

计及EV负荷-风电异质场景集的交流直流混合配电网多目标分布式协同优化

刘岩¹, 张亚超¹, 朱蜀², 谢仕炜¹

(1. 福州大学 电气工程与自动化学院, 福建 福州 350108;

2. 国网湖南省电力有限公司调度控制中心, 湖南 长沙 410004)

摘要:电动汽车以及分布式能源的规模化接入对配电网的安全经济运行提出了巨大的挑战。考虑到交直流混合配电网(HADDN)具有灵活可控性高、分区特性显著的特点,提出了一种计及源-荷侧双重不确定性的HADDN有功功率和无功功率的分布式协同优化方法。首先,提出了综合考虑交通拓扑结构、居民出行行为以及风电预测误差区间差异性的电动汽车充电负荷-风电场景生成方法,采用基于Wasserstein距离的最优场景缩减算法生成典型概率场景;其次,建立了以网络损耗和节点电压偏差最小为目标的HADDN随机优化模型;然后,对所提多目标优化模型进行目标分解以及区域解耦,采用一种基于目标值交换原理的交替方向乘子法对其进行分布式求解;最后,通过算例仿真验证了所提方法的有效性。

关键词:交直流混合配电网;电动汽车;风电;分布式协同优化;交替方向乘子法;随机优化

中图分类号:TM 73;TM 614;U 469.72

文献标志码:A

DOI:10.16081/j.epae.202208028

0 引言

在能源系统低碳化转型的背景下,大量直流型分布式电源DG(Distributed Generation)和负荷的接入促进了直流配电网的迅速发展,交直流混合配电网HADDN(Hybrid AC/DC Distribution Network)将成为未来配电网的重要形态^[1]。另一方面,电动汽车EV(Electric Vehicle)在减少交通领域的碳排放、缓解能源危机等方面具有巨大的优势和潜能,有望成为未来主要的道路运输工具^[2]。随着源侧DG、荷侧EV等分散化资源的大规模接入,传统的集中式优化方法面临着维度灾难、隐私泄露等一系列问题^[3]。此外,源-荷侧的双重不确定性和波动性易造成接入节点电压越限频繁问题,依托于传统的无功调整设备难以适应HADDN的安全经济运行需求^[4]。因此,开展计及源-荷双重不确定性的HADDN有功功率和无功功率的分布式优化运行研究具有重要的意义。

电压源型换流器VSC(Voltage Source Converter)实现了交/直流区域间的常态化双向互联,它不仅能满足有功功率/无功功率连续、精准的控制需求,还能为HADDN区域间的协调优化提供可能。目前,在HADDN的优化运行研究中主要采用集中式优化算法,如:文献[4]建立了两阶段鲁棒优化模型对传统无功设备和VSC进行集中式协调优化;文献

[5]提出了一种考虑多种主动管理措施的HADDN集中式调度策略。相比于集中式优化,现有文献对HADDN分布式优化问题的研究相对较少。文献[6]建立了基于目标分析级联法的HADDN多区域分布式调度模型,文献[7]提出了一种HADDN分布式电压优化模型,但文献[6-7]所建分布式优化模型中均未考虑源-荷侧的不确定性对系统优化运行的影响。文献[8]建立了考虑风电不确定性的HADDN鲁棒优化模型,文献[9]提出了计及源-荷双重不确定性的HADDN分层分布式优化调度模型,其中荷侧的不确定性特指常规负荷。但是随着EV保有量的快速增长,EV充电负荷的强随机性愈发突出,因此开展计及EV负荷不确定性的研究尤为关键。

针对EV充电负荷的建模,现有文献大多从时间和空间2个维度展开研究。文献[10-11]采用统计学方法得到EV起始充电时刻、日行驶里程的概率分布函数,利用蒙特卡罗模拟方法生成EV充电负荷场景集,但仅从时间维度分析了EV的充电行为,对充电负荷时空分布特性的刻画不足。文献[12]通过建立停车概率模型,提出了一种基于EV行驶、停放特性的充电负荷时空分布预测方法,但未考虑道路流量对车辆行驶的影响。文献[13]建立了基于EV出行概率矩阵的快充需求时空分布预测模型,但缺乏对EV用户行为特性的分析。

随着DG渗透率的不断提高,源侧DG出力与荷侧EV负荷的随机性相互叠加,进一步增加了电力部门的调控难度。目前,关于考虑EV负荷、DG出力不确定性的配电网优化的研究成果较多,如:文献[14]建立了HADDN中EV充换储一体站的规划模型,但

收稿日期:2022-05-18;修回日期:2022-08-08

在线出版日期:2022-08-24

基金项目:国家自然科学基金资助项目(61903088)

Project supported by the National Natural Science Foundation of China(61903088)

研究对象侧重于EV充电站,未考虑充电负荷、DG接入对配电网优化调度的影响;文献[15]提出了一种计及风电-EV不确定性的电力系统节能减排动态调度方案,但对于EV充电负荷不确定性的建模较为简单,缺少对其空间分布特征的刻画;文献[16]提出了一种考虑规模化EV接入的柔性台区协同经济调度方案;文献[17]构建了计及光储快充一体站的配电网日前经济调度模型。在上述含EV和DG的配电网优化调度研究中,仅考虑以经济性最优为目标,但高渗透率下EV负荷、DG出力的不确定性尤为突出,电压越限、网损增加等问题频发,因此亟需开展考虑EV负荷、DG出力不确定性的配电网电压质量问题研究。

综上所述,本文建立了计及源-荷侧双重不确定性的HADDN多目标随机优化模型,并对其进行目标分解和区域解耦,采用基于目标值交换原理的交替方向乘子法(ADMM)实现对所建模型的分布式求解。本文的主要贡献如下:①构建计及EV充电负荷、风电出力双重不确定性的场景集生成框架,采用基于Wasserstein距离的0-1规划模型实现初始场景集的最优缩减;②为了应对源侧DG出力以及荷侧EV负荷的不确定性对系统安全经济运行的影响,建立以网络损耗、节点电压偏差最小为目标的HADDN多目标随机优化模型;③通过目标分解和分区解耦,将HADDN多目标随机优化模型分解为交、直流子区域的单目标优化模型,构建基于目标值交换原理的ADMM分布式优化求解框架。

1 EV充电负荷-风电异质场景集建模

针对EV充电负荷和风电出力的不确定性,利用历史统计数据分别生成EV充电负荷、风电出力场景集,然后对场景进行降维、组合得到EV充电负荷-风电组合场景集及其发生的概率。

1.1 EV充电负荷的时空分布预测模型

EV充电负荷的时空分布预测模型框架见图1,




图1 EV充电负荷的时空分布预测模型框架

Fig.1 Temporal and spatial distribution prediction model framework of EV charging load

包括交通路网模型、居民出行模型、EV时空转移模型3个部分。首先,根据地理信息数据,建立城市交通路网模型;然后,基于居民出行调查数据,构建不同复杂程度的EV出行链模型;最后,输入EV参数,综合城市道路和居民出行信息,以行程时间最短为目标指导EV的行驶并更新EV信息,建立EV时空转移模型。利用蒙特卡罗模拟方法重复抽样,不断更新EV的行驶信息和充电需求,生成考虑时空分布特性的充电负荷场景集。

1.1.1 交通路网模型

1)道路拓扑结构。

交通路网是研究EV充电负荷时空分布特性的基础,本文采用图论方法对城市双向交通路网进行建模。交通路网可用图 $G=(U, E, W)$ 表示,其中 U 为道路节点集合, E 为道路集合, W 为道路权重值集合, W 可采用道路长度、行驶时间等参数表征道路的量化属性。对含有 N 个节点的交通路网图 G 量化赋值,道路邻接矩阵 $D=[d_{ij}]_{N \times N}$ 可表示为:

$$D = \begin{bmatrix} 0 & w_{12} & w_{13} & \cdots & \infty \\ w_{21} & 0 & w_{23} & \cdots & \infty \\ w_{31} & w_{32} & 0 & \cdots & \infty \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \infty & \infty & \infty & \cdots & 0 \end{bmatrix} \quad (1)$$

$$d_{ij} = \begin{cases} w_{ij} & \text{道路 } ij \text{ 连通} \\ 0 & i=j \\ \infty & \text{道路 } ij \text{ 不连通} \end{cases} \quad (2)$$

式中: w_{ij} 为道路 ij 的权重值。

2)速度-流量实用模型。

在实际的交通出行过程中,EV用户最关心的路阻因素往往为行程时间,而与行程时间直接相关的EV行驶速度主要受到道路等级和车流量的限制。因此,本文引入速度-流量实用模型^[18]进行分析。

t 时段EV在直连道路 ij 上的行驶速度 $v_{ij}(t)$ 和通行时间 $s_{ij}(t)$ 可分别表示为:

$$v_{ij}(t) = \frac{v_{ij}^0}{1 + (q_{ij}(t)/C_{ij})^\beta} \quad (3)$$

$$s_{ij}(t) = \frac{l_{ij}}{v_{ij}(t)} \quad (4)$$

$$\beta = a + b \left(\frac{q_{ij}(t)}{C_{ij}} \right)^c \quad (5)$$

式中: v_{ij}^0 为直连道路 ij 上的自由流车速; $q_{ij}(t)$ 为 t 时段道路 ij 的车流量; C_{ij} 为道路 ij 的通行能力,其值与道路等级有关; a 、 b 、 c 为不同道路等级下的自适应系数; l_{ij} 为道路 ij 的长度。

1.1.2 居民出行模型

1)出行链结构。

根据我国传统居民的出行调查数据,本文将出

行目的地归纳为住宅(Home,用行程H表示)、工作(Work,用行程W表示)、商业(Business,用行程B表示)这3类,其中行程B主要包括购物吃饭和社交娱乐。根据文献[19]中出行链结构的划分规则,用简单链(H-W、B-H)和复杂链(H-W-B-H、H-B-W-H)描述EV用户的出行规律。

2)出行时刻。

根据2016年英国交通部的统计数据,对不同复杂度出行链的行程起始时刻(即出行时刻)采用不同的分布规律进行拟合,具体分布规律可参考文献[20]设定。

1.1.3 EV时空转移模型

1)EV用户的出行数据。

EV用户典型的出行数据包括出发地、目的地、出行时刻、返程时刻,这些参数可通过概率分布函数随机抽取;当前位置、荷电状态SOC(State Of Charge)、行驶路径等数据的求解见下文。

2)路径规划。

根据1.1.1节中的速度-流量实用模型,本文选择行程时间作为道路路阻,以行程时间最短为目标并采用Dijkstra算法实现EV路径规划。目标函数可表示为:

$$\min W_R^{o \rightarrow d} = \sum s_{ij}(t) \quad (6)$$

式中: o 、 d 分别为出发地、目的地节点; $W_R^{o \rightarrow d}$ 为节点 o 到节点 d 之间道路上的行驶时间; R 为从节点 o 到节点 d 的道路集合。

3)充电负荷时空分布预测。

假设城市功能区内包含足够的充电设施,即EV充电行为不受充电桩位置的影响。假设完整的出行周期为1d,用 $l_{TC,n}$ 表示出行链中的第 n 段行程,每段行程可能经过多条交通道路。当 $n=0$ 时,EV在居民区(即H)内,起始SOC $R_{SOC,0}=0.9$;当一天的行程结束后,EV返回居民区充电至SOC为 $R_{SOC,0}$ 。可根据式(7)更新EV结束第 n 段行程时的SOC $R_{SOC,n}$ 。

$$R_{SOC,n} = \frac{R_{SOC,n-1}C - \omega l_n}{C} \quad (7)$$

式中: $R_{SOC,n-1}$ 为EV结束第 $n-1$ 段行程时的SOC; C 为EV电池容量; ω 为EV行驶1km的耗电量; l_n 为第 n 段行程的行驶距离。

EV结束第 n 段行程后开始充电的条件按照式(8)进行预判,即当下一段行程结束时的SOC小于0.3时,触发充电需求。

$$R_{SOC,n}C - \omega l_{n+1} < 0.3C \quad (8)$$

假设EV结束第 n 段行程后立刻开始充电,直至SOC为0.9或者达到下一段行程的出发时刻。分别根据式(9)和式(10)计算EV第 n 段行程的起始充电时刻 $t_{start,n}$ 和充电时长 $t_{c,n}$,并根据式(11)计算EV m 的充电功率 $P_{m,t}$ 。

$$t_{start,n} = t_n + \Delta t_n \quad (9)$$

$$t_{c,n} = \min \left\{ \frac{(R_{SOC,0} - R_{SOC,n})C}{\eta P_c}, t_{n+1} - t_{start,n} \right\} \quad (10)$$

$$P_{m,t} = P_c \quad t \in [t_{start,n}, t_{start,n} + t_{c,n}] \quad (11)$$

式中: t_n 为随机抽样得到的第 n 段行程的起始时刻; Δt_n 为第 n 段行程的行驶时间,可由速度-流量实用模型计算得到; P_c 为EV的充电功率; η 为EV的充电效率。

综上所述,可得一天内各统计时段的充电负荷。采用蒙特卡罗模拟方法重复抽样即可生成计及时空分布特性的EV充电负荷场景集。其中一次蒙特卡罗模拟的流程见图附录A图A1。

1.2 风电预测误差的不确定性建模

风电的实际出力为风电功率预测值与预测误差之和。文献[21]表明,风电预测误差的概率分布受预测出力幅值的影响,且单一概率分布模型无法兼顾风电预测误差概率密度分布尖峰厚尾、非对称的特征。因此,本文采用高斯混合模型对不同功率区间内的风电预测误差进行拟合。风电功率预测框架如图2所示,风电预测误差不确定性建模的详细过程见附录B。




图2 风电功率预测框架

Fig.2 Prediction framework of wind power

1.3 基于Wasserstein距离的最优场景缩减

场景缩减是用少量具代表性的典型场景来代替原始的高维场景集,以减轻模型求解的计算负担,其精度在很大程度上依赖于场景间距离的定义^[22]。本文引入Wasserstein距离来衡量初始场景与典型场景之间的差距。Wasserstein距离越小,则缩减后的典型场景集越逼近初始场景集。Wasserstein距离 $d_w(P, P_s)$ 的定义如下:

$$d_w(P, P_s) = \inf_{\pi(\zeta_1, \zeta_2)} \left\{ \int d(\zeta_1, \zeta_2) \pi(d\zeta_1, d\zeta_2) \right\} \quad (12)$$

式中: $\pi(\cdot)$ 为满足边缘分布 P 和 P_s 的联合概率密度函数; $d(\zeta_1, \zeta_2) = \|\zeta_1 - \zeta_2\|_2$ 为场景 ζ_1 和场景 ζ_2 之间的欧氏范数; $\inf$ 为下确界函数。

最优场景缩减过程可视为“选址-分配”双层优

化问题,即下层对典型场景进行选择,上层对选取的典型场景进行概率分配,以获得最优的 Wasserstein 距离。离散域中基于 Wasserstein 距离的上层概率分配问题可表述为:

$$\begin{cases} d_w(P, P_s) = \min \left\{ \sum_{\zeta_i \in \Omega, \zeta_j \in \Omega_s} d(\zeta_i, \zeta_j) p_i x_{i,j} \right\} \\ \text{s.t.} \quad \sum_{\zeta_j \in \Omega_s} x_{i,j} = 1 \quad \zeta_i \in \Omega \end{cases} \quad (13)$$

式中: Ω 为初始场景集合; Ω_s 为典型场景集合; p_i 为初始场景 ζ_i 发生的概率; $x_{i,j}$ 为概率分配 0-1 决策变量,若初始场景 ζ_i 的概率被分配至典型场景 ζ_j 中则 $x_{i,j}=1$, 否则 $x_{i,j}=0$ 。式(13)中的约束条件表示每个初始场景的概率仅可被分配至 1 个典型场景中。

下层问题则是根据聚类数对典型场景进行选择,为此引入 0-1 辅助变量描述初始场景的选择状态,可表示如下:

$$\sum_{\zeta_i \in \Omega} y_i = Y \quad (14)$$

式中: Y 为给定的典型场景数; y_i 为 0-1 决策变量,若初始场景 ζ_i 被选择则 $y_i=1$, 否则 $y_i=0$ 。

此外,上层问题的求解建立在下层问题的场景确定的基础上,通过添加约束式(15)描述上、下层之间的耦合关系,当且仅当初始场景 $\zeta_i (\zeta_i \in \Omega)$ 被选中即 $y_i=1$ 时,对应列的决策变量 $x_{i,j}$ 才可以进行概率分配。

$$x_{i,j} \leq y_i \quad \zeta_i \in \Omega, \zeta_j \in \Omega_s \quad (15)$$

考虑到上层模型式(13)中的 Ω_s 为未知量,结合式(14)和式(15)所示约束, $\zeta_j \in \Omega_s$ 可松弛为 $\zeta_j \in \Omega$ (当 $\zeta_j \notin \Omega_s$ 时, $x_{i,j} \equiv 0$, 对目标函数值无影响)。

综上所述,基于 Wasserstein 距离的场景缩减问题可表示为式(16)所示 0-1 规划问题,其中典型场景发生的概率可根据式(17)计算。

$$\begin{cases} d_w(P, P_s) = \min \left\{ \sum_{\zeta_i, \zeta_j \in \Omega} d(\zeta_i, \zeta_j) p_i x_{i,j} \right\} \\ \text{s.t.} \quad \sum_{\zeta_i \in \Omega} y_i = Y \\ \sum_{\zeta_j \in \Omega} x_{i,j} = 1 \quad \zeta_i \in \Omega \\ x_{i,j} \leq y_j \quad \zeta_i, \zeta_j \in \Omega \end{cases} \quad (16)$$

$$p_j = \sum_{\zeta_i \in \Omega} p_i x_{i,j} \quad \zeta_j \in \Omega_s \quad (17)$$

1.4 净负荷场景的生成及削减

根据 1.2 节所述方法分别生成 N_s 个 EV 充电负荷场景和风电出力场景,经组合后生成 N_s^2 个 EV 充电负荷-风电组合场景。EV 充电负荷、风电出力组成的净负荷场景如式(18)所示。

$$P_k^{\text{net}} = P_i^{\text{EV}} - P_j^{\text{WT}} \quad k=1, 2, \dots, N_s^2; i, j=1, 2, \dots, N_s \quad (18)$$

式中: P_k^{net} 为第 k 个组合场景的净负荷功率; $P_i^{\text{EV}}、P_j^{\text{WT}}$ 分别为与第 k 个组合场景相对应的第 i 个 EV 充电负荷场景的 EV 充电功率、第 j 个风电出力场景的风电功率。

考虑到不同的 EV 充电负荷、风电出力场景组合形成的净负荷场景可能存在相似性,故采用 1.3 节中的方法对上述 N_s^2 个净负荷场景集进行缩减,得到 N_s 个典型场景,以减轻计算负担。

2 HADDN 随机优化模型

为了应对 EV 充电负荷、风电出力的不确定性对 HADDN 运行的影响,本文建立了基于 EV 充电负荷-风电组合场景集的随机优化模型。

2.1 目标函数

HADDN 随机优化模型以最小化系统网络损耗和节点电压偏差为优化目标,具体表达式为:

$$\min F = \min \{f_{\text{loss}}, f_u\} \quad (19)$$

式中: f_{loss} 为系统的总网络损耗,包含交、直流支路以及换流站内部的有功功率损耗; f_u 为系统的节点电压偏差,包括交、直流侧的电压偏差。

1) 目标函数 1: 最小化总网络损耗。

$$\min f_{\text{loss}} = \sum_{t=1}^T \left\{ \sum_{s=1}^{N_s} p_s \left[\sum_{l \in N_b^{\text{AC}}} (I_{l,t,s}^{\text{AC}})^2 R_l^{\text{AC}} + \sum_{i \in N_{\text{VSC}}} P_{i,t,s}^{\text{VSC,loss}} + \sum_{l' \in N_b^{\text{DC}}} (I_{l',t,s}^{\text{DC}})^2 R_{l'}^{\text{DC}} \right] \right\} \quad (20)$$

式中: T 为调度时段总数; p_s 为场景 s 发生的概率; $N_b^{\text{AC}}、N_b^{\text{DC}}$ 分别为交流、直流配电网中的支路集合; N_{VSC} 为换流站集合; $P_{i,t,s}^{\text{VSC,loss}}$ 为场景 s 下 t 时段换流站 i 的有功功率损耗; $I_{l,t,s}^{\text{AC}}、I_{l',t,s}^{\text{DC}}$ 分别为场景 s 下 t 时段交流配电网中支路 l 、直流配电网中支路 l' 上流过的电流; $R_l^{\text{AC}}、R_{l'}^{\text{DC}}$ 分别为交流配电网中支路 l 、直流配电网中支路 l' 的电阻。

2) 目标函数 2: 最小化节点电压偏差。

$$\min f_u = \sum_{t=1}^T \sum_{s=1}^{N_s} p_s \left[\sum_{j \in N_e^{\text{AC}} \cup N_e^{\text{DC}}} |(U_{j,t,s}^* - 1)| \right] \quad (21)$$

式中: $N_e^{\text{AC}}、N_e^{\text{DC}}$ 分别为交流、直流配电网的节点集合; $U_{j,t,s}^*$ 为场景 s 下 t 时段 HADDN 中节点 j 的电压标么值。其中,目标函数中绝对值的线性化方法见附录 C 式(C1)。

2.2 约束条件

1) 风机出力约束。

接入交流侧的风机有功、无功出力约束分别如式(22)和式(23)所示,接入直流侧的风机则不包含无功出力约束。

$$0 \leq P_{j,t,s}^{\text{WT}} \leq P_{j,t,s}^{\text{WT0}} \quad j \in N_{\text{WT}} \quad (22)$$

$$Q_{j,t,s}^{\text{WT}} = \tan(\sec \varphi_{\text{WT}}) P_{j,t,s}^{\text{WT}} \quad j \in N_{\text{WT}} \quad (23)$$

式中: N_{WT} 为接入风机的节点集合; $P_{j,t,s}^{\text{WT}}$ 、 $Q_{j,t,s}^{\text{WT}}$ 分别为场景 s 下 t 时段接入节点 j 处风机的有功、无功出力; $P_{j,t,s}^{\text{WT0}}$ 为场景 s 下 t 时段接入节点 j 处风机的预测出力值; φ_{WT} 为风机的功率因数角。

2) 静止无功发生器 SVG (Static Var Generator) 运行约束。

SVG 需满足的运行约束条件为:

$$Q_{\min}^{\text{SVG}} \leq Q_{j,t}^{\text{SVG}} \leq Q_{\max}^{\text{SVG}} \quad (24)$$

式中: $Q_{j,t}^{\text{SVG}}$ 为 t 时段节点 j 处 SVG 输出的无功功率; $Q_{\max}^{\text{SVG}}$ 、 $Q_{\min}^{\text{SVG}}$ 分别为 SVG 输出无功功率的上、下限。

3) HADDN 的交互功率约束。

本文考虑交流配电网与上级电网、直流配电网与交流配电网的交互功率约束, 分别如式 (25) 和式 (26) 所示。

$$\begin{cases} P_{\min}^{\text{grid}} \leq P_{i,t,s}^{\text{AC, grid}} \leq P_{\max}^{\text{grid}} \\ Q_{\min}^{\text{grid}} \leq Q_{i,t,s}^{\text{AC, grid}} \leq Q_{\max}^{\text{grid}} \end{cases} \quad i \in N_e^{\text{AC}} \quad (25)$$

$$P_{\min}^{\text{A2D, grid}} \leq P_{j,t,s}^{\text{DC, grid}} \leq P_{\max}^{\text{A2D, grid}} \quad j \in N_e^{\text{DC}} \quad (26)$$

式中: $P_{i,t,s}^{\text{AC, grid}}$ 、 $Q_{i,t,s}^{\text{AC, grid}}$ 分别为场景 s 下 t 时段上级电网向交流配电网节点 i 输送的有功、无功功率; $P_{j,t,s}^{\text{DC, grid}}$ 为场景 s 下 t 时段交流配电网向直流配电网节点 j 输送的有功功率; $P_{\max}^{\text{grid}}$ 、 $P_{\min}^{\text{grid}}$ 和 $Q_{\max}^{\text{grid}}$ 、 $Q_{\min}^{\text{grid}}$ 分别为上级电网与交流配电网交互的有功功率和无功功率上、下限; $P_{\max}^{\text{A2D, grid}}$ 、 $P_{\min}^{\text{A2D, grid}}$ 分别为交流配电网与直流配电网交互的有功功率上、下限。

4) 安全约束。

交流配电网的安全约束主要包括节点电压、支路电流上下限约束以及支路传输功率限制, 具体如式 (27) 所示。直流配电网的安全约束与交流配电网类似, 此处不再赘述。

$$\begin{cases} (I_{\min}^{\text{AC}})^2 \leq \tilde{I}_{l,t,s}^{\text{AC}} \leq (I_{\max}^{\text{AC}})^2 \\ (U_{\min}^{\text{AC}})^2 \leq \tilde{U}_{i,t,s}^{\text{AC}} \leq (U_{\max}^{\text{AC}})^2 \\ P_{\min}^{\text{AC, tran}} \leq P_{l,t,s}^{\text{AC, tran}} \leq P_{\max}^{\text{AC, tran}} \\ Q_{\min}^{\text{AC, tran}} \leq Q_{l,t,s}^{\text{AC, tran}} \leq Q_{\max}^{\text{AC, tran}} \end{cases} \quad l \in N_b^{\text{AC}}, i \in N_e^{\text{AC}} \quad (27)$$

式中: $\tilde{I}_{l,t,s}^{\text{AC}}$ 、 $\tilde{U}_{i,t,s}^{\text{AC}}$ 分别为场景 s 下 t 时段交流配电网中支路 l 上流过电流的平方、节点 i 处电压的平方; $P_{l,t,s}^{\text{AC, tran}}$ 、 $Q_{l,t,s}^{\text{AC, tran}}$ 分别为场景 s 下 t 时段交流配电网中支路 l 传输的有功、无功功率; $I_{\max}^{\text{AC}}$ 和 $I_{\min}^{\text{AC}}$ 、 $U_{\max}^{\text{AC}}$ 和 $U_{\min}^{\text{AC}}$ 、 $P_{\max}^{\text{AC, tran}}$ 和 $P_{\min}^{\text{AC, tran}}$ 、 $Q_{\max}^{\text{AC, tran}}$ 和 $Q_{\min}^{\text{AC, tran}}$ 分别为交流配电网的支路电流、节点电压、支路传输有功功率、支路传输无功功率的上限和下限。

此外, HADDN 随机优化模型还需要满足交/直流二阶锥潮流约束、储能系统 (ESS) 的运行约束以及换流站的运行约束, 具体如附录 C 式 (C2) — (C21) 所示。

3 基于 ADMM 的多目标分区优化模型

为了减轻交直流区域的数据通信压力, 保护区域信息隐私, 实现分区自治, 本文采用基于目标值交换原理的 ADMM 求解 HADDN 多目标优化模型。

3.1 多目标分区解耦机制

1) 将第 2 节建立的集中式 HADDN 多目标优化模型转化为单目标模型, 如附录 D 式 (D1) — (D4) 所示, 具体步骤见附录 D。

2) 采用线路撕裂法, 将换流站与直流配电网之间的直流联络线撕裂, 解耦得到 2 个独立的子区域 A、B, 如附录 D 图 D1 所示。

针对子区域 A、B 的优化模型, 分别引入辅助变量 ξ^A 和 ξ^B , 则目标函数 i 的值 f_i 转换为子区域 A 的目标函数值 f_i^A 与子区域 B 的目标函数值 f_i^B 之和, 即 $f_i = f_i^A + f_i^B$ 。

3) 在各子区域中引入虚拟目标因子, 即在子区域 A 中引入虚拟目标因子 $\hat{f}_i^B$ 代替 f_i^B , 在子区域 B 引入虚拟目标因子 $\hat{f}_i^A$ 代替 f_i^A , 并令 $\hat{f}_i^B = f_i^B$, $\hat{f}_i^A = f_i^A$, 则模型式 (D4) 可转化为附录 D 式 (D5)。

分区解耦后, 子区域 A、B 需添加功率、电压以及目标函数值的一致性约束, 具体可表示为:

$$\begin{cases} \mathbf{x}_{\text{co}}^A = \mathbf{x}_{\text{co}}^B \\ \mathbf{x}_{\text{co}}^A = [P_{\text{co}}^A, U_{\text{co}}^A, \xi^A, f_i^A, \hat{f}_i^B]^T \\ \mathbf{x}_{\text{co}}^B = [P_{\text{co}}^B, U_{\text{co}}^B, \xi^B, \hat{f}_i^A, f_i^B]^T \end{cases} \quad (28)$$

式中: $\mathbf{x}_{\text{co}}^A$ 、 $\mathbf{x}_{\text{co}}^B$ 分别为子区域 A、B 的耦合变量; P_{co}^A 、 P_{co}^B 分别为子区域 A 向子区域 B 输送的功率、子区域 B 从子区域 A 接收的功率; U_{co}^A 、 U_{co}^B 分别为子区域 A、B 边界处的节点电压。

3.2 分布式优化

对优化问题式 (D5) 的目标函数值取相反数, 将其转化为最小化问题, 并将式 (28) 以惩罚项的形式添加到优化问题中, 根据 ADMM 的原理, 可得到解耦后子区域 A、B 的优化模型分别如附录 D 式 (D6) 和式 (D7) 所示。基于 ADMM 的分布式调度求解步骤见附录 E。

4 算例分析

为了验证本文所建模型的有效性, 在 MATLAB R2017b 平台上利用 YALMIP 工具箱以及 CPLEX 求解器建模求解, 硬件环境为 AMD Ryzen 7 4800H CPU @ 2.90 GHz, 16 G 内存。

4.1 基本数据设置

本文算例测试系统的拓扑结构如附录 F 图 F1 所示, 交流配电网采用改进的 IEEE 33 节点网络, 直流配电网采用文献 [23] 中的 15 节点算例测试系统,

两者通过换流站相连接。交通网络采用 29 节点道路拓扑结构,相关道路参数见文献[18]。充电站建在交通网络的 4 个区域(居民区 1、居民区 2、工作区、商业区)内,且分别接入交、直流配电网的 4 个节点,以实现电气-交通网络的耦合。

交流配电网的额定电压为 15 kV,直流配电网的额定电压为 10 kV,两配电网电压幅值的最大波动范围为 $[0.95, 1.05]$ p.u.;交、直流配电网中支路允许通过的最大电流分别为 500、800 A,变电站关口以及支路传输的有功、无功功率上下限分别为 ± 9 MW 和 ± 6 Mvar。交、直流配电网的基本负荷曲线见附录 F 图 F2,并将无功负荷数值设置为有功负荷数值的 50%。接入 HADDN 的设备有风电机组、EV 充电桩、ESS、SVG,其基本参数设置见附录 F 表 F1—F3。本文采用蒙特卡罗模拟方法分别生成 500 个 EV 充电负荷、风电出力场景,经净负荷场景生成及缩减后得到 5 个 EV 充电负荷-风电典型场景集。

交通网络拓扑被划分为居民区 1(含节点 1—11)、居民区 2(含节点 12—16)、工作区(含节点 17—20、22、27)和商业区(含节点 21、23—26、28、29)。4 个区域内共有 1 200 辆 EV,各 EV 用户按一定的概率选择出行链,具体见附录 F 表 F4。EV 电池的额定容量为 30 kW·h,充电 SOC 上限为 0.9,充电需求触发 SOC 阈值为 0.3;EV 在居民区内进行慢速充电,在工作区和商业区内进行快速充电,慢充、快充功率分别为 15、30 kW;EV 行驶 1 km 的耗电量取值见附录 F 表 F5。

4.2 仿真结果分析

4.2.1 EV 充电负荷的时空分布特征

为了验证本文所建 EV 充电负荷时空分布模型的有效性,本节以某 EV 充电负荷场景为例展开分析。

首先以某辆 EV 的全天行程为例,说明 EV 时空转移特性对充电负荷时空分布的影响,具体结果如附录 G 图 G1 所示。图 G1(a)中,每条黑色线段代表 EV 的时空转移轨迹,其向 x - y 平面的投影(紫色线段)为 EV 的实际行驶路线。由图可知:EV 从居民区节点 12 出发到达商业区节点 21,停留 15 min 后前往工作区节点 20 上班,在节点 20 处的 SOC 满足式(8)所示充电需求触发条件即开始充电,在充电时段内该节点会累积部分充电负荷;下班后,EV 返回居民区,且为了保证第二天的正常行驶而进行充电,同样会导致节点 12 处充电负荷增加。

进一步以 1 h 为仿真步长(即全天 24 h 被分为 24 个时段),统计各区域全天 24 h 内 EV 触发充电需求的分布情况,结果如图 3 所示。

由图 3 可知,不同区域的 EV 充电需求数量在时间上分布不均衡。由于 EV 在结束一天的行程后需




图3 各区域的EV充电需求分布

Fig.3 EV charging demand distribution in each region

返回住宅充电,故在时段 17—21 内居民区 1、居民区 2 出现了充电需求高峰,共有 587 辆 EV 产生充电需求;工作区以工作出行为目的,EV 充电需求高峰集中在上班的时段 7—10 内,总需求为 288 辆;商业区以娱乐出行为主,充电需求高峰时段的跨度较长,主要集中在时段 12—21。可见,EV 时空转移特性会导致各区域内 EV 充电需求的时间分布不均衡,使得该场景下的充电负荷峰谷差明显,呈现“双峰”特性。

EV 充电负荷的时空分布情况如附录 G 图 G2 所示。由图可知:由于 EV 用户集中在工作时段进行充电,因此工作区(含节点 17—20、22、27)在时段 7—10 内有明显的负荷高峰,峰值为 1.025 MW;用户结束行程后返回居民区(含节点 1—16)充电,在 16:00—20:00 时段内会累积另一个负荷高峰,峰值达到 1.56 MW;商业区的 EV 充电负荷则较为分散。

4.2.2 场景缩减算法的性能分析

为了验证基于 Wasserstein 距离的最优场景缩减算法的有效性,定义式(29)所示距离指标 T_g 来衡量本文所用场景缩减算法与传统同步回代消减法所得典型场景集对初始场景集的逼近程度。 T_g 值越小,则缩减后的典型场景集越逼近初始场景集。

$$T_g = \sum_{\zeta_i \in \Omega} p_i \min_{\zeta_j \in \Omega_k} \{d(\zeta_i, \zeta_j)\} \quad (29)$$

根据第 1 节的场景建模方法,分别生成 300 个、500 个净负荷场景,经基于 Wasserstein 距离的最优场景缩减算法、传统同步回代消减法缩减后的结果对比见附录 G 表 G1。由表可知,本文所用场景缩减算法的距离指标 T_g 值较小,即缩减后的典型场景集更能代表初始场景集。此外,本文所用场景缩减算法的求解速度较传统同步回代消减法更优,且随着场景数量规模的扩大,该优势愈加明显。

4.2.3 优化调度结果分析

1) 优化策略性能分析。

为了验证本文所提方法的有效性,设置如下 3 种模式进行对比分析:①模式 1,不考虑 ESS、SVG 的接入以及 DG、VSC 的无功调节能力,VSC 采用下垂

控制策略,对系统进行有功功率优化;②模式2,考虑ESS、SVG的接入以及DG、VSC的无功调节能力,VSC采用下垂控制策略,对系统进行有功功率和无功功率协调优化;③模式3,考虑ESS、SVG的接入以及DG、VSC的无功调节能力,VSC采用主从控制策略,对系统进行有功功率和无功功率协调优化。

上述3种模式的优化结果如表1所示,表中节点电压偏差、电压波动范围均为标么值,后同。由表可知,考虑多设备间的协调优化后,相较于模式1,模式2的网络损耗减小,节点电压偏差减小了46.0%,系统节点最高电压从1.0401 p.u.降低为1.0179 p.u.,验证了本文所提方法的有效性。此外,对比模式2和模式3的结果可知,VSC采用下垂控制和主从控制时,系统的网络损耗、节点电压偏差的优化效果基本一致。3种模式下配电网的节点电压分布结果见附录G图G3。

表1 3种模式的优化结果

Table 1 Optimization results of three modes

模式	网络损耗 / MW	节点电压偏差	电压波动范围
1	2.9055	19.3899	0.9670~1.0401
2	2.2364	10.4739	0.9797~1.0179
3	2.2534	10.7008	0.9790~1.0167

以12:00时刻为例,模式2和模式3下各换流站向直流侧传输的有功功率结果如表2所示。交流配电网通过VSC₁和VSC₂向直流配电网供电,其中VSC₁靠近交流配电网的首端,承担向直流配电网供电的主要任务。VSC₃将直流侧的有功功率转送至交流侧,避免了有功功率在交流网络中的长距离输送,有利于减小网络损耗。在模式3下,主换流站VSC₁负责维持直流电压稳定和平衡系统功率,因此VSC₁输送的功率较大。采用下垂控制时各VSC根据下垂斜率方程共同承担功率平衡,通过调节直流电压来控制功率大小。因此相比于模式3,模式2下VSC₁承担的有功功率减少,VSC₂和VSC₃传输的有功功率增大。

表2 换流站直流侧传输的有功功率

Table 2 Active power transmitted by DC side of converter station

模式	直流侧传输的有功功率 / MW		
	VSC ₁	VSC ₂	VSC ₃
2	0.4985	0.2667	-0.3252
3	0.5169	0.2212	-0.2855

结合表1和2可知,在不同的VSC控制方式下,本文所提优化策略均能取得良好的优化效果。

2) 不同运行方案的潮流分析。

以模式2为例,为了进一步分析EV充电负荷接入系统后,调节ESS、SVG、VSC对电网电压的支撑作

用,设置以下4种运行方案:①方案1不考虑ESS、SVG、VSC的无功调节能力,系统接入基准EV充电负荷;②方案2—4均考虑ESS、SVG、VSC的无功调节能力,且方案2中系统不接入EV充电负荷,方案3中系统接入基准EV充电负荷,方案4中系统接入的EV充电负荷为基准值的1.5倍。

4种运行方案下居民区1充电站即交流节点24的电压曲线如图4所示,图中电压为标么值。由图可知:由于方案1不考虑各设备的无功调节能力,交流侧节点25处的风机出力大于本地负荷,会发生功率倒送,导致节点24的电压大幅升高;同时根据上文EV充电负荷时空分布特性的分析,居民区1的充电负荷高峰集中在16:00—20:00时段,此时风电消纳量增大,使得方案1下该时段内的电压有明显下降。此外,随着EV充电负荷接入比例的不断增大,高峰时段的EV充电需求激增。为了减小负荷峰谷差、提高风电利用率,在EV充电负荷低谷时段(00:00—10:00),大量风电功率向ESS倒送,导致方案2—4下该时段内的节点电压逐渐升高。




图4 交流节点24的电压曲线

Fig.4 Voltage curve of AC Node 24

方案3的ESS有功、无功功率结果如附录G图G4所示,其中功率值大于0表示吸收功率,值小于0表示发出功率。结合图4分析可知:方案3中配置的ESS在负荷低谷时段吸收系统中的无功功率,缓解了风电功率倒送引起的节点电压升高情况;ESS在负荷高峰时段发出无功功率,防止电压降落,起到了抑制节点电压波动的作用。同时,ESS在负荷低谷时段吸收有功功率,在负荷高峰时段发出有功功率,起到了减小负荷峰谷差、降低网络损耗的作用。

工作区充电站即交流节点10的电压曲线以及ESS的工作情况见附录G图G5。由图可知,接入EV充电负荷之后,各方案的节点电压在07:00—10:00时段内均有明显下降,符合EV用户普遍选择到达工作地后进行充电的行为特性。ESS接入后,在负荷低谷时段(00:00—05:00)吸收有功功率,在EV充电负荷高峰时段发出有功功率以满足充电需求,并发出大量的无功功率以防止节点电压过低,起到了无

功补偿和削峰填谷的作用。

3) ADMM 的有效性分析。

为了验证本文所用分布式优化方法的有效性,以模式 3 为例,分别采用集中式、分布式优化方法求解 HADDN 优化问题,结果如表 3 所示。由表可知,ADMM 求解所得网络损耗、节点电压偏差与集中式方法所得结果基本一致,验证了 ADMM 的有效性。分布式优化和集中式优化的残差迭代过程见附录 G 图 G6。由图可知:分布式优化经过 34 次迭代后残差达到收敛裕度 5×10^{-3} ,用时 463.365 s;集中式优化由于不需要迭代计算,其求解时间为 152.459 s。考虑到本文属于日前优化调度问题,虽然分布式优化方法的求解时间相对较长,但仍在可接受的范围内。故相比于集中式优化方法,分布式优化方法在牺牲了一定的求解时间的条件下实现了对优化问题的解耦和对隐私的保障^[24]。

表 3 集中式优化方法与分布式优化方法的
计算结果对比

Table 3 Comparison of calculation results between
centralized and distributed optimization methods

方法	网络损耗 / MW	节点电压偏差	求解时间 / s	迭代次数
分布式	2.2534	10.7008	463.365	34
集中式	2.2534	10.7010	152.459	—

4) 二阶锥松弛精度分析。

当优化问题的目标函数为支路电流的严格增函数^[25]时,二阶锥松弛精度得以保证。考虑到本文的优化目标包含节点电压偏差项,可能导致二阶锥松弛不精确。以 ADMM 的迭代求解结果对二阶锥松弛精度进行验证^[5],其误差散点图见附录 G 图 G7。由图可知,最大松弛误差为 4.5884×10^{-4} ,满足二阶锥松弛精度要求。

5 结论

针对 EV、风电大规模接入给 HADDN 的安全经济运行带来的挑战,本文构建了基于随机优化的 HADDN 多目标分布式协同优化模型。基于算例分析可得如下结论。

1) 居民的出行规律和交通拓扑结构会影响 EV 的行驶、停驻、充电行为,导致充电负荷时空分布的不均衡性,具体表现为时间分布上的“双峰”特性以及空间分布上的区域特性。

2) 将基于 Wasserstein 距离的最优场景缩减算法与传统同步回代消减法进行仿真对比,结果表明相比于传统同步回代消减法,基于 Wasserstein 距离的最优场景缩减算法具有更高的拟合精度,且计算效率更优。

3) 在不同的 VSC 控制模式(下垂控制、主从控

制)下,所提 HADDN 的有功功率和无功功率协调优化模型均能有效地降低网络损耗、均衡节点电压,消除规模化 EV 充电负荷接入导致的电压越限风险。

4) 通过分区解耦和目标分解,采用基于目标值交换原理的 ADMM 实现了对所建多目标优化模型的分布式求解。ADMM 仅需交换区域目标函数以及边界耦合变量,就可获得各区域多目标的全局最优解,同时保证了各区域的隐私安全。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 孙旭,邱晓燕,张志荣,等. 基于数据驱动的交流配电网分布式鲁棒优化调度[J]. 电网技术,2021,45(12):4768-4778.
SUN Xu, QIU Xiaoyan, ZHANG Zhirong, et al. Distributed robust optimal dispatching of AC/DC distribution network based on data driven mode[J]. Power System Technology, 2021, 45(12):4768-4778.
- [2] 黄雨涵,丁涛,李雨婷,等. 碳中和背景下能源低碳化技术综述及对新型电力系统发展的启示[J]. 中国电机工程学报,2021,41(增刊1):28-51.
HUANG Yuhuan, DING Tao, LI Yuting, et al. Decarbonization technologies and inspirations for the development of novel power systems in the context of carbon neutrality[J]. Proceedings of the CSEE, 2021, 41(Supplement 1):28-51.
- [3] 寇凌峰,吴鸣,李洋,等. 主动配电网分布式有功无功优化调控方法[J]. 中国电机工程学报,2020,40(6):1856-1865.
KOU Lingfeng, WU Ming, LI Yang, et al. Optimization and control method of distributed active and reactive power in active distribution network[J]. Proceedings of the CSEE, 2020, 40(6):1856-1865.
- [4] 符杨,张智泉,李振坤. 基于二阶段鲁棒优化模型的混合交流配电网无功电压控制策略研究[J]. 中国电机工程学报,2019,39(16):4764-4774,4978.
FU Yang, ZHANG Zhiquan, LI Zhenkun. Research on reactive power voltage control strategy for hybrid AC/DC distribution network based on two-stage robust optimization model[J]. Proceedings of the CSEE, 2019, 39(16):4764-4774, 4978.
- [5] 马鑫,郭瑞鹏,王蕾,等. 基于二阶锥规划的交流主动配电网日前调度模型[J]. 电力系统自动化,2018,42(22):144-150.
MA Xin, GUO Ruipeng, WANG Lei, et al. Day-ahead scheduling model for AC/DC active distribution network based on second-order cone programming[J]. Automation of Electric Power Systems, 2018, 42(22):144-150.
- [6] 杨少波,李铁成,周文,等. 含柔性变电站的交流配电网分布式优化调度方法[J]. 电力自动化设备,2021,41(8):17-24.
YANG Shaobo, LI Tiecheng, ZHOU Wen, et al. Distributed optimal dispatching method for AC/DC distribution network with flexible substations[J]. Electric Power Automation Equipment, 2021, 41(8):17-24.
- [7] 张志荣,邱晓燕,孙旭,等. 基于 ADMM 的交流混合配电网分布式电压优化模型[J]. 电网技术,2021,45(11):4551-4559.
ZHANG Zhirong, QIU Xiaoyan, SUN Xu, et al. Distributed voltage optimization model for AC/DC hybrid distribution network based on ADMM[J]. Power System Technology, 2021, 45(11):4551-4559.
- [8] 王家怡,高红均,刘友波,等. 考虑风电不确定性的交流混合配电网分布式优化运行[J]. 中国电机工程学报,2020,40(2):550-563.
WANG Jiayi, GAO Hongjun, LIU Youbo, et al. A distributed

- operation optimization model for AC/DC hybrid distribution network considering wind power uncertainty[J]. Proceedings of the CSEE, 2020, 40(2): 550-563.
- [9] 梁海平, 王岩, 刘英培, 等. 计及源荷不确定性的混合交直流主动配电网分层-分布式优化调度[J]. 电力自动化设备, 2021, 41(12): 62-69, 77.
- LIANG Haiping, WANG Yan, LIU Yingpei, et al. Hierarchical-distributed optimal scheduling of hybrid AC/DC active distribution network considering source and load uncertainties[J]. Electric Power Automation Equipment, 2021, 41(12): 62-69, 77.
- [10] 郭创新, 刘洞宇, 朱承治, 等. 电动汽车居民区充电负荷建模分析[J]. 电力自动化设备, 2020, 40(1): 1-9.
- GUO Chuangxin, LIU Dongyu, ZHU Chengzhi, et al. Modeling and analysis of electric vehicle charging load in residential area[J]. Electric Power Automation Equipment, 2020, 40(1): 1-9.
- [11] 王守相, 陈建凯, 王洪坤, 等. 综合考虑电动汽车充电与储能及可中断负荷调度的配电网两阶段灵活性提升优化方法[J]. 电力自动化设备, 2020, 40(11): 1-10.
- WANG Shouxiang, CHEN Jiankai, WANG Hongkun, et al. Two-stage flexibility improvement optimization method of distribution network considering EV charging and scheduling of energy storage and interruptible loads[J]. Electric Power Automation Equipment, 2020, 40(11): 1-10.
- [12] 张洪财, 胡泽春, 宋永华, 等. 考虑时空分布的电动汽车充电负荷预测方法[J]. 电力系统自动化, 2014, 38(1): 13-20.
- ZHANG Hongcai, HU Zechun, SONG Yonghua, et al. A prediction method for electric vehicle charging load considering spatial and temporal distribution[J]. Automation of Electric Power Systems, 2014, 38(1): 13-20.
- [13] TANG D F, WANG P. Probabilistic modeling of nodal charging demand based on spatial-temporal dynamics of moving electric vehicles[J]. IEEE Transactions on Smart Grid, 2016, 7(2): 627-636.
- [14] 曾梦隆, 韦钢, 朱兰, 等. 交直流配电网中电动汽车充换储一体站规划[J]. 电力系统自动化, 2021, 45(18): 52-60.
- ZENG Menglong, WEI Gang, ZHU Lan, et al. Planning of electric vehicle charging-swapping-storage integrated station in AC/DC distribution network[J]. Automation of Electric Power Systems, 2021, 45(18): 52-60.
- [15] 朱永胜, 杨俊林, 董燕, 等. 考虑风-车不确定性接入的节能减排动态调度研究[J]. 太阳能学报, 2021, 42(8): 316-324.
- ZHU Yongsheng, YANG Junlin, DONG Yan, et al. Dynamic dispatching with wind-electric vehicle uncertainty accessing for energy saving and emission reduction[J]. Acta Energetica Sinica, 2021, 42(8): 316-324.
- [16] 孙国强, 徐广开, 沈培锋, 等. 规模化电动汽车负荷的柔性台区协同经济调度[J]. 电网技术, 2020, 44(11): 4395-4404.
- SUN Guoqiang, XU Guangkai, SHEN Peifeng, et al. Coordinated economic dispatch of flexible district for large-scale electric vehicle load[J]. Power System Technology, 2020, 44(11): 4395-4404.
- [17] 胡代豪, 郭力, 刘一欣, 等. 计及光储快充一体站的配电网随机-鲁棒混合优化调度[J]. 电网技术, 2021, 45(2): 507-519.
- HU Daihao, GUO Li, LIU Yixin, et al. Stochastic/robust hybrid optimal dispatching of distribution networks considering fast charging stations with photovoltaic and energy storage[J]. Power System Technology, 2021, 45(2): 507-519.
- [18] 邵尹池, 穆云飞, 余晓丹, 等. “车-路-网”模式下电动汽车充电负荷时空预测及其对配电网潮流的影响[J]. 中国电机工程学报, 2017, 37(18): 5207-5219, 5519.
- SHAO Yinchi, MU Yunfei, YU Xiaodan, et al. A spatial-temporal charging load forecast and impact analysis method for distribution network using EVs-traffic-distribution model[J]. Proceedings of the CSEE, 2017, 37(18): 5207-5219, 5519.
- [19] 陈丽丹, 聂涌泉, 钟庆. 基于出行链的电动汽车充电负荷预测模型[J]. 电工技术学报, 2015, 30(4): 216-225.
- CHEN Lidan, NIE Yongquan, ZHONG Qing. A model for electric vehicle charging load forecasting based on trip chains[J]. Transactions of China Electrotechnical Society, 2015, 30(4): 216-225.
- [20] 李含玉, 杜兆斌, 陈丽丹, 等. 基于出行模拟的电动汽车充电负荷预测模型及V2G评估[J]. 电力系统自动化, 2019, 43(21): 88-96.
- LI Hanyu, DU Zhaobin, CHEN Lidan, et al. Trip simulation based charging load forecasting model and vehicle-to-grid evaluation of electric vehicles[J]. Automation of Electric Power Systems, 2019, 43(21): 88-96.
- [21] 刘丽军, 张嫣, 徐启峰. 一种考虑功率不确定性影响及配电网灵活性需求的区间优化调度方法[J]. 电网技术, 2020, 44(12): 4654-4664.
- LIU Lijun, ZHANG Yan, XU Qifeng. An interval optimal scheduling method considering the influence of power uncertainty and the flexibility of distribution network[J]. Power System Technology, 2020, 44(12): 4654-4664.
- [22] 董骁翀, 孙英云, 蒲天骄, 等. 一种基于 Wasserstein 距离及有效性指标的最优场景约简方法[J]. 中国电机工程学报, 2019, 39(16): 4650-4658, 4968.
- DONG Xiaochong, SUN Yingyun, PU Tianjiao, et al. An optimal scenario reduction method based on Wasserstein distance and validity index[J]. Proceedings of the CSEE, 2019, 39(16): 4650-4658, 4968.
- [23] PATNAM B S K, PINDORIYA N M. DLMP calculation and congestion minimization with EV aggregator loading in a distribution network using bilevel program[J]. IEEE Systems Journal, 2021, 15(2): 1835-1846.
- [24] 张志义, 余涛, 李昊飞, 等. 考虑大气污染物时空分布的多区域电力系统调度及其多目标分布式优化[J]. 电网技术, 2020, 44(3): 1047-1058.
- ZHANG Zhiyi, YU Tao, LI Haoifei, et al. Dispatching model of multi-area power systems considering space-time distribution of atmospheric pollutants and its decentralized multi-objective optimization[J]. Power System Technology, 2020, 44(3): 1047-1058.
- [25] 孙峰洲, 马骏超, 于淼, 等. 含多端柔性多状态开关的主动配电网日前-日内协调能量管理方法[J]. 中国电机工程学报, 2020, 40(3): 778-790.
- SUN Fengzhou, MA Junchao, YU Miao, et al. A day-ahead and intraday coordinated energy management method for active distribution networks based on multi-terminal flexible distribution switch[J]. Proceedings of the CSEE, 2020, 40(3): 778-790.

作者简介:



刘 岩

刘 岩(1998—),男,硕士研究生,主要研究方向为电力系统优化调度(E-mail: liuyancfop@163.com);

张亚超(1985—),男,副教授,博士,通信作者,主要研究方向为含新能源电力系统优化调度(E-mail: yczhang@fzu.edu.cn)。

(编辑 陆丹)

(下转第272页 continued on page 272)

Electric vehicle charging navigation method based on hierarchical reinforcement learning

ZHAN Hua¹, JIANG Changxu², SU Qinglie¹

(1. Automotive College, Fujian Chuanzheng Communications College, Fuzhou 350007, China;

2. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

Abstract: In order to effectively solve the problem of EV (Electric Vehicle) charging destination optimization and charging path planning, as well as the online real-time decision making problem of EV charging navigation, a double-layer stochastic optimization model for EV charging navigation considering a variety of uncertainty factors is established, and an EV charging navigation method based on HEDQN (Hierarchical Enhanced Deep Q Network) is proposed. The proposed HEDQN algorithm adopts double competitive deep Q network algorithm based on the Huber loss function, including two layers of eDQN (enhanced Deep Q Network) algorithms. The upper eDQN is used to optimize the EV charging destination. On this basis, the lower eDQN is utilized to optimize the EV charging path in real time. Finally, the proposed HEDQN algorithm is simulated and verified in a city transportation network. The simulation results illustrate that compared with the nearest recommendation algorithm based on Dijkstra's shortest path, single-layer deep Q network algorithm and traditional hierarchical deep Q network algorithm, the proposed HEDQN algorithm can effectively decrease the EV charging cost, so as to realize the online real-time EV charging navigation. In addition, the adaptability of the proposed HEDQN algorithm is verified after the simulation environment changes.

Key words: electric vehicles; hierarchical reinforcement learning; charging navigation; path planning; deep reinforcement learning; real-time decision making

(上接第226页 continued from page 226)

Multi-objective distributed cooperative optimization of hybrid AC / DC distribution network considering EV load-wind power heterogeneous scenario sets

LIU Yan¹, ZHANG Yachao¹, ZHU Shu², XIE Shiwei¹

(1. School of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China;

2. Dispatching and Control Center of State Grid Hunan Electric Power Co., Ltd., Changsha 410004, China)

Abstract: The large-scale access of EVs (Electric Vehicles) and distributed energy has posed great challenges to the safe and economic operation of distribution networks. Considering that HADDN (Hybrid AC / DC Distribution Network) has the characteristics of high flexibility and controllability and significant partitioning features, a distributed cooperative optimization method of HADDN active and reactive power considering the dual uncertainties of source side and load side is proposed. Firstly, the EV charging load-wind power scenario generation method is proposed, which comprehensively considers the traffic topology structure, the residents' travel behavior and the interval difference of wind power prediction error. The optimal scenario reduction algorithm based on Wasserstein distance is used to generate typical probability scenarios. Secondly, the stochastic optimization model of HADDN is established to minimize the network loss and node voltage deviation. Then, the objective decomposition and region decoupling of the proposed multi-objective optimization model are performed, and the alternating direction method of multipliers based on the objective value exchange principle is used to solve the above model. Finally, the effectiveness of the proposed method is verified by a numerical example.

Key words: hybrid AC / DC distribution network; electric vehicles; wind power; distributed cooperative optimization; alternating direction method of multipliers; stochastic optimization

附录 A




图 A1 EV 充电负荷预测流程图

Fig.A1 Flowchart of predicting EV charging load

附录 B

本文选择 Elia 电网^[21]2020 年 1 月 1 日至 2021 年 6 月 1 日的风电实测数据作为研究对象。以风电机组的额定出力为基准值, 对风电预测出力和预测误差进行标么化处理, 得到不同风电预测功率对应的预测误差分布散点图, 如图 B1 所示。由图可知, 风电预测误差在功率区间 $[0, 0.25]$ p.u.、 $[0.25, 0.6]$ p.u.和 $[0.6, 1]$ p.u.内表现出不同的分布规律, 故预测误差概率密度函数分上述 2 个区间进行拟合。




图 B1 不同风电预测功率区间的预测误差分布

Fig.B1 Prediction error distribution of different predicted power ranges of wind power

本文采用高斯混合模型对风电预测误差分布进行拟合, 拟合得到的概率密度函数如附录图 B2 所示, 其中高斯混合模型可表示为:

$$f(x) = \sum_{k=1}^n \omega_k f_N(x | \mu_k, \sigma_k^2) \quad (B1)$$

式中: n 为组成高斯混合模型的正态分布个数; $f_N(x | \mu_k, \sigma_k^2)$ 为第 k 个正态分布的概率密度函数; ω_k 、 μ_k 和

σ_k^2 分别为第 k 个正态分布的权重、期望和方差。本文采用三成分的高斯混合模型进行拟合，即 $n=3$ ，高斯混合模型拟合参数如表 B1 所示。




图 B2 风电功率预测误差概率密度拟合曲线

Fig.B2 Fitting curves of wind power prediction error probability density

表 B1 风电功率预测误差的三成分高斯混合模型拟合参数

Table B1 Fitting parameters of three-component Gaussian mixture model for wind power prediction error

预测功率区段	参数
[0,0.25] p.u.	$\omega_1=0.0447$ 、 $\omega_2=0.6679$ 、 $\omega_3=0.2874$
	$\mu_1=0.0525$ 、 $\mu_2=-0.0271$ 、 $\mu_3=-0.0089$
	$\sigma_1=0.1015$ 、 $\sigma_2=0.0500$ 、 $\sigma_3=0.0140$
[0.25,0.6] p.u.	$\omega_1=0.1775$ 、 $\omega_2=0.2680$ 、 $\omega_3=0.5545$
	$\mu_1=-0.1168$ 、 $\mu_2=-0.0249$ 、 $\mu_3=-0.0693$
	$\sigma_1=0.0458$ 、 $\sigma_2=0.0387$ 、 $\sigma_3=0.1158$
[0.6,1] p.u.	$\omega_1=0.2461$ 、 $\omega_2=0.6981$ 、 $\omega_3=0.0558$
	$\mu_1=-0.0873$ 、 $\mu_2=-0.0061$ 、 $\mu_3=-0.2078$
	$\sigma_1=0.0837$ 、 $\sigma_2=0.0510$ 、 $\sigma_3=0.1225$

由图 B2 可知，风电预测误差概率分布在[0, 0.25] p.u.功率区间内表现出明显的尖峰特性，在[0.25, 0.6] p.u.功率区间内具有明显的左偏特性，而在[0.6, 1] p.u.功率区间内呈现对称特性。故该方法能真实地反映风电预测误差的分布情况。在此基础上，采用蒙特卡罗模拟方法重复模拟即可生成风电出力场景集。

附录 C

1) 目标函数绝对值线性化。

针对式(21)所示的节点电压偏差目标函数，以交流侧节点电压为例，通过引入辅助变量 $X_{j,t,s}^{AC}$ 将其线性化为：

$$\begin{cases} X_{j,t,s}^{AC} = |\tilde{U}_{j,t,s}^{AC} / U_B^2 - 1| \\ \tilde{U}_{j,t,s}^{AC} / U_B^2 - 1 \leq X_{j,t,s}^{AC} \\ 1 - \tilde{U}_{j,t,s}^{AC} / U_B^2 \leq X_{j,t,s}^{AC} \end{cases} \quad \forall j \in N_e^{AC} \quad (C1)$$

2) 潮流约束。

本文采用 DistFlow 潮流模型表示交直流配电网的潮流约束，并令 $\tilde{I} = I^2$ 、 $\tilde{U} = U^2$ ，对辐射形配电网的潮流模型进行二阶锥松弛。

(1) 交流潮流约束。

$$P_{j,t,s}^{AC, inj} = \sum_{k \in \delta(j)} P_{jk,t,s}^{AC, tran} - \sum_{i \in \pi(j)} (P_{ij,t,s}^{AC, tran} - \tilde{I}_{ij,t,s}^{AC} R_{ij}^{AC}) \quad \forall ij, jk \in N_b^{AC} \quad (C2)$$

$$Q_{j,t,s}^{\text{AC,inj}} = \sum_{k \in \delta(j)} Q_{jk,t,s}^{\text{AC,tran}} - \sum_{i \in \pi(j)} (Q_{ij,t,s}^{\text{AC,tran}} - \tilde{I}_{ij,t,s}^{\text{AC}} X_{ij}^{\text{AC}}) \quad \forall ij, jk \in N_b^{\text{AC}} \quad (\text{C3})$$

$$\tilde{U}_{j,t,s}^{\text{AC}} = \tilde{U}_{i,t,s}^{\text{AC}} - 2(P_{ij,t,s}^{\text{AC,tran}} R_{ij}^{\text{AC}} + Q_{ij,t,s}^{\text{AC,tran}} X_{ij}^{\text{AC}}) + \tilde{I}_{ij,t,s}^{\text{AC}} [(R_{ij}^{\text{AC}})^2 + (X_{ij}^{\text{AC}})^2] \quad \forall ij \in N_b^{\text{AC}} \quad (\text{C4})$$

$$\left\| \begin{matrix} 2P_{ij,t,s}^{\text{AC,tran}} \\ 2Q_{ij,t,s}^{\text{AC,tran}} \\ \tilde{I}_{ij,t,s}^{\text{AC}} - \tilde{U}_{i,t,s}^{\text{AC}} \end{matrix} \right\|_2 \leq \tilde{I}_{ij,t,s}^{\text{AC}} + \tilde{U}_{i,t,s}^{\text{AC}} \quad \forall ij \in N_b^{\text{AC}} \quad (\text{C5})$$

$$\begin{cases} P_{j,t,s}^{\text{AC,inj}} = P_{j,t,s}^{\text{AC,grid}} + P_{j,t,s}^{\text{WT}} + P_{j,t}^{\text{ESS,-}} - P_{j,t}^{\text{ESS,+}} - P_{j,t,s}^{\text{AC,VSC}} - P_{j,t}^{\text{AC,load}} - P_{j,t,s}^{\text{EV}} \\ Q_{j,t,s}^{\text{AC,inj}} = Q_{j,t,s}^{\text{AC,grid}} + Q_{j,t,s}^{\text{WT}} + Q_{j,t}^{\text{SVG}} - Q_{j,t}^{\text{ESS}} - Q_{j,t,s}^{\text{AC,VSC}} - Q_{j,t}^{\text{AC,load}} \end{cases} \quad \forall j \in N_e^{\text{AC}} \quad (\text{C6})$$

式中： $\delta(j)$ 为以节点 j 为首端的支路末端节点集合； $\pi(j)$ 为以节点 j 为末端的支路首端节点集合； $P_{j,t,s}^{\text{AC,inj}}$ 、 $Q_{j,t,s}^{\text{AC,inj}}$ 分别为场景 s 下 t 时段交流配电网中节点 j 净注入的有功、无功功率； $P_{ij,t,s}^{\text{AC,tran}}$ 、 $Q_{ij,t,s}^{\text{AC,tran}}$ 分别为场景 s 下 t 时段交流配电网中支路 ij 传输的有功、无功功率； X_{ij}^{AC} 为交流支路 ij 的电抗； $P_{j,t,s}^{\text{WT}}$ 、 $Q_{j,t,s}^{\text{WT}}$ 分别为场景 s 下 t 时段节点 j 处风机的有功、无功出力； $P_{j,t}^{\text{ESS,+}}$ 、 $P_{j,t}^{\text{ESS,-}}$ 和 $Q_{j,t}^{\text{ESS}}$ 分别为 t 时段节点 j 处 ESS 的充、放电功率和无功功率； $P_{j,t,s}^{\text{AC,grid}}$ 、 $Q_{j,t,s}^{\text{AC,grid}}$ 分别为场景 s 下 t 时段上级电网向交流配电网输送的有功、无功功率； $P_{j,t,s}^{\text{AC,VSC}}$ 、 $Q_{j,t,s}^{\text{AC,VSC}}$ 分别为场景 s 下 t 时段节点 j 处换流站交流侧的有功、无功功率； $Q_{j,t}^{\text{SVG}}$ 为 t 时段节点 j 处 SVG 输出的无功功率； $P_{j,t}^{\text{AC,load}}$ 、 $Q_{j,t}^{\text{AC,load}}$ 分别为 t 时段交流配电网节点 j 处的有功、无功负荷； $P_{j,t,s}^{\text{EV}}$ 为场景 s 下 t 时段节点 j 处的 EV 充电负荷。

(2) 直流潮流约束。

直流网络中不存在无功功率和电抗，其约束条件可表示为^[8]：

$$P_{j,t,s}^{\text{DC,inj}} = \sum_{k \in \delta(j)} P_{jk,t,s}^{\text{DC,tran}} - \sum_{i \in \pi(j)} [P_{ij,t,s}^{\text{DC,tran}} - \tilde{I}_{ij,t,s}^{\text{DC}} R_{ij}^{\text{DC}}] \quad \forall ij, jk \in N_b^{\text{DC}} \quad (\text{C7})$$

$$\tilde{U}_{j,t,s}^{\text{DC}} = \tilde{U}_{i,t,s}^{\text{DC}} - 2P_{ij,t,s}^{\text{DC,tran}} R_{ij}^{\text{DC}} + \tilde{I}_{ij,t,s}^{\text{DC}} (R_{ij}^{\text{DC}})^2 \quad \forall ij \in N_b^{\text{DC}} \quad (\text{C8})$$

$$\left\| \begin{matrix} 2P_{ij,t,s}^{\text{DC,tran}} \\ \tilde{I}_{ij,t,s}^{\text{DC}} - \tilde{U}_{i,t,s}^{\text{DC}} \end{matrix} \right\|_2 \leq \tilde{I}_{ij,t,s}^{\text{DC}} + \tilde{U}_{i,t,s}^{\text{DC}} \quad \forall ij \in N_b^{\text{DC}} \quad (\text{C9})$$

$$P_{j,t,s}^{\text{DC,inj}} = P_{j,t,s}^{\text{DC,grid}} + P_{j,t,s}^{\text{WT}} + P_{j,t}^{\text{ESS,-}} - P_{j,t}^{\text{ESS,+}} - P_{j,t}^{\text{DC,load}} - P_{j,t,s}^{\text{EV}} \quad \forall j \in N_e^{\text{DC}} \quad (\text{C10})$$

式中： $P_{j,t,s}^{\text{DC,inj}}$ 、 $P_{ij,t,s}^{\text{DC,tran}}$ 分别为场景 s 下 t 时段直流配电网节点 j 净注入的有功功率、支路 ij 传输的有功功率； $P_{j,t,s}^{\text{DC,grid}}$ 为场景 s 下 t 时段交流配电网向直流配电网输送的有功功率； $P_{j,t}^{\text{DC,load}}$ 为 t 时段直流配电网节点 j 处的有功负荷。

3) ESS 约束。

交流侧 ESS 的运行约束^[3]如式 (C11) — (C13) 所示，若接入直流侧，则不包含式(C13)所示约束条件。

$$\begin{cases} 0 \leq P_{i,t}^{\text{ESS,+}} \leq P_{\max}^{\text{ESS,+}} \\ 0 \leq P_{i,t}^{\text{ESS,-}} \leq P_{\max}^{\text{ESS,-}} \end{cases} \quad \forall i \in N_{\text{ESS}} \quad (\text{C11})$$

$$\begin{cases} E_{\min}^{\text{ESS}} \leq E_{i,t}^{\text{ESS}} \leq E_{\max}^{\text{ESS}} \\ E_{i,t}^{\text{ESS}} = E_{i,t-1}^{\text{ESS}} + (\eta^+ P_{i,t}^{\text{ESS,+}} - P_{i,t}^{\text{ESS,-}} / \eta^-) \Delta t \\ E_{i,0}^{\text{ESS}} = E_{i,T}^{\text{ESS}} = 0.5 E_{\max}^{\text{ESS}} \end{cases} \quad \forall i \in N_{\text{ESS}} \quad (\text{C12})$$

$$(P_{i,t}^{\text{ESS,+}} - P_{i,t}^{\text{ESS,-}})^2 + (Q_{i,t}^{\text{ESS}})^2 \leq (S_{\max}^{\text{ESS}})^2 \quad \forall i \in N_{\text{ESS}} \quad (\text{C13})$$

式中：\$N_{\text{ESS}}\$ 为 ESS 接入配网的节点集合；\$E_{i,t}^{\text{ESS}}\$ 为 \$t\$ 时段节点 \$i\$ 处 ESS 的电量；\$P_{\text{max}}^{\text{ESS},+}\$、\$P_{\text{max}}^{\text{ESS},-}\$ 分别为 ESS 的充、放电功率上限；\$S_{\text{max}}^{\text{ESS}}\$ 为 ESS 逆变器的最大视在功率；\$E_{\text{max}}^{\text{ESS}}\$、\$E_{\text{min}}^{\text{ESS}}\$ 分别为 ESS 能量的上、下限；\$\eta^+\$、\$\eta^-\$ 分别为 ESS 的充、放电效率。

当 ESS 的充、放电效率不同为 1 时，式 (C11) — (C13) 的最优解将自动满足 ESS 充放电互补约束条件：

$$P_{i,t}^{\text{ESS},+} P_{i,t}^{\text{ESS},-} = 0 \quad (\text{C14})$$

4) 换流站运行约束。

换流站为交流配电网与直流配电网进行功率交互的枢纽，其基本结构如图 C1 所示。换流站所需满足的约束条件如式 (C15) — (C19) 所示。




图 C1 换流站的基本结构

Fig.C1 Basic structure of converter station

$$P_{i,t,s}^{\text{AC,VSC}} - P_{i,t,s}^{\text{VSC,loss}} = P_{i,t,s}^{\text{VSC,DC}} \quad \forall i \in N_{\text{VSC}} \quad (\text{C15})$$

$$P_{\min}^{\text{AC,VSC}} \leq P_{i,t,s}^{\text{AC,VSC}} \leq P_{\max}^{\text{AC,VSC}} \quad \forall i \in N_{\text{VSC}} \quad (\text{C16})$$

$$Q_{\min}^{\text{AC,VSC}} \leq Q_{i,t,s}^{\text{AC,VSC}} \leq Q_{\max}^{\text{AC,VSC}} \quad \forall i \in N_{\text{VSC}} \quad (\text{C17})$$

$$(P_{i,t,s}^{\text{AC,VSC}})^2 + (Q_{i,t,s}^{\text{AC,VSC}})^2 \leq 2 \left(\frac{P_{i,t,s}^{\text{VSC,loss}}}{\sqrt{2}c_i} \right)^2 \quad \forall i \in N_{\text{VSC}} \quad (\text{C18})$$

$$U_{i,t,s}^{\text{AC,VSC}} = \frac{\sqrt{3}}{3} \mu M_i^{\text{VSC}} U_{i,t,s}^{\text{VSC,DC}} \quad \forall i \in N_{\text{VSC}} \quad (\text{C19})$$

式中：\$P_{i,t,s}^{\text{VSC,DC}}\$ 为场景 \$s\$ 下 \$t\$ 时段第 \$i\$ 座换流站直流侧的有功功率；\$U_{i,t,s}^{\text{AC,VSC}}\$、\$U_{i,t,s}^{\text{VSC,DC}}\$ 分别为场景 \$s\$ 下 \$t\$ 时段第 \$i\$ 座换流站交流侧、直流侧电压；\$P_{\max}^{\text{AC,VSC}}\$、\$Q_{\max}^{\text{AC,VSC}}\$ 和 \$P_{\min}^{\text{AC,VSC}}\$、\$Q_{\min}^{\text{AC,VSC}}\$ 分别为换流站交流侧有功、无功功率的上限和下限；\$c_i\$ 为第 \$i\$ 座换流站工作时的损耗系数；\$\mu\$ 为变换器直流侧电压利用率，假设调制方式为空间矢量脉宽调制，则 \$\mu = \sqrt{3}/2\$；\$M_i^{\text{VSC}}\$ 为第 \$i\$ 座换流站的调制度，\$0 \leq M_i^{\text{VSC}} \leq 1\$，取其基准值 \$M_B = 2U_B^{\text{AC}}/U_B^{\text{DC}}\$，标幺化后换流站交直流侧电压关系式(C19)可改写为式 (C20)。

$$\frac{U_{i,t,s}^{\text{AC,VSC}}}{U_B^{\text{AC}}} \leq \frac{U_{i,t,s}^{\text{VSC,DC}}}{U_B^{\text{DC}}} \quad (\text{C20})$$

当 VSC 采用主从控制时，指定一个 VSC 作为主导站，该换流站采用定直流电压控制，负责维持功率平衡及直流电压稳定，其余 VSC 为从属站，采用定交流有功功率控制；当 VSC 采用下垂控制时，各 VSC 需满足如下 \$V^2 - P\$ 下垂特性方程。

$$(U_{\text{ref}}^{\text{DC}})^2 - (U_{i,t,s}^{\text{VSC,DC}})^2 = k_{p,i} (P_{i,t,s}^{\text{VSC,DC}} - P_{\text{ref}}^{\text{DC}}) \quad (\text{C21})$$

式中：\$U_{\text{ref}}^{\text{DC}}\$、\$P_{\text{ref}}^{\text{DC}}\$ 分别为直流侧电压和有功功率的参考点；\$k_{p,i}\$ 为 VSC 的有功功率下垂斜率。

附录 D

1) 多目标优化问题转化。

为了便于讨论，将 HADDN 多目标随机优化模型写成如下紧凑形式：

$$\min F = \min \{f_{\text{loss}}, f_u\} \quad (\text{D1})$$

$$\text{s.t.} \quad \begin{cases} \mathbf{h}(\mathbf{x}) = 0 \\ \mathbf{g}(\mathbf{x}) \leq 0 \end{cases} \quad (\text{D2})$$

式中： $\mathbf{x}$ 为模型的决策变量； $\mathbf{h}(\mathbf{x})$ 、 $\mathbf{g}(\mathbf{x})$ 分别为等式、不等式约束条件。

首先以式(D2)为约束条件，分别构造最小化网络损耗 f_{loss} 、节点电压偏差 f_u 的单目标优化问题，求解得到2组最优解 $[f_{\text{loss}}^{\min}, f_u^{\max}]$ 、 $[f_{\text{loss}}^{\max}, f_u^{\min}]$ 。

注意到上述考虑节点电压偏差的单目标优化问题中，目标函数不是支路电流的严格增函数^[25]，因此该模型中支路潮流的二阶锥松弛精度无法得到保证，目标值 $[f_{\text{loss}}^{\max}, f_u^{\min}]$ 可能偏离全局最优解。为此，本文在以节点电压偏差为目标的优化问题中引入改进切平面法，通过循环迭代逐步收紧二阶锥的松弛间隙。改进切平面法的详细步骤可见参考文献[25]。

考虑到目标函数之间量纲不同，按式(D3)对式(D1)的解空间进行归一化处理。

$$\{\mu_1, \mu_2\} = \left\{ \frac{f_{\text{loss}}^{\max} - f_{\text{loss}}}{f_{\text{loss}}^{\max} - f_{\text{loss}}^{\min}}, \frac{f_u^{\max} - f_u}{f_u^{\max} - f_u^{\min}} \right\} \quad (\text{D3})$$

然后引入辅助变量 ξ 来表示式(D3)所示解的最小值，其中 ξ 的大小可以衡量多目标决策的总体效果： ξ 越大，各目标的优化效果越好；反之，则越差。因此，多目标优化模型式(D1)和式(D2)可转化为最大化 ξ 的单目标优化问题，如式(D4)所示。

$$\begin{cases} \max \xi \\ \text{s.t.} \quad \begin{cases} \mu_i \geq \xi \quad i=1,2 \\ \mu_i = \frac{f_i^{\max} - f_i}{f_i^{\max} - f_i^{\min}} \quad i=1,2 \\ 0 \leq \xi \leq 1 \\ \mathbf{h}(\mathbf{x}) = 0 \\ \mathbf{g}(\mathbf{x}) \leq 0 \end{cases} \end{cases} \quad (\text{D4})$$

式中： i 表示第 i 个目标函数， $i=1$ 为网络损耗优化目标， $i=2$ 为节点电压偏差优化目标； $f_i^{\max}$ 、 $f_i^{\min}$ 分别为第 i 个目标函数 f_i 的最大值和最小值。




图 D1 交直流系统解耦示意图
Fig.D1 Decoupling diagram of AC/DC system

2) 分区解耦。

$$\left\{ \begin{array}{l} \max \xi^A + \xi^B \\ \text{s.t.} \left\{ \begin{array}{l} \frac{f_i^{\max} - (f_i^A + \hat{f}_i^B)}{f_i^{\max} - f_i^{\min}} \geq \xi^A \quad i=1,2 \\ \frac{f_i^{\max} - (\hat{f}_i^A + f_i^B)}{f_i^{\max} - f_i^{\min}} \geq \xi^B \quad i=1,2 \\ 0 \leq \xi^A \leq 1 \\ 0 \leq \xi^B \leq 1 \\ \mathbf{h}^A(\mathbf{x}^A) = 0, \quad \mathbf{g}^A(\mathbf{x}^A) \leq 0 \\ \mathbf{h}^B(\mathbf{x}^B) = 0, \quad \mathbf{g}^B(\mathbf{x}^B) \leq 0 \end{array} \right. \end{array} \right. \quad (\text{D5})$$

式中：A、B 分别表示子区域 A 和子区域 B； $\hat{f}_i^A$ 、 $\hat{f}_i^B$ 分别为子区域 B/A 中引入子区域 A/B 的虚拟目标因子； $\mathbf{x}^A$ 、 $\mathbf{x}^B$ 分别为子区域 A、B 的决策变量； $\mathbf{h}^A/\mathbf{h}^B$ 、 $\mathbf{g}^A/\mathbf{g}^B$ 分别为子区域 A、B 的等式、不等式约束。

3) 分布式优化模型。

$$\left\{ \begin{array}{l} L_A = \min \left\{ -M\xi^{A,n} + (\boldsymbol{\lambda}^{A,n})^T (\mathbf{x}_{\text{co}}^{A,n} - \bar{\mathbf{x}}_{\text{co}}^n) + \frac{\rho^A}{2} (\mathbf{x}_{\text{co}}^{A,n} - \bar{\mathbf{x}}_{\text{co}}^n)^T (\mathbf{x}_{\text{co}}^{A,n} - \bar{\mathbf{x}}_{\text{co}}^n) \right\} \\ \text{s.t.} \left\{ \begin{array}{l} \frac{f_i^{\max} - (f_i^{A,n} + \hat{f}_i^{B,n})}{f_i^{\max} - f_i^{\min}} \geq \xi^{A,n} \quad i=1,2 \\ 0 \leq \xi^{A,n} \leq 1 \\ \mathbf{h}^A(\mathbf{x}^{A,n}) = 0 \\ \mathbf{g}^A(\mathbf{x}^{A,n}) \leq 0 \end{array} \right. \end{array} \right. \quad (\text{D6})$$

$$\left\{ \begin{array}{l} L_B = \min \left\{ -M\xi^{B,n} + (\boldsymbol{\lambda}^{B,n})^T (\mathbf{x}_{\text{co}}^{B,n} - \bar{\mathbf{x}}_{\text{co}}^n) + \frac{\rho^B}{2} (\mathbf{x}_{\text{co}}^{B,n} - \bar{\mathbf{x}}_{\text{co}}^n)^T (\mathbf{x}_{\text{co}}^{B,n} - \bar{\mathbf{x}}_{\text{co}}^n) \right\} \\ \text{s.t.} \left\{ \begin{array}{l} \frac{f_i^{\max} - (\hat{f}_i^{A,n} + f_i^{B,n})}{f_i^{\max} - f_i^{\min}} \geq \xi^{B,n} \quad i=1,2 \\ 0 \leq \xi^{B,n} \leq 1 \\ \mathbf{h}^B(\mathbf{x}^{B,n}) = 0 \\ \mathbf{g}^B(\mathbf{x}^{B,n}) \leq 0 \end{array} \right. \end{array} \right. \quad (\text{D7})$$

式中：上标 n 表示当前迭代次数； M 为足够大的正数，以防止惩罚项过大而劣化目标值； L_A 、 L_B 分别为子区域 A、B 的拉格朗日函数； $\boldsymbol{\lambda}^A$ 和 $\boldsymbol{\lambda}^B$ 分别为子区域 A、B 耦合变量对应的拉格朗日乘子； ρ^A 和 ρ^B 分别为子区域 A、B 相应的惩罚系数； $\bar{\mathbf{x}}_{\text{co}}^n$ 为耦合变量的平均值，可在 $n-1$ 次迭代后按式 (D8) 进行更新。

$$\bar{\mathbf{x}}_{\text{co}}^n = \frac{1}{2} (\mathbf{x}_{\text{co}}^{A,n-1} + \mathbf{x}_{\text{co}}^{B,n-1}) \quad (\text{D8})$$

附录 E

所提基于 ADMM 的分布式调度求解步骤如下。

步骤 1: 设置迭代次数 $n=1$; 初始化耦合变量平均值 $\bar{x}_{co}^n$, 拉格朗日乘子 λ^A 、 λ^B , 以及惩罚参数 ρ^A 和 ρ^B ; 设置残差收敛裕度 ε 。

步骤 2: 子区域 A、B 并行求解本地问题得到耦合变量 $x_{co}^{A,n+1}$ 和 $x_{co}^{B,n+1}$, 根据式(D8)更新其平均值。

步骤 3: 计算式(E1)所示优化问题的原始残差 M 和对偶残差 D , 并检查两者是否满足式(E2)的收敛条件: 若满足, 则停止迭代, 输出最终结果; 否则, 转至步骤 4。

$$\begin{cases} M^n = \max \left\{ \left| x_{co}^{A,n+1} - \bar{x}_{co}^{n+1} \right|, \left| x_{co}^{B,n+1} - \bar{x}_{co}^{n+1} \right| \right\} \\ D^n = \max \left\{ \left| \bar{x}_{co}^{n+1} - \bar{x}_{co}^n \right| \right\} \end{cases} \quad (E1)$$

$$\max \{M^n, D^n\} \leq \varepsilon \quad (E2)$$

步骤 4: 根据式(E3)更新优化问题的拉格朗日乘子, 设置迭代次数 $n = n + 1$ 并跳转至步骤 2。

$$\begin{cases} \lambda^{A,n+1} = \lambda^{A,n} + \rho^A (x_{co}^{A,n+1} - \bar{x}_{co}^{n+1}) \\ \lambda^{B,n+1} = \lambda^{B,n} + \rho^B (x_{co}^{B,n+1} - \bar{x}_{co}^{n+1}) \end{cases} \quad (E3)$$

附录 F





图 F1 电气-交通拓扑结构图

Fig.F1 Electric-traffic topology diagram




图 F2 交、直流配电网的有功负荷
Fig.F2 Active load of AC and DC distribution network

表 F1 设备接入点

Table F1 Device access point

电网	风机接入节点	ESS 接入节点	SVG 接入节点	充电站接入节点
交流配电网	13, 25	8, 23	21, 31	10, 24
直流配电网	4, 11	3, 6	—	7, 14

表 F2 ESS 参数

Table F2 Parameters of ESS

接入点	充电功率 上限/MW	放电功率 上限/MW	最大存储 电量/(MW·h)	最小存储 电量/(MW·h)	最大视在功率/ (MV·A)	充电效率	放电效率
交流侧节点 8、23	2	2	14	3	4	0.98	0.97
直流侧节点 3、6	3	3	18	3	—	0.98	0.97

表 F3 SVG 参数

Table F3 SVG parameters

接入点	无功功率上限/Mvar	无功功率下限/Mvar
交流侧节点 21、31	0.8	0

表 F4 出行链概率

Table F4 Trip chain probability


出行链	H-W-H	H-B-H	H-B-W-H	H-W-B-H
概率	0.22	0.16	0.3	0.32

表 F5 EV 每公里耗电量


Table F5 EV power consumption per km

时段	耗电量/(kW·h·km ⁻¹)
早高峰(07:00—09:00)	0.26
中午(12:00—14:00)	0.32
晚高峰(17:00—19:00)	0.28
其他时段	0.35

附录 G



(a)电动汽车行程轨迹



(b)电动汽车SOC

图 G1 EV 的时空转移特性

Fig.G1 Temporal and spatial transfer characteristics of EVs




图 G2 充电负荷时空分布

Fig.G2 Temporal and spatial distribution of charging load

表 G1 场景缩减结果对比

Table G1 Comparison of scenario reduction results

场景缩减方法	300 组初始场景(典型场景数 $K=3$)		500 组初始场景(典型场景数 $K=5$)	
	指标值	计算时间/s	指标值	计算时间/s
本文方法	3.9461	8.231	3.8778	28.696
同步回代消减法	4.3003	10.047	4.1944	40.801

3 种模式下配电网的节点电压分布情况如图 G3 所示, 图中节点编号 1—33 分别表示交流配电网中的节点 1—33, 编号 34—48 分别表示直流配电网中的节点 1—15。




图 G3 3 种模式下节点电压分布
Fig.G3 Node voltage distribution under three modes




图 G4 ESS 有功、无功功率（交流节点 23）
Fig.G4 Active and reactive power of ESS(AC Node 23)




图 G5 交流节点 10 电压、ESS 有功/无功功率曲线
Fig.G5 Voltage of AC Node 10 and active and reactive power curves of ESS




图 G6 残差迭代过程
Fig.G6 Iterative process of residuals

各支路二阶锥松弛误差散点图如图 G7 所示，其中支路编号 1—32 为交流配电网支路索引，编号 33—46 为直流配电网支路索引。




图 G7 各支路的二阶锥松弛误差

Fig.G7 Second order cone relaxation error of each branch