

基于相邻分区可用转供能力的配电网分区间互济运行优化方法

罗龙波¹, 陈明辉¹, 王仁浚², 高红均², 刘俊勇²

(1. 广东电网有限责任公司广州供电局, 广州 510630; 2. 四川大学电气工程学院, 成都 610065)

摘要: 在大规模配电网中, 负荷转供可以有效缓解单个分区供电紧张的问题。然而, 由于网络规模过大, 传统的数学优化方法难以解决这一问题。首先提出了一种基于网络化简的分区可用转供能力量化评估模型, 以选取互济运行的分区规模。其次, 提出了一种基于深度强化学习的配电网分区间互济运行优化方法以快速寻找到分区间互济运行方案。该方法改进了传统的奖励函数以提升智能体对不同负荷场景的适应能力与泛化特性。然后, 采用对决双深度 Q 网络 (dueling double deep Q network, D3QN) 算法进行策略学习, 以应对大规模系统的复杂性。最后, 通过对 IEEE 33 节点系统和实际 445 节点系统进行仿真实验, 验证了所提方法的有效性。

关键词: 配电网运行优化; 可用转供能力量化评估; 深度强化学习; D3QN 算法

Inter-Sub-District Operation Optimization Method in Distribution Network Based on Available Transfer Capacity of Adjacent Zones

LUO Longbo¹, CHEN Minghui¹, WANG Renjun², GAO Hongjun², LIU Junyong²

(1. Guangzhou Power Supply Bureau of Guangdong Power Grid Co., Ltd., Guangzhou 510630, China; 2. College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: In large-scale distribution networks, load transfer can effectively alleviate power supply shortages in individual partitions. However, due to the excessive network size, traditional mathematical optimization methods struggle to address this issue. First, a quantitative assessment model for partition transfer capability based on network simplification is proposed to select the scale of partitions for inter-sub-district operation. Second, an optimization method for inter-sub-district operation between distribution network partitions using deep reinforcement learning is introduced to quickly identify inter-sub-district operation support schemes. This approach improves the traditional reward function to enhance the agent's adaptability and generalization characteristic across different load scenarios. Then, the dueling double deep Q-network (D3QN) algorithm is employed for policy learning to tackle the complexity of large-scale systems. Finally, simulations on the IEEE 33-node system and a practical 445-node system are conducted to validate the effectiveness of the proposed method.

Key words: distribution network operation optimization; quantitative assessment of available transfer capacity; deep reinforcement learning; D3QN algorithm

0 引言

近年来, 随着城市负荷不断增长, 尤其是在迎

峰度夏期间, 配电网面临着巨大的保供压力。配电网负荷转供技术通过控制不同馈线之间的分段开关与联络开关, 从而将负荷在馈线间进行转移以缓解单条馈线的供电压力^[1]。然而, 目前的负荷转供技术通常只应用在单个变电站分区中的馈线间^[2], 对配电网供电压力缓解十分有限。目前针对多个分区间负荷转供的研究较少。因此, 解决配电网分区间互济运行优化问题具有重要意义。

基金项目: 国家自然科学基金资助项目 (52077146); 中国南方电网有限责任公司创新项目 (030100KK52222069)。

Foundation item: Supported by the National Natural Science Foundation of China (52077146); the Innovation Project of China Southern Power Grid Co., Ltd. (030100KK52222069).

针对负荷转供问题,传统的配电网优化方法主要包括凸优化方法^[3-6]与启发式方法^[8-10]。凸优化方法通过采用一些凸松弛方法如半定规划松弛^[3]、二阶锥松弛^[4-6]等对非凸的最优潮流模型进行凸化后求解。该方法需要求解两种变量:开关状态的二进制变量和配电网潮流相关的连续变量^[7]。在精确松弛的前提下凸优化方法能够找到“全局最优解”,但其依赖于准确的数学模型。启发式方法则基于直觉和模拟经验,如和声算法^[8]、粒子群算法^[9]、蚁群算法^[10]等,以迭代的方式逐步寻找开关组合最优方案。该方法更倾向于直觉来减少搜索空间^[11],因此该方法找到的最优解更可能为“局部最优解”。当配电网规模较小时这两种方法通常能够快速收敛到最优解。然而,在考虑多个分区的配电网分区间互济运行优化问题时涉及到的网架规模庞大。对于大规模配电网转供优化问题,由于变量与约束众多且需要计及开关变化的时序耦合特性导致问题复杂度过高^[12],使得传统的凸优化方法难以求解。且由于开关数量大导致可行解过多,启发式方法也同样需要很长的求解时间。

近年来,深度强化学习方法由于其面对复杂动态优化问题的快速求解能力受到广泛关注。文献[13]提出了一种利用深度Q学习(deep Q-learning, DQN)模型确定最佳网络拓扑结构的方法。文献[14]使用了Double DQN算法确定系统重构方案。文献[15]针对配电网负荷转供问题,采用了dueling DQN算法进行网络重构。文献[16]采用了软演员-评论家(soft actor-critic, SAC)算法以改善智能体对于探索与利用的权衡。文献[17-19]使用了多智能体算法以减少每个智能体的动作空间。然而,这些深度强化学习方法仅在小规模配电网重构中得到验证,在大规模配电网中尤其是分区负荷转供等问题上,其收敛性难以保证。此外,以上提及的深度强化学习方法中奖励函数均采取成本绝对值并乘以权重的方式,该方式可能会导致智能体在学习策略面临变化的负荷场景时神经网络拟合受到影响。总之,对于分区负荷转供问题,主要挑战在于可行解的数量过多,导致求解困难。若将所有存在弱耦合关系的分区纳入优化计算,待求解的系统规模将非常庞大。因此,确定分区规模以减少深度强化学习的动作空间是一个值得深入研究的课题。然而,目前关于配电网分区互济如何选定相邻分区的研究还处于空白。此外,在大规模系统中进行优化的深

度强化学习算法研究也仍处于起步阶段。

基于上述分析,本文提出了相邻配电网分区之间的互济运行优化方法,通过分区间的负荷转供提高配电网的供电能力。首先,考虑到多个分区间节点数目众多、数学计算复杂度过大,本文提出一种基于网络化简的分区可用转供能力量化评估模型以确定待优化区域。在确定待优化区域后,本文提出了一种深度强化学习方法以寻找分区间快速互济支撑方案。在深度强化学习方法中,本文对传统的奖励函数进行了改进以提升智能体策略的泛化特性。通过更精细地设计奖励机制可以使智能体更好地适应不同情境,并在测试集中表现更为稳健和高效。为了应对大规模系统的复杂性,本文采用了对决双深度Q网络(dueling double deep Q network, D3QN)算法来学习智能体的策略。D3QN算法结合了双重Q网络和优势函数的思想,具有更好的收敛性和学习效果,能够更有效地处理大规模系统中的复杂优化问题。

1 配电网分区间互济运行优化

如图1所示,在典型城市配电网中,一个110 kV变电站往往连接着多回馈线,可视为一个单独的分区。每个分区内部可通过分段开关与联络开关的倒闸操作进行小规模的潮流转移。而各分区间通过联络开关保持弱耦合关系。当配电网中单个分区整体负荷过重导致供电能力不足时,将部分负荷通过开关倒闸操作由其他相邻变电站进行转供,并优化分区内部的潮流分布,可以有效地缓解供电压力,从而提升配电网的经济性与安全性。

配电网相邻分区间互济运行优化问题旨在探寻




图1 典型城市配电网拓扑结构

Fig. 1 Topology structure of typical urban distribution network

最优的开关组合方式,以实现配电网分区间总体成本函数的最小化。该问题涉及两类变量:一是开关状态的二进制变量,二是与配电网潮流相关的连续变量。随着待求解配电网规模的扩大,该问题的求解难度将呈指数级增长^[20]。在一些特大型城市中分区间存在弱耦合关系的馈线数量可能高达数百条。鉴于问题的数学复杂度,对所有分区进行优化计算是不现实的。

本文所提出的配电网分区间互济运行优化方法的整体流程如图2所示。由于一个分区可能同时与多个相邻分区相连,若将所有相邻分区统一纳入优化计算,可能会导致计算复杂度过高。因此,首先需要确定配电网的相邻转供分区。本文提出了一种考虑相邻分区转供的配电网化简方法,并建立了配电网分区可用转供能力量化模型,用于计算正常运行典型场景下相邻分区的最大可用转供能力。值得一提的是,网络化简的目的是通过降维来提升配电网分区可用转供能力量化模型的求解效率。

然而,在确定相邻分区后,待求解的配电网规模依然较大,导致优化问题中的二进制变量和连续变量维度较高,使得传统的凸优化方法在求解时耗时较长。此外,在配电网运行转供问题中,网络损耗与节点电压是重要的转供方案评估因素。若采用简化节点系统进行凸优化求解,网络损耗与节点电压可能与未化简系统对应的值存在较大差异,从而影响解的可信性。因此,本文提出了一种基于深度

强化学习的优化方法以实现快速求解。




图2 配电网分区间互济运行优化流程

Fig. 2 Inter-sub-district operation optimization in distribution network flowchart

2 相邻分区可用转供能力量化评估

本文提出了一种基于网络化简的分区可用转供能力量化评估模型,从而从中长期时间尺度上实现待求解配电网分区规模的有效选取。

2.1 计及相邻分区转供的配电网化简方法

本文提出了一种考虑相邻分区转供的配电网化简方法,通过合并原相邻分区中的可转供节点以支持后续的分析计算。该方法的核心思想在于确定弱耦合关系,合并开关间的负荷,进而重新构建配电网的拓扑结构。




图3 配电网化简示例图

Fig. 3 Distribution network simplifying illustration

所提的计及相邻分区转供的配电网化简方法流程如图 3 所示, 以下将详细讨论该方法的步骤和关键内容。

1) 确定相邻分区可转供区域

根据开关分布确定相邻分区可转供区域。如图 3 所示, 在与红色节点经联络开关 1 连接的相邻分区中, 左半分区与红色节点存在弱耦合关系, 因此将其视为相邻分区可转供区域。

2) 确定孤岛节点群

将所有联络开关、分段开关及与变电站相连的支路视为断开, 从而分离出配电网中直接与变电站相连的节点群和直接与开关相连的节点群。这一步骤将生成多个孤立的电网子区域, 从图论视角来看, 这些子区域即为多个连通子图, 共同构成一个非连通图。利用连通性计算方法, 识别所有子连通图的节点集合。首先, 选定一个节点, 运用广度优先搜索遍历算法, 依次访问与其相连的所有节点, 并将这些节点纳入同一连通分量。其次, 针对非连通图内的多个连通分量, 重复上述步骤, 直至遍历完所有节点。最终, 获取每个连通分量的节点集合, 这些集合即为各子连通图的节点集合。

3) 建立新节点的连接关系

将每个子连通图的节点集合视为一个新的节点。如果变电站、开关或其他子连通图的一个节点与这个子连通图的任何一个节点相连, 将保留这条线路, 并将其视为与这个新节点的连接关系。这一步骤将产生一个更简化的配电网, 其中节点的数量 N 为:

$$N = N^{\text{substation}} + N^{\text{subsets}} \quad (1)$$

式中: $N^{\text{substation}}$ 为变电站的数量; N^{subsets} 为子连通图的数量。

4) 节点编号匹配

将新节点的编号与原节点的编号进行匹配, 以便进行进一步的计算和分析。新节点的编号按照它们所属的子连通图来进行重新编排, 最终形成如图 3 右所示的相邻分区可转供区域化简网络。

2.2 配电网相邻分区的可用转供能力模型

基于化简后的相邻分区可转供区域(如图 3 右中简化网络的黑色节点部分), 本文建立了配电网相邻分区可用转供能力量化模型来计算正常运行典型场景下相邻分区的最大可用转供能力。该模型的

决策变量包括化简节点的有功负荷倍率与开关的合开状态。其目标函数旨在最大化相邻分区可转供区域所有主变所带有功负荷之和, 并优化各条馈线的负荷均衡度。

$$\max \sum_{s=1}^S (P_s^{\text{sub}} - S_s^{\text{D}}) \quad (2)$$

$$S_s^{\text{D}} = \frac{1}{M} \sum_{m=1}^M (P_{m,s}^{\text{feeder}} - \bar{P}_s^{\text{feeder}})^2 \quad (3)$$

式中: P_s^{sub} 为第 s 个典型场景下可转供区域 110 kV 主变所带有功负荷; S_s^{D} 为可转供区域所有馈线有功功率的方差; $P_{m,s}^{\text{feeder}}$ 为第 m 条馈线所带有功功率, $\bar{P}_s^{\text{feeder}}$ 为所有馈线平均功率; M 为该分区变电站所有出线数量; S 为场景数量。

约束条件包括配电网功率平衡约束、安全约束、配电网拓扑辐射状约束, 具体如下。

1) 配电网功率平衡约束

由于配电网中存在多种电压调节方式, 正常运行下, 影响配电网供电能力的主要因素通常是载流量约束, 而不是电压约束^[21]。因此, 相邻分区可用转供能力量化无须准确的潮流模型。在本文中, 分区可用转供能力模型统一只考虑有功功率平衡, 且不考虑网损, 以满足各个分区可用转供能力的公平比较的最小前提。

$$P_s^{\text{sub}} - \alpha_s P_{j,s}^{\text{load}} = \sum_{k \in \delta(j)} P_{ij,s}^{\text{line}} - \sum_{i \in \pi(j)} P_{ij,s}^{\text{line}}, \forall i, \forall j, \forall k \in B \quad (4)$$

式中: $P_{ij,s}^{\text{line}}$ 为化简后配电网节点 j 的上游线路有功功率流; $P_{jk,s}^{\text{line}}$ 为化简后配电网节点 j 的下游线路有功功率流; $\delta(j)$ 为化简后配电网节点 j 的上游节点集合; $\pi(j)$ 为化简后配电网节点 j 的下游节点集合, B 为化简后配电网的所有节点集合; $P_{j,s}^{\text{load}}$ 为节点 j 的有功负荷; α_s 为第 s 个典型场景下待求解的有功负荷统一倍率; i 为节点 j 的上游节点。

2) 安全约束

$$P_{ij,s}^{\text{line}} \leq P_{ij}^{\text{line}, \max}, \forall ij \in E^{\text{NS}} \quad (5)$$

$$\sigma_{ij,s} P_{ij,s}^{\text{line}, \min} \leq P_{ij}^{\text{line}} \leq \sigma_{ij,s} P_{ij,s}^{\text{line}, \max}, \forall ij \in E^{\text{SW}} \quad (6)$$

$$P_s^{\text{sub}} \leq P_s^{\text{sub}, \max} \quad (7)$$

式中: $P_{ij}^{\text{line}, \max}$ 为线路有功潮流上限值; $P_s^{\text{sub}, \max}$ 为变电站所带有功功率上限值。这两个值可通过视在功率上限值与变电站所带负荷功率因素求得。 E^{NS} 为化简配电网没有开关的支路集合; E^{SW} 为化简配电网有开关的支路集合; $\sigma_{ij,s}$ 为待求解的开关状态。

3) 配电网拓扑辐射状约束

由于涉及多个变电站,负载配电网重构的关键在于如何有效地保证配电网辐射状约束。该约束由以下两种条件来保证:(1)线路数=节点数-变电站数。(2)没有不含变电站节点的子连通图。这两个约束保证了网络既没有孤岛也没有环网,具体如下所示。

$$\sum_{ij \in E^{NS}} "1" + \sum_{ij \in E^{SW}} \sigma_{ij,s} = N^{bus} - N^{sub} \quad (8)$$

$$P_s^{vir,sub} = \varepsilon \quad (9)$$

$$P_s^{vir,sub} - P_{j,s}^{vir,load} = \sum_{k \in \delta(j)} P_{jk,s}^{vir} - \sum_{i \in \pi(j)} P_{ij,s}^{vir} \quad (10)$$

$$-\sigma_{ij,s} P_{ij}^{line,max} \leq P_{ij,s}^{vir} \leq \sigma_{ij,s} P_{ij}^{line,max} \quad (11)$$

$$P_{j,s}^{vir,load} > 0 \quad (12)$$

式中:“1”表示没有开关的支路状态固定为1; N^{bus} 为化简配电网节点数量; N^{sub} 为变电站数量,此处为1; $P_s^{vir,sub}$ 与 $P_{j,s}^{vir,load}$ 分别为虚拟变电站有功功率与虚拟有功负荷; ε 为一个小的常数; $P_{ij,s}^{vir}$ 与 $P_{jk,s}^{vir}$ 均为虚拟支路有功功率流。上式严格限制了开关组合方式,能严格保证辐射性。

根据配电网相邻分区的可用转供能力模型求得有功负荷倍率 α_s 与其对应的最大可用转供能力 P_s^{total*} ,则相邻分区可用转供能力 P^{supply} 为:

$$P^{supply} = \frac{1}{S} \sum_s (P_s^{total*} - P_s^{total}) \quad (13)$$

式中: S 为场景数量; P_s^{total} 为第 s 个场景的总有功负荷。

最后,考虑到目标函数是非线性的,难以求解,对目标进行线性化如下所示。

$$S_s^D = \frac{1}{M} \sum_{m=1}^M v_{m,s} \quad (14)$$

$$\begin{cases} v_{m,s} \geq P_{m,s}^{feeder} - \bar{P}_s^{feeder} \\ v_{m,s} \geq -P_{m,s}^{feeder} + \bar{P}_s^{feeder} \end{cases} \quad (15)$$

式中 $v_{m,s}$ 为引入的辅助变量。

总的来说,该模型综合考虑了负荷均衡、线路容量及开关操作等多个关键因素,能够有效评估在正常运行典型场景下相邻分区的可用转供能力。通过选取相邻分区中可用转供能力最强的分区与原区域组成待优化区域,确保了优化目标区域的合理性。此外,若所有相邻分区的可用转供能力均较低,模型还可进一步从相邻分区的相邻分区中筛选,综合考虑并选取可用转供能力最大的分区进行互济支撑。

3 基于深度强化学习的配电网分区间互济运行优化方法

本文提出了一种基于深度强化学习的配电网分区间互济运行优化方法。该方法旨在快速寻找到最优的分区间互济支撑方案,通过分区间的负荷转供来提升配电网的供电能力。分区间互济通过调整两个分区间的联络开关和分段开关,使供电紧张分区的一部分负荷得以由相邻分区变电站进行转供。当某分区供电紧张,无法仅依靠分区内馈线间的负荷转供缓解供电问题(例如变压器过载或变压器二次侧所有馈线均重载),且相邻分区具备一定的可转供能力时,即可启动分区间的互济操作。

3.1 马尔可夫决策过程

马尔可夫决策过程详尽地描述了深度强化学习所对应的物理问题,清晰地界定了智能体在状态转移过程中的动作、环境状态、奖励函数、状态转移概率以及折扣因子等^[13]核心要素。其中,状态转移概率通常由智能体在与环境交互过程中自行学习获得,而折扣因子则用于权衡当前动作的短期与长期影响。本文将重点围绕深度强化学习中状态转移过程中的智能体动作、环境状态和奖励函数进行详细阐述。

1) 动作空间

对于配电网分区间互济运行优化问题,智能体的决策变量为开关的状态组合方式,这属于典型的离散动作空间。在深度强化学习中输出神经元的数量需与动作空间的大小相匹配,即等于开关状态组合的数量,具体为2的 N^{OSW} 次方,其中 N^{OSW} 为待优化区域开关的数量。然而,为了满足配电网的辐射性约束,部分文献通常采用开关对的方式,即在一个开关对中,一个开关为开,另一个必须为关^[16]这种处理方式会导致部分开关被省略。相比之下,遍历所有开关组合方式,并根据辐射性约束筛选出所有满足约束的有效组合方式,是一种更为优越的处理方法。

2) 状态空间

对于深度强化学习而言,其状态空间无需选取过多的配电网状态变量,仅需满足一个条件,即能够为智能体选取动作提供依据。在本文中,选取配电网中所有节点的有功功率和无功注入功率作为状态空间,以 $s_t = \{P_t^{inj}, Q_t^{inj}\}$ 表示。

3) 奖励函数

传统的配电网开关优化奖励函数 r_t 通常由网损成本、开关动作成本、电压越限惩罚成本构成^[16-18]，如下所示。

$$r_t = -c^{\text{loss}} P_t^{\text{loss}} - c^{\text{sw}} \sum_{n \in E^{\text{OSW}}} |\sigma_{n,t} - \sigma_{n,t-1}| - c^{\text{vol}} \sum_{i \in \Omega^{\text{op}}} [\max(0, V_{i,t} - V^{\text{max}}) + \max(0, V^{\text{min}} - V_{i,t})] \quad (16)$$

式中： c^{loss} 、 c^{sw} 、 c^{vol} 分别为网损成本、开关动作成本、电压越限成本； P_t^{loss} 为网损； E^{OSW} 为优化区域的开关集合； Ω^{op} 为优化区域的节点集合； $\sigma_{n,t}$ 为开关状态； $V_{i,t}$ 为节点电压，其中下标 i 和 t 分别为节点和时间步； V^{max} 与 V^{min} 分别为节点电压上下限值。

显然，传统的奖励函数采用的是成本绝对值的方式。然而，对于每日负荷波动较大的地区，这种方式可能会影响智能体策略的收敛。具体来说，网损成本和电压越限惩罚成本不仅取决于智能体的动作，还与配电网的日负荷曲线紧密相关。在智能体采取相同动作的情况下，即配电网拓扑结构保持不变时，不同的负荷水平会导致不同的网损成本和电压越限惩罚成本。因此，当配电网的日负荷曲线变化较大时智能体在不同状态下对配电网采取相同动作可能会获得差异显著的奖励值。

另一个关键因素是，由于各配电网的负荷大小、网架规模和开关数量存在差异，在训练不同配电网的智能体时，奖励函数中各值的权重往往需要根据不同的网络条件进行调整。本文对奖励函数进行了进一步优化，采用相对值进行计算有效缓解了上述问题。与绝对值相比，相对值奖励函数在负荷场景变化时波动较小，能更准确地反映不同场景下不同动作的价值，从而显著降低神经网络的拟合难度。此外，相对值奖励函数的设计综合考虑了不同的负荷大小、网架规模和开关数量，因此无需针对不同配电网设置不同的权重，大幅减少了参数调整的时间。

$$r_t = -w^{\text{loss}} P_t^{\text{loss}} / P_t^{\text{sub}} - w^{\text{sw}} \sum_{n \in E^{\text{OSW}}} |\sigma_{n,t} - \sigma_{n,t-1}| / N^{\text{OSW}} - \frac{w^{\text{vol}}}{N^{\text{op}}} \sum_{i \in \Omega^{\text{op}}} [\max(0, \frac{V_{i,t} - V^{\text{max}}}{V^{\text{B}}}) + \max(0, \frac{V^{\text{min}} - V_{i,t}}{V^{\text{B}}})] \quad (17)$$

式中： w^{loss} 、 w^{sw} 、 w^{vol} 分别为网损相对值、开关操作相对值、电压越限相对值的系数，本文分别设置为 0.5×100 、 0.1×100 、 0.4×100 ； P_t^{sub} 为变电站有功功率； V^{B} 为基准电压； N^{op} 为优化区域节点数量； N^{OSW} 为优化区域开关节点数量。

图 4 为深度强化学习状态转移过程。




图 4 深度强化学习状态转移过程

Fig. 4 Deep reinforcement learning state transition process

如图 4 所示，在第 t 个时间步智能体接收到环境状态 S_t 后，选择动作 A_t ，并调整配电网中开关的状态。配电网随即根据开关状态的改变发生状态转移，进入下一个时间步的状态 S_{t+1} ，并依据该状态计算状态-动作对 $\{S_t, A_t\}$ 的奖励函数 R_t 。这一系列操作构成一个完整的状态转移过程。随后，判断当前时间步 t 是否为最终步骤，以确定 $done$ 的值。若 t 为最后一步，将 $done$ 赋值为 0，标志着当前 episode 的结束；若非最后一步，将 $done$ 赋值为 1，继续进入下一个状态转移过程。此外，状态转移数据 $\{S_t, A_t, R_t, S_{t+1}, done\}$ 将被存储至经验回放池，用于更新模型参数，从而优化智能体的策略。

3.2 D3QN 深度强化学习算法

本文采用 D3QN 深度强化学习算法来改进智能体的策略^[22]。该算法有效融合了广泛采用的 DQN 算法变体：Dueling DQN^[23] 与 Double DQN^[24]。

Dueling DQN 通过改变神经网络结构将原 DQN 输出的衡量状态-动作对价值的 Q 值估计分解为衡量状态价值的值函数与衡量动作与平均行动相比价值的优势函数，从而有助于智能体更好地理解每个行动在给定状态下的重要性。Dueling DQN 通过式 (18) 计算 Q 值。

$$Q(s) = V(s) + (A(s) - \text{mean}(A(s))) \quad (18)$$

式中： $Q(s)$ 为所有动作的 Q 值估计； $V(s)$ 为值函

数; $A(s)$ 为所有动作的优势函数; $\text{mean}(A(s))$ 为优势函数的均值。以上由于 $V(s)$ 与 $\text{mean}(A(s))$ 的维度为 $\text{mini batch} \times 1$, 而 $A(s)$ 的维度为 $\text{mini batch} \times \text{action}$ (动作数量), 因此需要这两项 ($V(s)$ 和 $\text{mean}(A(s))$) 通过复制每列值扩展到与 $A(s)$ 相同的维度处理后进行计算。

Double DQN 旨在解决 Q 值估计中的高估偏差问题。在标准 DQN 的更新过程中, 一个给定状态的目标 Q 值是通过在动作选择和目标 Q 值估计时使用相同的目标网络计算得出的, 这可能导致高估偏差, 即 Q 值持续被高估。相比之下, 在 Double DQN 的更新过程中动作选择由在线网络负责, 而与该动作相关的目标 Q 值则由目标网络估算, 从而有效减少了高估偏差。Double DQN 的更新公式为:

$$\min J(\theta) = \mathbb{E}_{s, a, s' \in B} [(Q_{\theta}(s, a) - y(s'))^2] \quad (19)$$

$$y(s', a') = r + \gamma(1 - d)[Q^{\text{target}}(s', a')] \quad (20)$$

$$a' = \arg \max Q(s') \quad (21)$$

式中: $J(\theta)$ 为损失函数; B 为经验回放池; $Q_{\theta}(s, a)$ 表示状态-动作对 (s, a) 的在线网络估计的 Q ; a 为动作; θ 为神经网络参数; $y(s', a')$ 为奖励函数目标值; s' 为下一个时间步的状态; a' 为下一个时间步的动作; d 表示是否为最后一步; $Q^{\text{target}}(s', a')$ 为状态-动作对 (s', a') 的目标网络估计的 Q 值, 其中 s' 由经验回放池采样所得, 而 a' 由式(21)利用在线网络选取。

总体而言, 与标准 DQN 相比, Dueling DQN 能够显著提升学习的稳定性和速度, 特别是在拥有较大行动空间的环境中表现尤为突出。而在那些高估偏差对性能影响较大的任务中, Double DQN 则展现出独特的有效性。D3QN 结合了 Dueling DQN 的 Q 值估算与 Double DQN 的模型更新机制, 具体而言, 通过将式(19)—(20)的 Q 估计利用式(18)进行计算。该算法有效整合了两者的优势, 从而实现了更为稳定的训练过程和更优的收敛性能。

4 算例分析

本文通过一个实际的 445 节点系统测试, 验证了所提出的配电网转供能力量化评估模型及深度强化学习优化方法的有效性。该系统包含 4 个变电站、445 个节点、469 条线路、26 个分段开关和 31 个联络开关, 基准电压为 10 kV。应用本文提出的

化简方法对其进行简化, 得到了如图 5 所示的配电网简化图。图中, 分区 1 为供电紧张区域, 其余 3 个分区则为相邻区域。典型运行场景基于历史数据中分区 1 供电紧张的时段选取, 并利用 K-means 方法进行统一聚类, 最终确定了 5 个正常运行典型场景。




图 5 实际 445 节点系统简化图

Fig. 5 Simplified topology of the practical 445-bus system

此外, 本文额外采用 IEEE 33 节点系统测试所提深度强化学习方法在不同系统的适应性, 该系统拓扑结构参见文献[5]。从图 5 可以看出, 该系统共有 33 个节点, 37 条线路, 其中 32 条常运行线路, 5 条备用线路。基准电压为 12.66 kV。电压上限为 1.06 p. u., 下限为 0.94 p. u.。本文基于 Python 平台采用 OPENDSS 进行配电网运行仿真。

考虑到不同的负荷水平来构建训练数据库以及测试集, 即采用前一年中的供电紧张时的日负荷数据构建训练集, 共 53 d, 采用后一年中的供电紧张时的日负荷数据构建测试集, 并聚类成 5 个典型日。为了进行公平的算法比较, 本文所提深度强化学习模型采用统一超参数, 如表 1 所示。对于一些具有特别超参数的算法, 采用网格法进行超参数的优化, 选取其中表现最稳定的超参数。

表 1 超参数

Tab. 1 Hyper parameters

学习率	折扣因子	采样数量	隐藏层神经元数量
0.000 5	0.995	64	64

4.1 相邻分区可用转供能力量化评估

基于图 5 所示的实际 445 节点系统简化图与原始拓扑结构, 本文设定了两个案例, 分别对构建的相邻分区可用转供能力模型进行求解, 获得了分区 1 的 3 个相邻分区的结果, 详见表 2。表中数据包括负荷及负荷倍率, 均为五个典型场景下供电紧张时段(08:00—20:00)每小时的平均值。Case1 代表采用原始拓扑结构进行求解, 考虑了无功功率、网络损耗以及节点电压的上下限约束。Case2 则代表采用本文提出的基于网络简化的量化模型进行求解。

表 2 相邻分区可用转供能力

Tab. 2 Available transfer capacities in neighboring zones

相邻分区		分区 2	分区 3	分区 4
优化节点数量	Case1	72	116	181
	Case2	8	9	12
总负荷大小/MW		13.030	20.648	25.294
负荷倍率	Case1	3.125	1.821	1.742
	Case2	3.286	1.825	1.747
可用转供能力/MW	Case1	27.689	16.952	18.768
	Case2	29.787	17.035	18.894
计算时长	Case1	0.11 s	0.11 s	0.15 s
	Case2	3.21 h	7.15 h	12.35 h

从表 2 可以看出, 无论是 Case1 还是 Case2, 尽管分区 2 的网架结构相较于分区 3 和分区 4 更小, 但其可用转供能力却是最高。因此, 本文选取分区 1 和分区 2 作为配电网分区间互济运行的待优化区域。此外, 表中数据显示, 尽管分区 4 的平均总负荷高于分区 3, 但由于其馈线和开关数量更多, 灵活性更强, 其可用转供能力反而高于分区 3。

其次, 由于 Case1 中考虑了电压上下限约束, 因此在 3 个分区上的供电能力计算结果普遍略低于 Case2, 但这并不影响最终结论, 反而验证了本文所提模型的有效性。另外, 本文提出的基于网络化简的相邻分区可用转供能力模型, 通过合并节点群, 极大地缩短了求解时间。

4.2 深度强化学习算法对比

4.2.1 IEEE 33 节点系统

为了对所提的改进马尔可夫决策过程(对奖励函数进行了改进)的有效性进行验证, 本文设置两种 DQN 方法进行对比。DQN 0: DQN 算法采用式(16)作为奖励函数; DQN 1: DQN 算法采用式(17)作为奖励函数。为了公平地进行比较, 对于训

练过程中的神经网络拟合误差, 采用相对值(绝对值/最大值)进行对比, 结果如图 6 所示。




图 6 两种方法在 IEEE 33 节点系统的训练过程中误差对比
Fig. 6 Comparison of fitting errors during training process using two methods in IEEE 33-bus system

从图 6 可以看出, 采用传统奖励函数的神经网络(DQN 0)在约 100 个训练轮数时拟合误差达到最小值, 但随着训练轮数的增加, 其拟合误差呈现出先上升后下降的趋势, 并且在训练结束时拟合误差未能再次达到最小值。这表明传统奖励函数会导致神经网络拟合困难, 难以收敛。原因在于训练过程中使用了不同的训练场景集, 而奖励函数与动作及场景负荷之间存在复杂的非线性关系。当配电网的日负荷曲线变化较大时, 智能体在不同状态下对配电网采取相同动作可能会获得差异显著的奖励值, 从而增加神经网络的拟合难度。相比之下, 采用本文改进奖励函数的神经网络(DQN 1)的拟合误差呈现出平稳的递减趋势, 并在训练结束时达到最小值。这表明本文提出的改进奖励函数能够显著降低训练过程中的拟合误差, 有效缓解场景波动带来的影响, 提升神经网络 Q 值估计的准确性。

为了验证本文提出的 D3QN 算法的优越性, 本文选取了 DQN、Double DQN、Dueling DQN 以及 DQN PER^[25] 进行对比。这些算法均采用改进的奖励函数进行训练, 并与采用传统奖励函数的 DQN 0 进行对比。为了确保对比的公平性, 所有算法的超参数均取自表 1 中的值。在验证过程中, 各算法均采用传统奖励函数在测试集上进行计算, 并分别运行 5 次取平均值, 以评估算法的泛化能力。此外, DQN PER 的优先经验回放中涉及额外的超参数, 本文选取其中表现最优的超参数组合, 即 $\alpha=0.1$, $\beta=0.1$ 。

训练过程中,所有算法的性能表现如图7所示。




图7 6种深度强化学习方法在IEEE 33节点系统的结果对比

Fig. 7 Results comparison of six deep reinforcement learning methods on the IEEE 33-bus system

从图7可以看出,采用传统奖励函数的DQN 0的奖励函数曲线最低。相比之下,采用改进奖励函数的DQN 1以及其他算法均能学习到更优的策略,进一步验证了本文所改进的奖励函数可以有效提升深度强化学习的泛化能力。从算法层面来看,本文提出的D3QN算法的奖励曲线在所有测试算法中不仅最高而且最为平稳。这表明与其他测试算法相比,D3QN能够快速学习到最佳策略,展现出最强的泛化能力。此外,从奖励函数的平稳值(处于1 750—2 000轮次)来看,DQN算法的奖励值还略高于Double DQN算法和Dueling DQN算法。由此可见,在小规模系统上,Double DQN算法和Dueling DQN算法未必比经典DQN算法表现更佳。

4.2.2 445节点系统中的待优化区域

由4.1节可知,445节点系统中的待优化区域为分区1和分区2,共计148个节点。首先,采用与上一节相同的设置对所提出的改进马尔可夫决策过程(对奖励函数进行了改进)的有效性进行验证,结果如图8所示。从图8可以看出采用传统奖励函数的神经网络拟合误差并未收敛,而采用改进奖励函数的神经网络拟合误差则随着训练轮次的增加平稳下降,并最终趋近于0。这一结果进一步验证了在不同规模系统上本文所改进的奖励函数能够有效提升深度强化学习对 Q 值的估计精度。

其次,为了公平地进行算法对比,采用与上一节IEEE 33节点系统相同的实验设置,结果如图9




图8 两种方法在445节点系统的训练过程中误差对比

Fig. 8 Comparison of fitting errors during training process using two methods in 445-bus system




图9 6种深度强化学习方法在445节点系统中的结果对比

Fig. 9 Comparison of results from six deep reinforcement learning methods in a 445-bus system

所示。

从图9可以看出,DQN 0的奖励值显著低于其他采用改进奖励函数的算法。可见,在较大规模的系统上,采用改进的奖励函数带来的泛化能力提升更为显著。并且,相比于其他测试算法,本文所提的D3QN在6 000轮便率先达到了奖励值平稳阶段。在所有算法的平稳阶段(9 000~10 000轮次)中,所提的D3QN算法奖励值同样在6种方法中最高。而DQN PER算法尽管在部分阶段(6 000~8 000轮次)的奖励函数均值略高于D3QN,但其表现非常不稳定,在平稳阶段反而下降了,最终表现甚至不如Double DQN算法与Dueling DQN算法。此外,在大规模系统上,Double DQN算法与Dueling DQN算法的表现也优于经典DQN算法,可见这两种算

法更加适合大规模系统上的应用。

最后,以在测试集中的场景2为例(该场景下分区1的日总负荷曲线如图10所示)对本文优化后的具体快速互济支撑方案进行说明。从日负荷曲线图中可以看出,分区1的总负荷在前8个时间段内均低于15 MW,而在之后的时间段内处于15~20 MW的区间。




图10 445节点系统分区1的日总负荷曲线

Fig. 10 Daily total load curves of partition 1 in the 445-bus system

基于该场景,采用本文所提的D3QN算法学习到的快速互济支撑方案如图11所示。




图11 两个分区间的互济运行方案

Fig. 11 Mutual assistance operation schemes between two partitions

图11中,实线为投入运行的线路,虚线为开关断开的线路,并对两个时段之间运行状态发生改变的线路用橙色线标记,灰色区域为两个分区的范

围。从图中可以看出,在分区1供电紧张时段,其负荷节点群5由分区2进行转供,从而缓解分区1的供电压力。而分区2为了降低馈线段8-9由于转供而增大的供电压力,将负荷节点群10由馈线段8-11进行转供。此外,分区1也对其他线路进行了相应调整以降低网损。

为了进一步分析对本文所提的快速互济支撑方案的有效性,本文对分区互济与不进行互济的结果对比,结果如表3所示。表中,设置了3个方案:Option1:所提互济方案;Option2:不互济且组内优化方案,该方案与图11下方的互济运行方案类似,区别仅在于负荷5在该方案中由分区1进行供电,其他拓扑不变;Option3:不互济且组内不优化方案,该方案与图11上方拓扑一致。

表3 分区互济与不进行互济的结果对比

Tab. 3 Comparison of outcomes between mutual assistance among zones and non-implementation of mutual assistance

09:00—00:00时段	总时段网损/MW			平均负载率/%			
区域/馈线	分区1	分区2	系统	馈线1-6	馈线1-7	馈线8-9	馈线8-11
Option1	3.322	4.972	8.495	53	32	52	35
Option2	4.985	4.582	9.567	81	32	24	35
Option3	5.973	4.643	10.616	113	0	38	21

从表3可以看出,当系统不采取互济措施且组内未进行优化时,由于分区1中的负荷节点5、6、7均集中在馈线1-6段供电,导致该馈线过载,进而使得分区1的网损显著升高。相比之下,不互济但组内优化的方案通过调整分区内部的开关配置,将负荷节点7改由馈线1-7段供电,从而有效降低了分区1的网损。然而,馈线1-6段的负载率依然居高不下(在09:00—00:00时段的平均负载率高达81%)。而本文提出的快速互济支撑方案在3个方案中展现出最低的系统总网损,并且4条馈线均未出现重载现象。由此可见,本文所提方法能够有效缓解单个分区供电能力不足的问题。

5 结论

本文针对相邻分区互济运行优化问题,提出了相邻分区可用转供能力的量化评估方法,以及基于D3QN的配电网分区互济运行优化策略。通过在IEEE 33节点系统与实际445节点系统上的算例对

比,得出以下结论。

1)本文提出的相邻分区可用转供能力量化评估方法能够有效量化转供能力。相邻分区的可用转供能力与其负荷大小、馈线条数、开关数量及网架结构均密切相关。

2)本文所改进的奖励函数能够有效减少神经网络在应对变化场景时的拟合误差,从而提升智能体的泛化性能。

3)通过对比设置的不同深度强化学习算法,相较于5种算法,本文提出的D3QN在不同系统中均能学习到最优策略。

参考文献

- [1] 周念成,谷飞强,雷超,等.考虑合环电流约束的主动配电网转供优化模型[J].电工技术学报,2020,35(15):3281-3291.
ZHOU Niancheng, GU Feiqiang, LEI Chao, et al. A power transfer optimization model of active distribution networks in consideration of loop closing current constraints [J]. Transactions of China Electrotechnical Society, 2020, 35(15): 3281-3291.
- [2] 石斌,安锐,高红均,等.基于柔性多状态开关和动态重构的配电网灵活运行方法[J].电力系统保护与控制,2023,51(22):133-144.
SHI Cheng, AN Rui, GAO Hongjun, et al. Flexible operation method for a distribution network based on flexible multi-state switching and dynamic reconfiguration [J]. Power System Protection and Control, 2023, 51(22): 133-144.
- [3] 吕东璘,韩蓓,汪可友,等.交直流配电网供电恢复问题的半定规划方法研究[J].电力系统保护与控制,2019,47(20):16-24.
LÜ Donglin, HAN Bei, WANG Keyou, et al. Semi-definite programming method for power supply restoration of AC/DC distribution network [J]. Power System Protection and Control, 2019, 47(20): 16-24.
- [4] 葛鹏江,张树永,董晓晶,等.基于鲁棒优化的配网重构二阶锥规划模型[J].电力科学与技术学报,2018,33(4):50-57.
GE Pengjiang, ZHANG Shuyong, DONG Xiaojing, et al. Distribution network reconfiguration model based on robust optimization [J]. Journal of Electric Power Science and Technology, 2018, 33(4): 50-57.
- [5] 舒俊霖,刘俊勇,高红均,等.考虑开关重构与需求响应的配电网分布鲁棒优化运行[J].电力建设,2023,44(6):101-111.
SHU Junlin, LIU Junyong, GAO Hongjun, et al. Distributionally robust optimal operation of distribution network considering switch reconfiguration and demand response [J]. Electric Power Construction, 2023, 44(6): 101-111.
- [6] 李洪美,崔翰韬,万秋兰.考虑电动汽车充电策略的配网重构二阶锥规划模型[J].中国电机工程学报,2015,35(18):4674-4681.
LI Hongmei, CUI Hantao, WAN Qiulan. Distribution network reconfiguration based on second-order conic programming considering EV charging strategy [J]. Proceedings of the CSEE, 2015, 35(18): 4674-4681.
- [7] 姜云鹏,任洲洋,李秋燕,等.考虑多灵活性资源协调调度的配电网新能源消纳策略[J].电工技术学报,2022,37(7):1820-1835.
JIANG Yunpeng, REN Zhouyang, LI Qiuyan, et al. An accommodation strategy for renewable energy in distribution network considering coordinated dispatching of multi-flexible resources [J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1820-1835.
- [8] 邹欣,李琴,黄宇,等.一种用于配电网重构的正反馈自适应和声算法[J].电力科学与技术学报,2018,33(1):22-29.
ZOU Xin, LI Qin, HUANG Yu, et al. Adaptive HSA based on positive feedback for distribution network reconfiguration [J]. Journal of Electric Power Science and Technology, 2018, 33(1): 22-29.
- [9] 李星成,鞠善忠,郑太英.基于粒子群算法的变压器直流偏磁隔直装置安装策略[J].南方电网技术,2023,17(10):13-21.
LI Xingcheng, JU Shanzhong, ZHENG Taiying. Installation strategy of transformer DC bias blocking device based on PSO algorithm [J]. Southern Power System Technology, 2023, 17(10): 13-21.
- [10] 黄健,张尧,李绮雯.蚁群算法在配电网重构的应用[J].电力系统及其自动化学报,2007,19(4):59-64.
HUANG Jian, ZHANG Yao, LI Qiwen. Application of ant colony system in distribution reconfiguration [J]. Proceedings of the CSU-EPSC, 2007, 19(4): 59-64.
- [11] 甘学涛,宋喜,王志刚,等.基于蚁群算法的配电网重构模型及其应用[J].西北农林科技大学学报(自然科学版),2005,33(5):157-160.
GAN Xuetao, SONG Xi, WANG Zhigang, et al. Model reconfiguration of distribution network and its application based on ant colony optimization [J]. Journal of Northwest Sci-Tech University of Agriculture and Forestry, 2005, 33(5): 157-160.
- [12] 王鲁明,程静,王维庆.基于改进灰狼算法的含分布式电源配电网重构研究[J].现代电力,2022,39(1):56-63.
WANG Luming, CHENG Jing, WANG Weiqing. Research on distribution network reconfiguration with distributed generation based on improved grey wolf optimizer [J]. Modern Electric Power, 2022, 39(1): 56-63.
- [13] OH S H, YOON Y T, KIM S W. Online reconfiguration scheme of self-sufficient distribution network based on a reinforcement learning approach [J]. Applied energy, 2020(280): 115900.1-115900.9.
- [14] BUI V H, SU W. Real-time operation of distribution network: a deep reinforcement learning-based reconfiguration approach [J]. Sustainable Energy Technologies and Assessments, 2022(50): 101841.1-101841.10.
- [15] 王光华,李晓影,宋秉睿,等.基于深度强化学习的配电网负荷转供控制方法[J].电力自动化设备,2022,42(7):253-260.
WANG Guanghua, LI Xiaoying, SONG Bingrui, et al. Load transfer control method of distribution network based on deep reinforcement learning [J]. Electric Power Automation Equipment, 2022, 42(7): 253-260.
- [16] GAO Y, WANG W, SHI J, et al. Batch-constrained reinforcement learning for dynamic distribution network reconfiguration [J]. IEEE Transactions on Smart Grid, 2020, 11(6): 5357-

- 5369.
- [17] WU T, WANG J, LU X, et al. AC/DC hybrid distribution network reconfiguration with microgrid formation using multi-agent soft actor-critic [J]. *Applied Energy*, 2022 (307): 118189.1 – 118189.13.
- [18] GAO H, WANG R, HE S, et al. A cloud-edge collaboration solution for distribution network reconfiguration using multi-agent deep reinforcement learning [J]. *IEEE Transactions on Power Systems*, 2023, 39(2): 3867 – 3879.
- [19] XU J, GAO H, WANG R, et al. Real-time operation optimization in active distribution networks based on multi-agent deep reinforcement learning [J]. *Journal of Modern Power Systems and Clean Energy*, 2023, 12(3): 886 – 899.
- [20] 徐成司, 董树锋, 朱嘉麒, 等. 基于供电回路非连通条件的配电网辐射状约束描述方法[J]. *电力系统自动化*, 2019, 43(20): 82 – 89.
- XU Chengsi, DONG Shufeng, ZHU Jiaqi, et al. Description method of radial constraints for distribution network based on disconnection condition of power supply loop [J]. *Automation of Electric Power Systems*, 2019, 43(20): 82 – 89.
- [21] 肖峻, 屈玉清, 张宝强, 等. $N-0$ 安全的城市配电网安全域与供电能力[J]. *电力系统自动化*, 2019, 43(17): 12 – 19.
- XIAO Jun, QU Yuqing, ZHANG Baoqiang, et al. Security region and supply capability of urban distribution network with $N-0$ security [J]. *Automation of Electric Power Systems*, 2019, 43(17): 12 – 19.
- [22] HUANG Y, WEI G L, WANG Y X. Vd D3QN: the variant of double deep Q-learning network with dueling architecture [C]// 2018 37th Chinese Control Conference, July 25 – 27, 2018, Wuhan, China. New York: IEEE, 2018: 558 – 563.
- [23] WANG Z, SCHAUL T, HESSEL M, et al. Dueling network architectures for deep reinforcement learning [C]// International conference on machine learning, June 19 – 24, 2016, New York, USA. New York: PMLR, 2016, 4(6): 2939 – 2947.
- [24] AN HASSELT H, GUEZ A, SILVER D. Deep reinforcement learning with double Q-learning [C]// Proceedings of the AAAI Conference on Artificial Intelligence, February 12 – 17, 2016, Phoenix, Arizona, USA. Phoenix: AAAI, 2016, 30(1): 2094 – 2100.
- [25] SCHAUL T, QUAN J, ANTONOGLOU I, et al. Prioritized experience replay [DB/OL]. (2025 – 11 – 18) [2016 – 02 – 25]. <https://arxiv.org/abs/1511.05952>.

收稿日期: 2024-01-25; 网络首发日期: 2024-06-27

作者简介:

罗龙波(1987), 高级工程师, 硕士, 从事电力调度控制运行分析和管理工作, 104267600@qq.com;

陈明辉(1985), 高级工程师, 硕士, 从事电力调度控制运行分析和管理工作, chenminghui1985@qq.com;

王仁浚(1997), 男, 通信作者, 博士研究生, 从事配电网运行优化、人工智能研究, 1328860755@qq.com。

(上接第 55 页 Continued from Page 55)

- CHENG Xianlong, BAO Youzhi, HE Dujiang, et al. Short-term wind power prediction based on EMD-ELM-LSTM [J]. *Journal of Kunming University of Science and Technology (Natural Science Edition)*, 2023, 48(6): 78 – 87.
- [24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017(30): 1 – 11.
- [25] BAO K, BI J, GAO M, et al. An improved ship trajectory prediction based on AIS data using MHA-BiGRU [J]. *Journal of Marine Science and Engineering*, 2022, 10(6): 804. 1 – 804. 18.
- [26] XIAO X, ZHANG D, HU G, et al. CNN-MHSA: a convolutional neural network and multi-head self-attention combined approach for detecting phishing websites [J]. *Neural Networks*, 2020(125): 303 – 312.
- [27] CHEN Y, XU J. Solar and wind power data from the Chinese state grid renewable energy generation forecasting competition [J]. *Scientific Data*, 2022, 9(1): 577. 1 – 577. 12.

收稿日期: 2024-02-06; 网络首发日期: 2024-07-28

作者简介:

陈磊(1981), 男, 副教授, 硕士, 研究方向为新能源发电、控制科学与工程;

黄凯阳(1999), 男, 通信作者, 硕士研究生, 研究方向为风电功率预测、新能源发电, huangkaiyang2022@163.com;

张怡(1983), 女, 教授, 博士, 研究方向为新能源电力系统频率稳定, 鲁棒分布式协同预测控制方法。