_{ESS}^{max})$	(-0.8, 0.8)
$(a_{FL}^{min}, a_{FL}^{max})$	(-0.3, 0.3)

4.2 训练结果分析

图 3 展示了 10 000 回合训练过程中每回合平均累计奖励变化曲线。由图可以看出:在训练初期智能体获得的奖励为很小的负值,说明此时总体处于探索阶段,尚未学习到有效的行动策略;在 1000 到 3500 回合左右奖励逐渐上升并达到稳定,说明智能体性能在学习过程中不断增强,已经能够学习并适应环境中的状态变化;4000 回合左右奖励收敛至稳定状态,说明此时已经达到了比较理想的控制效果,验证了所用 MADRL 算法在求解分布式广域电压调控问题的有效性。

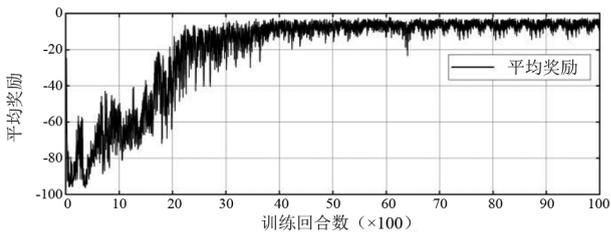


图 3 平均累计奖励曲线

4.3 测试结果分析

在测试集中随机选取连续 3 天数据进行测试,共 1440 个时间步,每个时间步持续时间为 3 min,测试平均耗时 2.65 s,图 4 为测试结果。为方便展示,负荷、PV、WT、柔性负荷有功和无功率取每小时的平均值,ESS 充放电功率取每小时所有时间步的有功功率之和。

通过测试结果可以看出:PV、WT 逆变器可以感

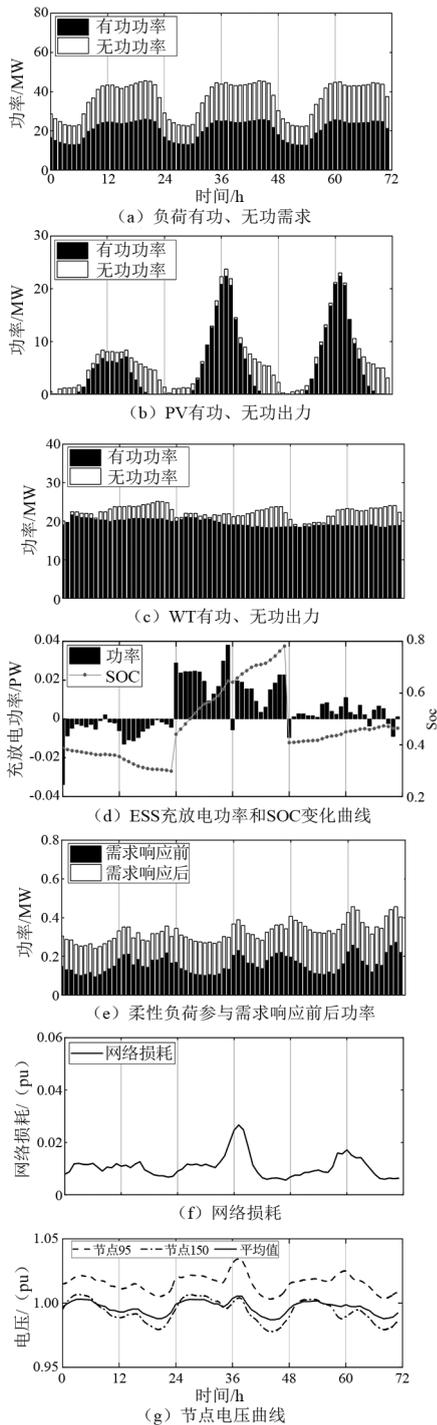


图 4 在线测试结果

知并适应配电网中无功需求的变化实时调节自身无功系数,实现全网无功功率平衡;ESS 可以感知并适应配电网中有功需求的变化实时调节自身与电网的交换功率,实现全网有功功率平衡;柔性负荷在负荷高峰期通过需求侧响应降低自身需求功率,在低谷期通过需求侧响应提高自身需求功率;ESS 的 SOC 始终在(0.2, 0.8)范围内,说明分布式储能参与电压管控的过程中能够保持一定的后备容量,网络损

耗始终保持在较低水平(0.005~0.020 pu),说明各种分布式资源在参与电压管控的同时能够兼顾网络的损耗;系统所有结点的平均电压在连续 3 天的测试结果中均保持在(0.98,1.01)范围内,节点 95 最高电压为 1.034,最低电压为 1.002;节点 105 最高电压为 1.007,最低电压为 0.977,说明通过对源网荷储的广域分布式控制,可以监测并实现电网的实时稳定。

为更好地验证所提广域电压自趋优管控方法相比传统调压方法的优越性,设置对比算例:将网络中 6 台变压器改造为 OLTC,每个 OLTC 含有 5 个抽头位置(-2~+2),增设 3 台电压调节器(voltage regulators, VR),每个 VR 含有 21 个抽头位置(-10~+10),OLTC 和 VR 的调节范围均为 $\pm 10\%$;增设 3 台 CB,每个 CB 含有 4 个调节单元,共 2.4 MVar 的调节能力(0.6 MVar/单元),各元件的最小动作间隔为 1 h;在测试集中随机选取 1 天进行测试。使用电压控制率、电压最大偏差作为衡量指标,测试对比结果如表 5 所示。由对比结果可以看出在电压调控过程中,使用 OLTC、CB 等传统调压手段无法适应新型配电系统中 RDG、负荷的快速波动,电压控制率仅为 68.2%,部分节点电压出现严重越限。

表 5 两种方法测试对比结果

电压调控方法	电压控制率/%	电压最大偏差
所提方法	100.0	0.008
传统方法	68.2	0.862

5 结 论

上面提出了一种基于数据驱动的新型配电系统分布式源网荷储资源广域电压自趋优管控方法,通过配电网分布式资源的协调互动实现对电网电压的广域控制。同时,将新型配电系统中的光伏、风电、ESS、柔性负荷等分布式资源建模为智能体,使用基于数据驱动的 MADDPG 算法进行求解,避免了传统优化方法对精确模型的依赖。仿真结果表明,所提方法能够实现保留分布式储能后备容量,降低网损的同时提高全网电压水平,使各节点电压始终处于安全范围内,整个过程是自趋优进行的,相比传统调压策略更加符合新型配电系统中实时可靠性的电压调控需求。

参考文献

- [1] 陈文淑乐,向月,彭光博,等.“双碳”目标下电力系统供给侧形态发展系统动力学建模与分析[J].上海交通大学学报,2021,55(12):1567-1576.
- [2] 董旭柱,华祝虎,尚磊,等.新型配电系统形态特征与技术展望[J].高电压技术,2021,47(9):3021-3035.
- [3] 重庆市人民政府办公厅,四川省人民政府办公厅.关于印发推动川渝能源绿色低碳高质量发展协同行动方案的通知:渝府办发[2022]91号[Z/OL].[2022-08-20].http://www.cq.gov.cn/zwgk/zfxxgkml/szfwj/qtgw/202208/t20220817-11015192.html.
- [4] FUSCO G, RUSSO M. A decentralized approach for voltage control by multiple distributed energy resources[J]. IEEE Transactions on Smart Grid, 2021, 12(4): 3115-3127.
- [5] CARLI R, CAVRARO G. Algorithms for voltage control in distribution networks[C]. 2015 IEEE International Conference on Smart Grid Communications (SmartGridComm), 2015: 737-742.
- [6] 刘蕊,吴奎华,冯亮,等.含高渗透率分布式光伏的主动配电网电压分区协调优化控制[J].太阳能学报,2022,43(2):189-197.
- [7] SUN X Z, QIU J, YI Y, et al. Cost-effective coordinated voltage control in active distribution networks with photovoltaics and mobile energy storage systems[J]. IEEE Transactions on Sustainable Energy, 2022, 13(1): 501-513.
- [8] 史景坚,周文涛,张宁,等.含储能系统的配电网电压调节深度强化学习算法[J].电力建设,2020,41(3):71-78.
- [9] WANG Z Y, WANG J H, CHEN B K, et al. Mpc-based voltage/var optimization for distribution circuits with distributed generators and exponential load models[J]. IEEE Transactions on Smart Grid, 2014,5(5): 2412-2420.
- [10] DE Souza BA, DE Almeida M F, Multi-objective optimization and fuzzy logic applied to planning of the volt/var problem in distributions systems[J]. IEEE Transactions on Power Systems, 2010, 25(3): 1274-1281.
- [11] YAO Haotian, XIANG Yue, HU Shuai, et al. Optimal prosumers' peer-to-peer energy trading and scheduling in distribution networks[J]. IEEE Transactions on Industry Applications, 2022,58(2): 1466-1477.
- [12] CAPITANESCU F, BILIBIN I, RAMOS E R. A comprehensive centralized approach for voltage constraints management in active distribution grid[J]. IEEE Transactions on Power Systems, 2014, 29(2): 933-942.

