

DOI: 10.19783/j.cnki.pspc.231538

基于 LSTM-CGAN 的多微网数据驱动分布鲁棒 协同优化运行策略

李虹, 韩雨萌

(新能源电力系统国家重点实验室(华北电力大学), 河北 保定 071003)

摘要: 新能源的强烈不确定性给多微网协同运行带来了可靠性和安全性的巨大挑战。为此, 提出一种基于长短期记忆(long short-term memory, LSTM)网络和条件生成对抗网络(conditional generative adversarial networks, CGAN)的多微网数据驱动两阶段分布鲁棒协同优化调度模型。首先, 为更准确地描述新能源的不确定性, 该模型以 LSTM-CGAN 生成和 K-means++ 聚类算法削减得到的场景集作为分布鲁棒优化集合的初始新能源场景。其中 CGAN 网络模型使用 Wasserstein 距离作为判别器损失函数, 以新能源日前预测值作为生成对抗网络的条件变量, 并采用 LSTM 构建生成器和判别器。其次, 提出一种基于多能点对点交易贡献率的利益分配方法, 以实现合作收益的公平分配。然后, 为保护各主体隐私并提高求解效率, 提出一种耦合可并行计算列与约束生成(column and constraint generation, C&CG)的交替方向乘子法(alternating direction multiplier method, ADMM)进行求解能量交易问题。算例结果表明, 所提场景驱动方法生成的场景集能更准确、更有效地描述新能源的不确定性, 能兼顾系统的鲁棒性、经济性和隐私性, 并实现每个主体公平合理的利益分配。

关键词: 多微网; 分布鲁棒优化; 合作收益; 长短期记忆网络; 条件生成对抗网络

Data-driven distributionally robust collaborative optimization operation strategy for a multi-microgrid based on LSTM-CGAN

LI Hong, HAN Yumeng

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Baoding 071003, China)

Abstract: The high uncertainty of renewable energy poses significant challenges to the reliable and secure operation of multi-microgrids. To address this, a two-stage distributed robust coordination optimization model driven by data is proposed based on long short-term memory (LSTM) networks and conditional generative adversarial networks (CGAN). First, to accurately characterize the uncertainty of renewable energy, the model generates an initial set of renewable energy scenarios for the distributionally robust optimization (DRO) set using LSTM-CGAN and the K-means++ clustering algorithm. The CGAN model uses Wasserstein distance as the discriminator loss function, with the day-ahead renewable energy forecast as the conditional variable for the generative adversarial network, and employs LSTM to construct the generator and discriminator. Secondly, a benefit allocation method based on the contribution rate of multi-node energy trading is proposed to achieve fair distribution of cooperative benefits. In addition, to protect the privacy of individual entities and improve solution efficiency, an alternating direction multiplier method (ADMM) is proposed. This couples parallel computation of columns and constraint generation (C&CG) to solve the energy trading problem. Case study results demonstrate that the proposed approach, with the scenario-driven method for generating scenario sets, can accurately and effectively describe the uncertainty of renewable energy, while considering system robustness, economic efficiency, and privacy, and achieving fair and reasonable benefit allocation for each entity.

This work is supported by the National Natural Science Foundation of China (No. 51607068).

Key words: multi-microgrid; distributionally robust optimization; cooperative benefits; long short-term memory network; conditional generative adversarial networks

基金项目: 国家自然科学基金项目资助(51607068)

0 引言

微电网(microgrid, MG)作为一种微型电力系统,是应对能源危机和实现双碳目标的重要手段^[1]。然而,单个微电网的工作能力非常有限,并且受运行环境变化的影响,其抗干扰能力并不理想^[2]。随着微电网技术的不断发展,两个或多个单独的微电网可以通过公共耦合点连接起来构成多微电网系统(multi-microgrid, MMG),这些相邻的微电网可以进行点对点(peer-to-peer, P2P)能量交互。这种系统能够实现微网之间的智能协调和灵活的能源交易,有效解决更大范围内新能源的消纳和利用问题,降低社会成本^[2-3]。然而随着可再生能源渗透率的不断增长,其固有的不确定因素对 MMG 的稳定协同运行产生了巨大影响^[4]。

目前,随机优化^[5]和鲁棒优化^[6]是处理 MMG 不确定性的两种主要方法。随机优化通常需要获得准确的不确定性概率密度函数,然后对有限场景集进行采样。并且,过少的场景造成过于乐观的决策,而随着场景规模的增大,随机优化的计算时间迅速增加,求解效率低^[7]。此外,不确定性的真实分布往往难以精确获取,这反过来又降低了为优化调度而生成的场景的可靠性。因此,随机优化的局限性阻碍了其更广泛的使用。鲁棒优化不需要不确定参数的概率信息,而是利用不确定性集来描述不确定参数的波动区间,但由于过于强调最坏情况,往往导致过于保守的解决方案^[8]。相比之下,近年来新兴的分布鲁棒优化(distributionally robust optimization, DRO)结合了这两种方法的特点,具有更好的性能。该方法不需要设置概率分布的类型和参数;它以数据驱动的方式构造概率分布模糊集,并针对最差的概率分布进行决策。基于概率距离或矩信息构造模糊集是 DRO 中的两种常见手段。文献[9]基于 Wasserstein 距离建立风光发电的概率分布模糊集,用于解决可再生能源参与的输配电网最优潮流问题。文献[10]在配电网运营商与聚合了电动汽车的多个充电站之间构建了以多主体 Wasserstein 分布鲁棒互动博弈模型。文献[11]基于矩信息建立可再生能源概率分布模糊集,实现了电力能源系统安全要求下的经济调度。文献[12]构建基于 Wasserstein 距离的移动氢能系统分布鲁棒模型,以处理加氢站氢气需求的不确定性。然而,上述文献所构造的概率分布模糊集一般是通过偏转线性决策规则和对偶定理构造凸优化模型来求解,且 0-1 变量的引入也会增加模型转换和求解的难度,相应的 NP-hard 问题也很复杂。另外一种基于数据驱动的 DRO 方法因

其可以采用并行求解的方法进行处理,有效避免了推导对偶形式以及引入 0-1 变量造成的求解效率低的问题^[13]。该方法利用历史数据样本生成并计算典型场景的初始概率分布,并以 1-范数和 ∞ -范数作为综合范数约束其概率分布模糊集,然后制定不确定因素在最恶劣概率分布下的最优决策^[14-15]。

目前,针对风光等可再生能源场景生成的方法主要基于统计学习,涵盖了蒙特卡罗抽样法^[16]、概率密度法^[17]、马尔可夫链法^[18]、时间序列法^[19]和场景树生成法^[20]等多种方法。这些传统的统计学模型首先依据可再生能源出力的历史数据确定相应的参数,然后使用特定的抽样方法生成初始场景集。然而,这些方法未能充分考虑新能源发电序列的时空相关性及其他未知信息。因此,在复杂的实际应用环境中,基于统计学模型的场景生成方法缺乏广泛的适用性。

近年来,人工智能技术已经开始在可再生能源场景生成中发挥越来越重要的作用。与传统方法相比,基于深度学习的场景生成方法展现出更强的泛化能力和数据表达能力。这种方法有利于进行无监督学习和自主学习,能够更准确地反映随机变量的时空特征,从而提高系统管理未来不确定性的能力。在最新的研究中,学者们应用生成对抗网络(generative adversarial networks, GAN)来生成符合概率分布的可再生能源功率曲线,以及在不同条件下的可再生能源功率曲线^[21]。同时,一种基于条件生成对抗网络(conditional generative adversarial networks, CGAN)的可再生能源日前场景生成方法也被提出,通过对 CGAN 模型进行博弈训练,使其学会学习预测曲线与实际曲线之间的映射关系,相较于传统的马尔可夫链场景生成方法,能够更精确地描述风电不确定性^[22]。此外,针对电力系统运行规划中不同条件下的场景,还提出了一种基于 Wasserstein 距离的 CGAN 模型,用于风电功率极端场景的生成,相较于传统的基于 Wasserstein 距离的 GAN 生成的场景集质量更佳^[23]。

另一方面,随着电力市场的发展,MMG 中各微网隶属于不同的利益主体,建立合适的利益分配机制以促进多微网可持续的协同优化运行至关重要。合作博弈被认为是解决利益分配问题的有效手段。文献[24]提出了工业园区综合能源系统中各参与主体独立运营与合作运营模式,采用 Shapley 值法分配合作收益。但 Shapley 方法只考虑了边际贡献进行利益分配,无法保证全局利益最大化。纳什议价考虑了合作参与者之间的利益、策略和信息等问题,在处理参与者之间的非独立性和交互性方面

优于 Shapley 值方法, 近年来得到广泛关注^[25-26]。为克服传统纳什议价均等分配的弊端, 通过赋予不同的议价能力, 采用非对称的分配策略也受到了关注^[27-29]。然而, 上述文献的利益分配过程未考虑除电能外的其他能源交易贡献。

基于以上研究, 本文提出了一种基于长短期记忆(long short-term memory, LSTM)网络和 CGAN 的多微网数据驱动两阶段分布鲁棒协同优化调度模型。与现有研究相比, 本研究的主要创新点和贡献如下:

1) 为更准确地描述新能源的随机特性, 提出一种基于 LSTM-CGAN 的场景生成方法, 用于生成 DRO 集合的初始新能源场景。该方法首先利用核密度估计法拟合新能源预测误差, 然后采样生成符合新能源预测误差分布的随机噪声, 用于训练 CGAN 模型。该 CGAN 模型使用 Wasserstein 距离作为判别器损失函数, 以优化训练过程中梯度消失和模式崩溃的问题。同时, 以新能源功率日前预测值作为 CGAN 的条件变量, 使 CGAN 能够学习满足条件的噪声分布与真实数据训练集之间的映射关系。此外, 采用 LSTM 网络构建 CGAN 的生成器, 以更好地学习新能源出力序列的时序特征。通过 LSTM-CGAN 构造的 DRO 模型相较于传统两阶段 DRO 方法, 进一步降低了保守性。

2) 根据各微网不同的贡献率, 提出一种基于 P2P 电热多能交易贡献率的非对称纳什议价机制来分配各微网的合作收益, 确保了合作盈余分配的公平合理性。

3) 为提高模型求解效率并有效保护各主体隐私, 提出一种耦合可并行计算列与约束生成(column and constraint generation, C&CG)的交替方向乘子法(alternating direction method of multiplier, ADMM)分布式求解能源交易问题。

1 多微网系统框架

图 1 为本研究提出的多微网运行模型框架。MG 与上级能源网直接相连, 可以根据上级能源网指定价格进行购能, 也可以根据合作联盟形式在微网之间进行 P2P 交易。微网运营商会根据自身供给需求, 通过议价来交换电能和热能, 减小对上级能源网的依赖, 以降低自身的运行成本。同时, 合作的微网运营商通过租赁云储能(cloud energy storage, CES)来降低在微网内部建设储能系统的高额投资成本, 促进可在生能源的消纳。此外, 各微电网配备了能量管理系统(energy management system, EMS), 微网之间采用先进的 5G 通信技术, 以实现实时能源交互和价格

传输, 保证高效率的同时兼顾 MG 隐私保护要求^[27]。

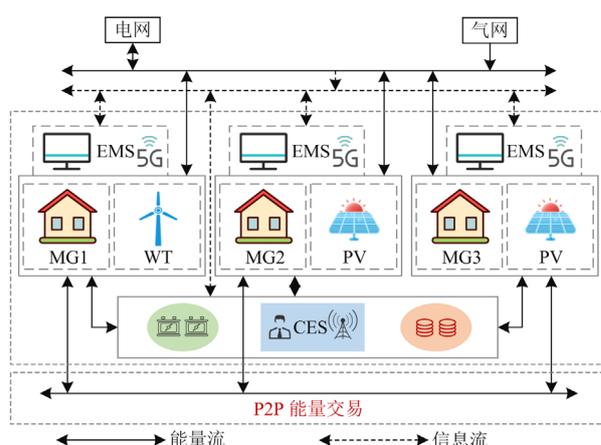


图 1 多微网运行模型框架

Fig. 1 Multi-microgrid running model framework

图 2 为微网的内部系统模型, 微网根据自身的地理位置等条件选择适当的分布式发电能源。为更好地实现多能利用, 加入燃气轮机、热泵、吸收式制冷机和电制冷机等能源耦合设备。引入碳捕集和电转气设备来降低 CO_2 的排放, 同时考虑柔性负荷, 进一步实现新能源的消纳并提高用户参与的积极性。

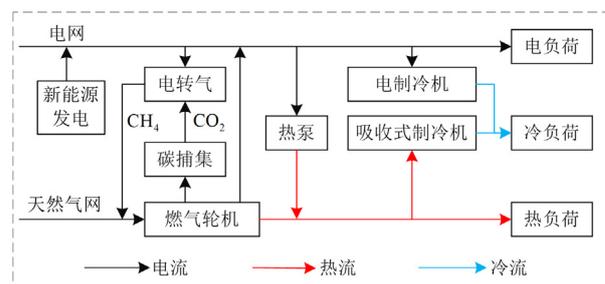


图 2 微网的内部系统模型

Fig. 2 Internal system model of a microgrid

2 风光场景生成与削减

2.1 基于 Wasserstein 距离的 CGAN

GAN 是一种基于博弈论的无监督生成式模型^[30]。它通过生成器网络(generator network, GN)和判别器网络(discriminator network, DN)之间相互对抗博弈逐渐生成与真实样本相似的数据样本。而 CGAN 将监督学习与半监督学习结合, 允许在生成样本的过程中将附加信息作为生成器的输入, 指导样本的生成过程, 其基本架构如图 3 所示。生成器利用映射随机噪声的方式生成接近真实分布的数据, 而判别器则用来判断样本是否为真实数据。经过训练, 生成器可以欺骗判别器, 使其无法分辨生成的数据是否真实。在生成器的训练过程中, 数据被映射到高

维空间进行迭代, 最终使得生成器和判别器达到纳什均衡状态。

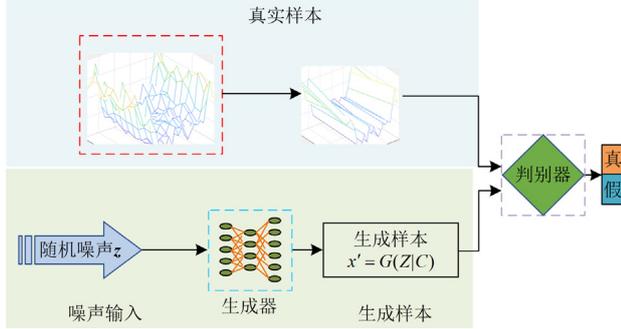


图 3 条件生成对抗网络的结构

Fig. 3 Structure of CGAN

生成器通过学习真实数据 \mathbf{x} 的潜在分布, 负责对噪声向量 \mathbf{z} 进行处理, 生成服从概率分布 P_z 的数据样本 $G(\mathbf{z})$; 判别器的输入是 GN 生成的数据和真实数据 \mathbf{x} 。生成器 G 的目的是生成和真实数据一样分布的样本, 以最大限度地减少对判别器的干扰。判别器 D 用来区分生成的样本 $G(\mathbf{z})$ 和真实数据 \mathbf{x} , 两者都可以通过迭代对抗训练不断提高自己的性能, 直到判别器 D 不再能够区分真实数据 \mathbf{x} 和生成的样本 $G(\mathbf{z})$ 。生成器 G 的损失函数 L_G 和判别器 D 的损失函数 L_D 可以定义为

$$L_G = -E_{z \sim P_z}[D(G(\mathbf{z}))] \quad (1)$$

$$L_D = E_{z \sim P_z}[D(G(\mathbf{z}))] - E_{x \sim P_d}[D(\mathbf{x})] \quad (2)$$

式中: $E(\cdot)$ 为期望函数; $G(\cdot)$ 为发生器函数; $D(\cdot)$ 为判别器函数; P_d 与 P_z 分别为真实数据和噪声的概率分布。 L_G 的值越小, 表示生成器生成的样本越接近实际数据, 判别器区分数据真实性的能力越强。

由于 CGAN 容易出现模式崩溃和梯度消失问题, 因此使用 Wasserstein 距离来代替 CGAN 中的 JS 散度, 其目标函数 $V(G, D)$ 表示为

$$\min_G \max_D V(G, D) = E_{x \sim P_d}[D(\mathbf{x})] - E_{z \sim P_z}[D(G(\mathbf{z}))] \quad (3)$$

通过对 CGAN 鉴别器的梯度范数进行惩罚, 解决了 CGAN 不能在 1-Lipschitz 约束下约束判别器的问题。带梯度惩罚项的 CGAN 整体训练的目标函数表示为^[25]

$$\min_G \max_D V(G, D) = E_{x \sim P_d}[D(\mathbf{x})] - E_{z \sim P_z}[D(G(\mathbf{z}))] + \rho E_{\hat{x} \sim P_{\hat{x}}}[\|\nabla \hat{x} D(\hat{x})\|_2 - 1] \quad (4)$$

式中: $\hat{x} = \varepsilon \mathbf{x} + (1 - \varepsilon)G(\mathbf{z})$, $\varepsilon \sim U[0, 1]$; $\|\cdot\|_2$ 表示 2-范数; ρ 为梯度惩罚系数。

2.2 基于 LSTM-CGAN 的场景生成

LSTM 网络是一种特殊类型的循环神经网络

(recursive neural network, RNN), 它在处理和预测时间序列数据或者其他连续数据时表现出色。与标准的 RNN 相比, LSTM 网络能够更有效地解决长期依赖问题, 因为它引入了称为“门”的结构, 这些门可以选择性地让信息通过网络, 从而控制数据的流动。LSTM 网络内部有三种门控单元: 遗忘门、输入门和输出门, 它们协同工作以控制信息的流动和保存长期记忆。通过这种方式, LSTM 网络在分析和学习时间序列数据时能够有效地捕捉长期依赖关系, 因此被广泛应用于语音识别、文本生成、机器翻译等领域。LSTM-CGAN^[31]是一种具有长短期记忆结构的条件生成对抗网络模型, 它的网络结构通常具有以下 4 个组成部分。

1) 生成器: 这部分通常采用 LSTM 网络, 类似于标准的生成器, 但是在这里还会接收额外的条件信息, 例如类别标签或其他辅助信息。条件生成器的目标是生成具有所需特征的数据样本。

2) 判别器: 判别器部分通常采用传统的卷积神经网络或者多层感知器结构, 用来评估输入数据的真实性。与常规的 GAN 不同, 它还会接收并考虑条件信息, 以帮助进行条件化的判别。

3) LSTM 结构: LSTM 结构被用于生成器中, 以处理序列数据的生成, 同时也可能被用于处理输入序列的时间相关性。

4) CGAN 结构: 整个模型遵循条件生成对抗网络的框架, 因此生成器和判别器在训练过程中都会受到条件信息的影响。

基于 LSTM-CGAN 的风光场景生成模型通过学习风光功率数据的时序特征和误差分布, 生成符合实际情况的风光场景。具体而言, 该模型首先利用 LSTM 网络学习风光功率数据的时序特征, 然后结合核密度估计法对风电预测误差进行拟合, 并采样生成符合误差分布的随机噪声。这些噪声数据被用于训练 CGAN 模型, 其中判别器损失函数采用 Wasserstein 距离, 以解决训练过程中可能出现的梯度消失和模式崩溃问题。同时, 将风光功率日前预测值作为条件变量输入到 CGAN 中, 使得模型能够学习条件噪声分布与实际数据之间的映射关系。整个模型的设计旨在更准确地描述风光的随机性和不确定性, 为风光场景生成提供了一种有效的方法。

2.3 基于 K-means⁺⁺的场景削减

相对于 K-means 算法, K-means⁺⁺聚类算法在选取初始聚类中心方面进行优化, 在电力系统场景聚类过程中更加简单高效。本文采用 K-means⁺⁺算法^[32]对 CGAN 生成的大量场景进行聚类。通过 Davies

Bouldin 指数 $D(i)$ 和廓形系数 $s(k)$ 两个典型内部效率指标进行定量分析, 分别表示为

$$D(i) = \frac{1}{N_s} \sum_{s=1}^{N_s} \max \left[\frac{S_i + S_j}{d(C_i + C_j)} \right] \quad (5)$$

$$s(k) = \frac{b(k) - a(k)}{\max \{a(k), b(k)\}} \quad (6)$$

式中: N_s 为簇的个数; C_i 、 C_j 分别为第 i 个和第 j 个簇的中心; S_i 、 S_j 分别为簇 i 、 j 中所有样本到簇中心 C_i 、 C_j 的平均距离; $d(C_i + C_j)$ 为簇中心 C_i 与 C_j 之间的距离; $a(k)$ 为第 k 个样本与集群内所有样本之间的平均距离; $b(k)$ 为第 k 个样本与集群外其他样本之间的平均距离。

3 多微网的系统模型

3.1 微网内部设备模型

1) 燃气轮机通过燃烧天然气产生电能和热能^[26], 其出力模型和约束为

$$P_{i,e,t}^{GT} = \eta_{GT,e} H_{GHV} G_{i,t}^{GT} \quad (7)$$

$$P_{i,h,t}^{GT} = \eta_{GT,h} H_{GHV} G_{i,t}^{GT} \quad (8)$$

$$0 \leq P_{i,e,t}^{GT} \leq P_{i,e,max}^{GT} \quad (9)$$

$$0 \leq P_{i,h,t}^{GT} \leq P_{i,h,max}^{GT} \quad (10)$$

式中: $P_{i,e,t}^{GT}$ 、 $P_{i,h,t}^{GT}$ 分别为燃气轮机的发电功率和产热功率; $\eta_{GT,e}$ 、 $\eta_{GT,h}$ 分别为燃气轮机的发电效率和产热效率; $G_{i,t}^{GT}$ 为燃气轮机的天然气消耗量; H_{GHV} 为天然气热值; $P_{i,e,max}^{GT}$ 、 $P_{i,h,max}^{GT}$ 分别为燃气轮机的最大发电功率和最大产热功率。

2) 热泵作为利用低品位热能的高效装置, 是 MG 中重要的低碳节能设备。热泵通过电能驱动, 其制热功率 $P_{i,h,t}^{HP}$ 与耗电量 $P_{i,e,t}^{HP}$ 关系为^[26]

$$P_{i,h,t}^{HP} = \eta_{HP} P_{i,e,t}^{HP} \quad (11)$$

$$0 \leq P_{i,h,t}^{HP} \leq P_{i,h,max}^{HP} \quad (12)$$

式中: η_{HP} 为热泵制热效率; $P_{i,h,max}^{HP}$ 为热泵的最大制热功率。

3) 吸收式制冷机利用多余的热量实现以热制冷; 电制冷机则是利用电能制冷。其制冷功率和约束为

$$P_{i,c,t}^{AC} = \eta_{AC} P_{i,h,t}^{AC} \quad (13)$$

$$0 \leq P_{i,c,t}^{AC} \leq P_{i,c,max}^{AC} \quad (14)$$

$$P_{i,c,t}^{EC} = \eta_{EC} P_{i,e,t}^{EC} \quad (15)$$

$$0 \leq P_{i,c,t}^{EC} \leq P_{i,c,max}^{EC} \quad (16)$$

式中: $P_{i,c,t}^{AC}$ 、 $P_{i,c,t}^{EC}$ 分别为吸收式制冷机的制冷功

率和最大制冷功率; η_{AC} 为吸收式制冷机的制冷效率; $P_{i,c,t}^{EC}$ 、 $P_{i,c,max}^{EC}$ 分别为电制冷机的制冷功率和最大制冷功率; η_{EC} 为电制冷机的制冷效率。

4) 碳捕集与电转气耦合设备吸收 CO_2 制成 CH_4 , 既降低了微网的碳排放量, 又可以实现能源再生^[29]。其运行模型为

$$Q_{i,g,t}^{P2G} = \eta_{P2G} P_{i,e,t}^{P2G} \quad (17)$$

$$Q_{i,g,t}^{CCS} = \eta_{CC} P_{i,e,t}^{P2G} \quad (18)$$

$$P_{i,e,t}^{CCS} = \eta_{CCS} Q_{i,g,t}^{CCS} \quad (19)$$

$$0 \leq P_{i,e,t}^{P2G} \leq P_{i,e,max}^{P2G} \quad (20)$$

$$0 \leq P_{i,e,t}^{CCS} \leq P_{i,e,max}^{CCS} \quad (21)$$

式中: $Q_{i,g,t}^{P2G}$ 为 P2G 设备产生的 CH_4 体积; η_{P2G} 为电转气设备消耗电能产生 CH_4 的转换效率; $P_{i,e,t}^{P2G}$ 为电转气设备的耗电功率; $Q_{i,g,t}^{CCS}$ 为电转气设备合成 CH_4 需要的 CO_2 量; η_{CC} 为计算 CO_2 量的转换系数; $P_{i,e,t}^{CCS}$ 为 CCS 的耗电功率; η_{CCS} 为 CCS 捕捉 CO_2 消耗电能的转换系数; $P_{i,e,max}^{P2G}$ 为 P2G 设备耗电功率上限; $P_{i,e,max}^{CCS}$ 为 CCS 设备耗电功率上限。

3.2 云储能设备

为降低储能的投资成本和使用成本, 云储能模式成为微网运营商的一种选择^[32]。CES 服务商根据单位容量为 CES 服务提供定价。各微网运营商根据自身的储能需求, 向 CES 服务商购买相应容量电、热的云储能设备使用权。云储能服务商和微网之间通过通信系统交换信息和费用, 通过电网和热网进行能源交互。各微网的实时储电容量 $S_{i,e,t}$ 和实时储热容量 $S_{i,h,t}$ 用矩阵形式表示为

$$\begin{bmatrix} S_{i,e,t} \\ S_{i,h,t} \end{bmatrix} = \begin{bmatrix} S_{i,e,t-1} (1 - \delta_e) \\ S_{i,h,t-1} (1 - \delta_h) \end{bmatrix} + \begin{bmatrix} \eta_e^{ch} & -1 \\ \eta_h^{ch} & -1 \end{bmatrix} \begin{bmatrix} P_{i,e,t}^{ch} \theta_{i,e,t}^{ch} & P_{i,e,t}^{dis} \theta_{i,e,t}^{dis} \\ P_{i,h,t}^{ch} \theta_{i,h,t}^{ch} & P_{i,h,t}^{dis} \theta_{i,h,t}^{dis} \end{bmatrix}^T \quad (22)$$

MG 的云储能实时容量约束表示为

$$\begin{cases} \alpha_{i,e}^{\min} S_{i,e}^{\max} \leq S_{i,e,t} \leq \alpha_{i,e}^{\max} S_{i,e}^{\max} \\ \alpha_{i,h}^{\min} S_{i,h}^{\max} \leq S_{i,h,t} \leq \alpha_{i,h}^{\max} S_{i,h}^{\max} \end{cases} \quad (23)$$

MG 租用的云储电容 $S_{i,e}^{\max}$ 和云储热容量 $S_{i,h}^{\max}$ 约束为

$$\begin{cases} 0 \leq S_{i,e}^{\max} \leq S_{e,rent}^{\max} \\ 0 \leq S_{i,h}^{\max} \leq S_{h,rent}^{\max} \end{cases} \quad (24)$$

为了保证下一个周期储能系统的正常运行,应保持储能初始状态与调度周期结束时储能状态的连续性,即

$$\begin{cases} S_{i,e,0} = S_{i,e,T} \\ S_{i,h,0} = S_{i,h,T} \end{cases} \quad (25)$$

为防止 CES 的同时充能放能,约束为

$$\begin{cases} 0 \leq \theta_{i,e,t}^{\text{dis}} + \theta_{i,e,t}^{\text{ch}} \leq 1 \\ 0 \leq \theta_{i,h,t}^{\text{dis}} + \theta_{i,h,t}^{\text{ch}} \leq 1 \end{cases} \quad (26)$$

MG 租用的 CES 充放电功率 $P_{i,e,t}^{\text{max}}$ 和充放热功率

$P_{i,h,t}^{\text{max}}$ 约束为

$$\begin{cases} 0 \leq P_{i,e,t}^{\text{max}} \leq P_{e,\text{rent}}^{\text{max}} \\ 0 \leq P_{i,h,t}^{\text{max}} \leq P_{h,\text{rent}}^{\text{max}} \end{cases} \quad (27)$$

MG 的实时充放能功率约束表示为

$$\begin{cases} 0 \leq P_{i,e,t}^{\text{ch}} \leq P_{i,e,t}^{\text{max}} \\ 0 \leq P_{i,h,t}^{\text{ch}} \leq P_{i,h,t}^{\text{max}} \end{cases} \quad (28)$$

$$\begin{cases} 0 \leq P_{i,e,t}^{\text{dis}} \leq P_{i,e,t}^{\text{max}} \\ 0 \leq P_{i,h,t}^{\text{dis}} \leq P_{i,h,t}^{\text{max}} \end{cases} \quad (29)$$

式中: δ_e 、 δ_h 分别为云储电和云储热的自损耗系数; η_e^{ch} 、 η_h^{ch} 分别为充电和充热的效率; η_e^{dis} 、 η_h^{dis} 分别为放电和放热的效率; $P_{i,e,t}^{\text{ch}}$ 、 $P_{i,h,t}^{\text{ch}}$ 分别为实时充电功率和充热功率; $P_{i,e,t}^{\text{dis}}$ 、 $P_{i,h,t}^{\text{dis}}$ 分别为实时放电功率和放热功率; $\theta_{i,e,t}^{\text{ch}}$ 、 $\theta_{i,e,t}^{\text{dis}}$ 分别为充、放电的状态变量; $\theta_{i,h,t}^{\text{ch}}$ 、 $\theta_{i,h,t}^{\text{dis}}$ 分别为充、放热的状态变量; $\alpha_{i,e}^{\text{max}}$ 、 $\alpha_{i,e}^{\text{min}}$ 分别为 CES 荷电状态占比系数上下限; $\alpha_{i,h}^{\text{max}}$ 、 $\alpha_{i,h}^{\text{min}}$ 分别为 CES 荷热状态占比系数上下限; $S_{e,\text{rent}}^{\text{max}}$ 、 $S_{h,\text{rent}}^{\text{max}}$ 分别为 MG 可租用的最大云储电容量和最大云储热容量; $P_{e,\text{rent}}^{\text{max}}$ 、 $P_{h,\text{rent}}^{\text{max}}$ 分别为 MG 租用的 CES 最大充放电功率和最大充放热功率。

3.3 负荷模型

微网中的柔性负荷包括可削减和可转移负荷,其约束为

$$P_{i,e,t}^{\text{load}} = P_{i,e,t}^{\text{load0}} - P_{i,e,t}^{\text{cut}} + P_{i,e,t}^{\text{tran}} \quad (30)$$

$$P_{i,h,t}^{\text{load}} = P_{i,h,t}^{\text{load0}} - P_{i,h,t}^{\text{cut}} \quad (31)$$

$$\sum_{t=1}^T P_{i,e,t}^{\text{tran}} = 0 \quad (32)$$

$$0 \leq P_{i,e,t}^{\text{cut}} \leq \alpha_e^{\text{cut}} P_{i,e,t}^{\text{load0}} \quad (33)$$

$$-\alpha_e^{\text{tran}} P_{i,e,t}^{\text{load0}} \leq P_{i,e,t}^{\text{tran}} \leq \alpha_e^{\text{tran}} P_{i,e,t}^{\text{load0}} \quad (34)$$

$$0 \leq P_{i,h,t}^{\text{cut}} \leq \alpha_h^{\text{cut}} P_{i,h,t}^{\text{load0}} \quad (35)$$

式中: $P_{i,e,t}^{\text{load}}$ 、 $P_{i,h,t}^{\text{load}}$ 分别为实际电、热负荷; $P_{i,e,t}^{\text{load0}}$ 、 $P_{i,h,t}^{\text{load0}}$ 分别为基本电、热负荷; $P_{i,e,t}^{\text{cut}}$ 、 $P_{i,h,t}^{\text{cut}}$ 分别为可削减电、热负荷; $P_{i,e,t}^{\text{tran}}$ 为可转移电负荷; T 表示一个时间周期; α_e^{cut} 、 α_h^{cut} 分别表示可削减电、热负荷的占比系数; α_e^{tran} 为可转移电负荷占比系数。

3.4 成本模型

微网与外电网的交互成本 C_i^{grid} 表示为

$$C_i^{\text{grid}} = \sum_{t=1}^T (\lambda_b P_{i,t}^{\text{buy}} - \lambda_s P_{i,t}^{\text{sell}}) \quad (36)$$

微网的购气成本 C_i^{fuel} 表示为

$$C_i^{\text{fuel}} = \lambda_{\text{gas}} \sum_{t=1}^T (G_{i,t}^{\text{GT}} - Q_{i,g,t}^{\text{P2G}}) \quad (37)$$

需求响应成本 C_i^{dr} 表示为

$$C_i^{\text{dr}} = \lambda_{e,\text{tran}} \sum_{t=1}^T |P_{i,e,t}^{\text{tran}}| + \lambda_{e,\text{cut}} \sum_{t=1}^T |P_{i,e,t}^{\text{cut}}| + \lambda_{h,\text{cut}} \sum_{t=1}^T |P_{i,h,t}^{\text{cut}}| \quad (38)$$

MG 内的设备运维成本 C_i^{ope} 表示为

$$\begin{aligned} C_i^{\text{ope}} = & \lambda_{\text{GT}} \sum_{t=1}^T P_{i,e,t}^{\text{GT}} + \lambda_{\text{HP}} \sum_{t=1}^T P_{i,h,t}^{\text{HP}} + \lambda_{\text{AC}} \sum_{t=1}^T P_{i,e,t}^{\text{AC}} + \\ & \lambda_{\text{EC}} \sum_{t=1}^T P_{i,e,t}^{\text{EC}} + \lambda_{\text{wd}} \sum_{t=1}^T P_{i,e,t}^{\text{WT}} + \lambda_{\text{pv}} \sum_{t=1}^T P_{i,e,t}^{\text{PV}} + \\ & \lambda_{\text{P2G}} \sum_{t=1}^T P_{i,e,t}^{\text{P2G}} + \lambda_{\text{ccs}} \sum_{t=1}^T P_{i,e,t}^{\text{CCS}} \end{aligned} \quad (39)$$

碳交易成本 $C_i^{\text{co}_2}$ 表示为

$$C_i^{\text{co}_2} = \lambda_{\text{co}_2} (\sum_{t=1}^T Q_{i,t}^{\text{co}_2,\text{a}} - \sum_{t=1}^T Q_{i,g,t}^{\text{CCS}} - \sum_{t=1}^T Q_{i,t}^{\text{co}_2,\text{p}}) \quad (40)$$

MG 每日租借的云储能成本 C_i^{CES} 为

$$\begin{aligned} C_i^{\text{CES}} = & \frac{\lambda_{e,s} S_{i,e}^{\text{max}} + \lambda_{e,p} P_{i,e,t}^{\text{max}} + \lambda_{h,s} S_{i,h}^{\text{max}} + \lambda_{h,p} P_{i,h,t}^{\text{max}}}{365} + \\ & \sum_{t=1}^T [\lambda_e^{\text{CES}} (P_{i,e,t}^{\text{ch}} + P_{i,e,t}^{\text{dis}}) + \lambda_h^{\text{CES}} (P_{i,h,t}^{\text{ch}} + P_{i,h,t}^{\text{dis}})] \end{aligned} \quad (41)$$

总成本:

$$C_i^{\text{MG}} = C_i^{\text{grid}} + C_i^{\text{fuel}} + C_i^{\text{dr}} + C_i^{\text{ope}} + C_i^{\text{co}_2} + C_i^{\text{CES}} + C_i^{\text{P2P}} \quad (42)$$

式中: λ_b 、 λ_s 分别表示向外电网购、售电价格; $P_{i,t}^{\text{buy}}$ 、 $P_{i,t}^{\text{sell}}$ 分别表示向主电网购、售电量; λ_{gas} 表示购气价格; $\lambda_{e,\text{tran}}$ 、 $\lambda_{e,\text{cut}}$ 分别表示可转移和可削减电负荷的补偿价格; $\lambda_{h,\text{cut}}$ 表示可削减热负荷的补偿价格; λ_{GT} 、 λ_{HP} 、 λ_{AC} 、 λ_{EC} 、 λ_{wd} 、 λ_{pv} 、 λ_{P2G} 、 λ_{ccs} 分别对应 GT、HP、AC、EC、wd、PV、P2G、CCS 机组的运维价格系数; λ_{co_2} 表示碳排放价格系数; $Q_{i,t}^{\text{co}_2,\text{a}}$

表示设备产生 CO₂ 的量; $Q_{i,t}^{\text{CO}_2\text{-P}}$ 为微网的 CO₂ 配额; $\lambda_{e,s}$ 、 $\lambda_{e,p}$ 分别表示云储电的租赁价格系数和运维价格系数; $\lambda_{h,s}$ 、 $\lambda_{h,p}$ 分别表示云储热的租赁价格系数和运维价格系数; λ_e^{CES} 、 λ_h^{CES} 分别表示 CES 的充放电价格系数和充放热价格系数; C_i^{P2P} 表示微网间的交易支付成本。

3.5 能量平衡约束

$$P_{i,e,t}^{\text{GT}} + P_{i,e,t}^{\text{PV}} + P_{i,e,t}^{\text{WT}} + P_{i,e,t}^{\text{dis}} + P_{i,t}^{\text{buy}} = P_{i,e,t}^{\text{ch}} + P_{i,e,t}^{\text{load}} + P_{i,e,t}^{\text{EC}} + P_{i,e,t}^{\text{HP}} + P_{i,t}^{\text{sell}} + P_{i,e,t}^{\text{P2G}} + P_{i,e,t}^{\text{CCS}} + P_{i-j,e,t}^{\text{P2P}} \quad (43)$$

$$P_{i,h,t}^{\text{GT}} + P_{i,h,t}^{\text{HP}} + P_{i,t}^{\text{dis}} = P_{i,h,t}^{\text{load}} + P_{i,h,t}^{\text{AC}} + P_{i,h,t}^{\text{ch}} + P_{i-j,h,t}^{\text{P2P}} \quad (44)$$

$$P_{i,c,t}^{\text{EC}} + P_{i,c,t}^{\text{AC}} = P_{i,c,t}^{\text{load}} \quad (45)$$

式中: $P_{i-j,e,t}^{\text{P2P}}$ 、 $P_{i-j,h,t}^{\text{P2P}}$ 分别为微网之间的电能和热能交易量; $P_{i,c,t}^{\text{load}}$ 为用户的冷负荷量。

4 基于数据驱动的两阶段分布鲁棒模型及求解

为方便说明,用矩阵形式来表示两阶段分布鲁棒模型。第一阶段 min 问题先于不确定性发生前决策与外界的能量交易计划,称为预调度阶段,用 $a^T x$ 表示;第二阶段 max-min 问题是在给定第一阶段决策后在不确定集内寻找考虑最恶劣新能源出力场景概率下的调度计划,将其反馈给第一阶段重新调整适应该场景的决策,称为再调度阶段,用 $b^T y_k$ 表示。第一阶段与第二阶段通过不断交替优化直到第一阶段决策满足不确定集内所有场景的要求。

$$\min_{x \in X} a^T x + \max_{p_k \in \Omega} \min_{y_k \in Y} \sum_{k=1}^K p_k b^T y_k \quad (46)$$

$$Cx + Dz \leq d \quad (47)$$

$$Ex + Fy_k \leq h, \forall k \in K \quad (48)$$

$$X = [P_{i,t}^{\text{buy}}, P_{i,t}^{\text{sell}}, P_{i-j,e,t}^{\text{P2P}}, P_{i-j,h,t}^{\text{P2P}}] \quad (49)$$

$$Y = \begin{bmatrix} G_{i,t}^{\text{GT}}, Q_{i,g,t}^{\text{P2G}}, P_{i,e,t}^{\text{tran}}, P_{i,e,t}^{\text{cut}}, P_{i,h,t}^{\text{cut}}, P_{i,e,t}^{\text{GT}}, P_{i,h,t}^{\text{HP}}, P_{i,c,t}^{\text{AC}}, \\ P_{i,e,t}^{\text{EC}}, P_{i,e,t}^{\text{WT}}, P_{i,e,t}^{\text{PV}}, P_{i,e,t}^{\text{P2G}}, P_{i,e,t}^{\text{CCS}}, P_{i,h,t}^{\text{ch}}, P_{i,h,t}^{\text{dis}}, P_{i,e,t}^{\text{dis}}, P_{i,c,t}^{\text{ch}} \end{bmatrix} \quad (50)$$

式中: X 和 Y 分别表示第一阶段和第二阶段决策变量的集合,由式(49)、式(50)表示; K 为聚类后的场景总数; p_k 为聚类后场景 k 出现的概率; Ω 为综合范数的置信区间;式(47)、(48)表示第一阶段和第二阶段变量的约束条件, C 、 D 、 E 、 F 、 d 和 h 表示常数系数矩阵。

通过场景聚类得到的场景概率分布存在一定的

误差。为了使概率分布更接近真实数据,本节给出的不确定性置信集以初始概率分布为中心,通过综合范数对情景概率分布进行约束,得到每个离散情景的最差概率分布。由 1-范数和 ∞ -范数组成的综合范数概率置信区间表示为

$$\Pr\left\{\sum_{k=1}^K |p_k - p_{k0}| \leq \theta_1\right\} \geq 1 - 2Ke^{-\frac{2M\theta_1}{K}} \quad (51)$$

$$\Pr\left\{\max_{1 \leq k \leq K} |p_k - p_{k0}| \leq \theta_\infty\right\} \geq 1 - 2Ke^{-2M\theta_\infty} \quad (52)$$

式中: $\Pr\{\cdot\}$ 为概率算子; M 为生成的样本个数; p_{k0} 为离散情景 k 的初始概率值; θ_1 和 θ_∞ 分别为 1-范数和 ∞ -范数对应约束下的概率允许偏差极限。

为方便表示,令式(51)和式(52)不等式右边部分分别等于 α_1 和 α_∞ ; 其中, α_1 和 α_∞ 表示概率分布需要满足的不确定性置信度。式(51)和式(52)可变换为

$$\theta_1 = \frac{K}{2M} \ln \frac{2K}{1 - \alpha_1} \quad (53)$$

$$\theta_\infty = \frac{1}{2M} \ln \frac{2K}{1 - \alpha_\infty} \quad (54)$$

综合范数的置信区间表示为

$$\Omega = \left\{ \begin{array}{l} p_k | p_k \geq 0, k=1, \dots, K; \sum_{k=1}^K p_k = 1; \\ \sum_{k=1}^K |p_k - p_{k0}| \leq \theta_1; \max_{1 \leq k \leq K} |p_k - p_{k0}| \leq \theta_\infty \end{array} \right\} \quad (55)$$

5 MMG 博弈决策模型

5.1 MMG 博弈模型

各 MG 在联盟中的能量贡献不同,导致了议价能力的差异,根据议价能力分配微网收益。所提非对称议价收益分配如式(56)所示。

$$\begin{cases} \max \prod_{i=1}^N (C_i^0 - C_i^1 + C_i^{\text{P2P}})^{S_i} \\ \text{s.t. } C_i^{0*} - C_i^{1*} + C_i^{\text{P2P}} \geq 0 \end{cases} \quad (56)$$

式中: C_i^0 、 C_i^{0*} 分别为微网 i 合作前的成本和最优成本; C_i^1 、 C_i^{1*} 分别为微网 i 不考虑支付的合作成本和最优合作成本; S_i 为议价能力。文献[27-32]已经证明纳什议价模型可以等价求解合作效益最大化子问题和能源支付子问题。

5.2 子问题 1: 合作效益最大化(P1)

$$\begin{cases} \min C_i^1 = \min_{i=1}^N \sum_{i=1}^N a^T x + \max_{p_k \in \Omega} \min_{y_k \in Y} \sum_{i=1}^N \sum_{k=1}^K p_k b^T y_k \\ \text{s.t. (47)} \end{cases} \quad (57)$$

5.3 子问题 2: 能源支付子问题(P2)

$$\left\{ \begin{array}{l} \max \prod_{i=1}^N (C_i^0 - C_i^{1*} + C_i^{P2P}) S_i \\ \text{s.t. } C_i^0 - C_i^{1*} + C_i^{P2P} \geq 0 \\ C_i^{P2P} = p_{i-j}^{P2P,e} P_{i-j,e,t}^{P2P} + p_{i-j}^{P2P,h} P_{i-j,h,t}^{P2P} \\ p_{i-j,\min}^{P2P,e} \leq p_{i-j}^{P2P,e} \leq p_{i-j,\max}^{P2P,e} \\ p_{i-j,\min}^{P2P,h} \leq p_{i-j}^{P2P,h} \leq p_{i-j,\max}^{P2P,h} \end{array} \right. \quad (58)$$

式中: C_i^{1*} 为子问题 1 求得的最优解; $p_{i-j}^{P2P,e}$ 为交互电价, $p_{i-j,\max}^{P2P,e}$ 、 $p_{i-j,\min}^{P2P,e}$ 为其上下限; $p_{i-j}^{P2P,h}$ 为交互热价, $p_{i-j,\max}^{P2P,h}$ 、 $p_{i-j,\min}^{P2P,h}$ 为其上下限。

议价能力是决定收益分配的重要因素, 因此通过非线性能量映射法^[31]量化各主体的议价能力。本文将各微网的电能贡献和热能贡献进行量化, 确定合理的能量交易价格, 实现公平分配。具体表述如下。

$$S_i = S_i^a / \sum_{i=1}^N S_i^a \quad (59)$$

$$S_i^a = \mu_e S_{i,e} + \mu_h S_{i,h} \quad (60)$$

$$S_{i,e} = e^{E_i^{\text{supply}} / E_{\max}^{\text{supply}}} - e^{-(E_i^{\text{receive}} / E_{\max}^{\text{receive}})} \quad (61)$$

$$S_{i,h} = e^{H_i^{\text{supply}} / H_{\max}^{\text{supply}}} - e^{-(H_i^{\text{receive}} / H_{\max}^{\text{receive}})} \quad (62)$$

$$\mu_e + \mu_h = 1 \quad (63)$$

$$E_i^{\text{supply}} = \sum_{t=1}^T \max(P_{i-j,e,t}^{P2P}, 0) \quad (64)$$

$$E_i^{\text{receive}} = -\sum_{t=1}^T \max(P_{i-j,e,t}^{P2P}, 0) \quad (65)$$

$$H_i^{\text{supply}} = \sum_{t=1}^T \max(P_{i-j,h,t}^{P2P}, 0) \quad (66)$$

$$H_i^{\text{receive}} = -\sum_{t=1}^T \max(P_{i-j,h,t}^{P2P}, 0) \quad (67)$$

式中: S_i 为各微网议价能力 S_i^a 的归一化量化值; $S_{i,e}$ 、 $S_{i,h}$ 分别为各微网电能、热能议价能力的量化值; μ_e 、 μ_h 分别为电能、热能对议价的贡献占比; E_i^{supply} 、 H_i^{supply} 分别为微网参与合作时总体提供的电能和热能; E_i^{receive} 、 H_i^{receive} 分别为微网参与合作时总体接受的电能和热能; E_{\max}^{supply} 、 $E_{\max}^{\text{receive}}$ 分别为微网提供和接受电能的最大值; H_{\max}^{supply} 、 $H_{\max}^{\text{receive}}$ 分别为微网提供和接受热能的最大值。

5.4 模型的分布式求解

5.4.1 子问题 1 的分布式求解

注意到模型(57)目标函数的可分解性, 根据 ADMM 算法原理, 对于微网 i , 构造增广拉格朗日函数为

$$\left\{ \begin{array}{l} L_i(P_{i-j,e/h,t}^{P2P}, P_{j-i,e/h,t}^{P2P}, \lambda_{i-j,t}^{e/h}, \rho_{i-j,t}^{e/h}) = \\ \min_{x,z} \mathbf{a}^T \mathbf{x} + \sum_{i \in N} \lambda_{i-j,t}^{e/h} (P_{i-j,t}^{P2P} + P_{j-i,t}^{P2P}) + \\ \sum_{i \in N} \frac{\rho_{i-j,t}^{e/h}}{2} \|P_{i-j,e/h,t}^{P2P} - P_{j-i,e/h,t}^{P2P}\|_2^2 + \max_{p_k \in \Omega} \min_{y_k \in Y} \sum_{k \in K} p_k \mathbf{b}^T y_k \\ \text{s.t. } (47) \end{array} \right. \quad (68)$$

式中: $\lambda_{i-j,t}^{e/h}$ 为拉格朗日乘子; $\rho_{i-j,t}^{e/h}$ 为惩罚因子。

对于两阶段鲁棒优化问题, 由于各个场景问题相互独立, 可以采用并行求解的方法进行处理。首先分别求解 k 个 min 问题, 然后再求解 max 问题, 从而避免推导对偶形式以及引入 0-1 变量造成的求解效率低的问题。在得到最恶劣的场景概率后, 再通过 C&CG 算法进行主、子问题迭代求解。

先将原问题(57)拆分为一个主问题和子问题, 并通过主子问题不断迭代求解出模型的最优解。

主问题:

$$\left\{ \begin{array}{l} \min_{x,z} \mathbf{a}^T \mathbf{x} + \sum_{i \in N} \lambda_{i-j,t}^{e/h} (P_{i-j,t}^{P2P} + P_{j-i,t}^{P2P}) + \\ \sum_{i \in N} \frac{\rho_{i-j,t}^{e/h}}{2} \|P_{i-j,e/h,t}^{P2P} - P_{j-i,e/h,t}^{P2P}\|_2^2 + \eta \\ \text{s.t. } \mathbf{C}\mathbf{x} + \mathbf{D}\mathbf{z} \leq \mathbf{d} \\ \mathbf{E}\mathbf{x} + \mathbf{F}\mathbf{y}_k \leq \mathbf{h}, \forall k \in K \\ \eta \geq \sum_{y_k \in Y} p_{k*} \mathbf{b}^T y_k \end{array} \right. \quad (69)$$

式中: η 为引入的辅助变量; p_{k*} 为子问题求得的最恶劣概率分布的优化结果。

子问题:

$$\left\{ \begin{array}{l} \max_{p_k \in \Omega} \min_{y_k \in Y} \sum_{k=1}^K p_k \mathbf{b}^T y_k \\ \text{s.t. } \mathbf{E}\mathbf{x}^* + \mathbf{F}\mathbf{y}_k \leq \mathbf{h}, \forall k \in K \end{array} \right. \quad (70)$$

式中, \mathbf{x}^* 为主问题求得的优化结果, 在子问题中为已知量。由于不同场景下内层决策变量相互独立, 故子问题的内层可以分解为 K 个独立的线性规划问题, 并利用并行计算方法同时求解。因此子问题(70)可等效为

$$\left\{ \begin{array}{l} \max_{p_k \in \Omega} \sum_{k=1}^K p_k \mathbf{b}^T y_k^* \\ y_k^* = \arg \min_{y_k \in Y} \mathbf{b}^T y_k^* \\ \text{s.t. } \mathbf{E}\mathbf{x}^* + \mathbf{F}\mathbf{y}_k \leq \mathbf{h}, \forall k \in K \end{array} \right. \quad (71)$$

式中, y_k^* 指场景 k 对应线性规划问题的最优解。

基于耦合可并行计算的 ADMM-C&CG 算法求解子问题 1 的流程见图 4, 过程如下所述。

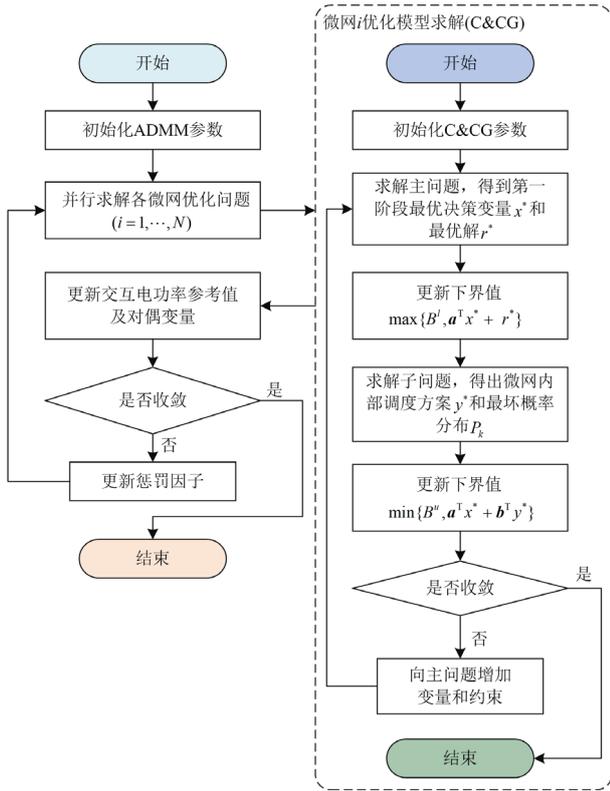


图4 算法流程图

Fig. 4 Algorithm flowchart

1) 初始化。初始化 ADMM 迭代次数 $m=1$ 、MG 间的交互功率、拉格朗日乘子。通过 LSTM-CGAN 和 K-means⁺⁺ 得到不同可再生能源出力的初始场景概率。

2) 在 ADMM 的每次迭代中, 各微网基于 C&CG 算法并行计算各自内部优化问题。基于 C&CG 算法的求解流程如下:

(a) 初始化不确定变量。设定下界 $LB = -\infty$, 上界 $UB = +\infty$, 迭代次数 $r=1$, 收敛误差 ε 。

(b) 求解主问题(68)。将主问题的目标函数值作为新的下界。

(c) 求解子问题(70)。将求得的主问题最优解代入子问题中, 求解得到子问题的目标函数值, 更新上界。

(d) 满足收敛条件, 则停止迭代, 返回微网 i 在 ADMM 第 m 次迭代中的最优解; 否则, 在主问题中增加关于场景约束继续迭代。

3) 每个微网重复执行以下步骤更新:

$$\begin{cases} P_{i-j,e/h,t}^{P2P,k+1} = \arg \min_{P_{i-j,e/h,t}^{P2P}} L_i(P_{i-j,e/h,t}^{P2P}, P_{j-i,e/h,t}^{P2P}, \lambda_{i-j,t}^{e/h}, \rho_{i-j,t}^{e/h}) \\ P_{j-i,e/h,t}^{P2P,k+1} = \arg \min_{P_{j-i,e/h,t}^{P2P}} L_i(P_{i-j,e/h,t}^{P2P}, P_{j-i,e/h,t}^{P2P}, \lambda_{i-j,t}^{e/h}, \rho_{i-j,t}^{e/h}) \\ \lambda_{i-j,t}^{e/h,k+1} = \lambda_{i-j,t}^{e/h,k} + \rho_{i-j,t}^{e/h} (P_{i-j,e/h,t}^{P2P} + P_{j-i,e/h,t}^{P2P}) \end{cases}$$

4) 判断每个微网是否均满足如下收敛条件:

$$\max \left\{ \sum_{t=1}^T \left\| (P_{i-j,e/h,t}^{P2P} + P_{j-i,e/h,t}^{P2P}) \right\|_2^2 \right\} \leq \varepsilon$$

5) 若满足则停止迭代, 输出多园区系统调度结果; 否则, 更新惩罚因子, 返回步骤 2) 继续迭代。

5.4.2 子问题 2 的分布式求解

求得子问题 1 后, 可同时得到微网间的最优电热交易功率, 进而计算出议价能力。将这些值代入到收益分配问题中可求解微网间电热交易价格。通过对模型(58)的目标函数取对数, 子问题 2 很容易利用商业求解器解决。利用目标函数的可分解性, 同样可采用 ADMM 进行求解以保护隐私, 因为相似性, 此处不再赘述。

6 仿真结果分析

本文算例选择华北地区的 3 个相邻微网作为研究对象, 并使用 Matlab R2020b 结合工具包 Yalmip, 调用商业求解器 Gurobi 9.1 对优化程序进行求解。以华北某地区 2 年的 PV 和 WT 输出数据作为历史数据集, 数据集的 80% 用于训练, 20% 用于测试。并设 $\alpha_1 = 0.5$, $\alpha_\infty = 0.8$ 。微网参数与能源价格见附录 A。

6.1 LSTM-CGAN 的性能评估

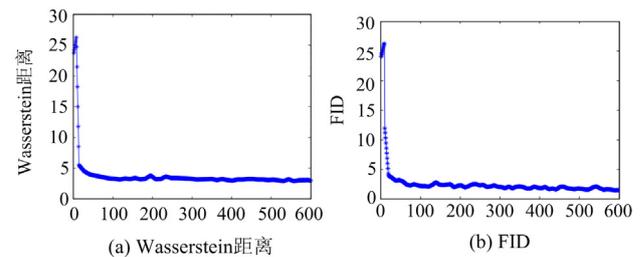
在本节中使用以下 3 个评价指标来评估所提 LSTM-CGAN 场景生成方法的性能。

1) Wasserstein 距离: 模型训练的目标是使损失尽可能小, 即最小化真实分布和生成分布之间的 Wasserstein 距离^[33]。随着 Wasserstein 距离不断减小, 最终判别器将无法准确区分输入样本的来源, 可再生能源输出场景将充分反映历史数据的真实分布。

2) Fréchet 起始距离(Fréchet inception distance, FID)测量真实样本和合成样本之间的距离^[34]。FID 越小, 两个分布越接近, 意味着训练性能越好。

3) 最大平均差异(maximum mean discrepancy, MMD)是希尔伯特空间中两个分布之间差异的度量, 它可用于测量生成的数据集和真实数据集之间的距离^[35]。与 FID 类似, MMD 度量越小, 生成性能越好, 这意味着 LSTM-CGAN 的性能越好。

以微网 1 为例, 这 3 个评价指标在训练过程中的变化如图 5 所示。可以发现, LSTM-GAN 方法生



(a) Wasserstein 距离

(b) FID

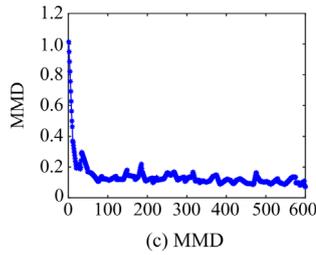


图 5 训练期间评估指标的变化

Fig. 5 Changes of the evaluation metrics during training

成的场景与风电真实值之间的误差很小，能很好地反映新能源的真实场景。

6.2 场景生成与聚类结果

图 6 显示了通过 LSTM-CGAN 场景生成和 K-means⁺⁺聚类获得的典型可再生能源输出场景及其概率。由图 6 可以看出，LSTM-GAN 方法生成的 1000 个场景集几乎可以覆盖真实功率曲线的范围，且功率区间宽度较小。通过分析多场景曲线，很明显聚类得到的典型场景可以完全包含真实功率曲线，这表明所提场景生成与削减方法能够很好地刻画新能源出力的不确定性区间。

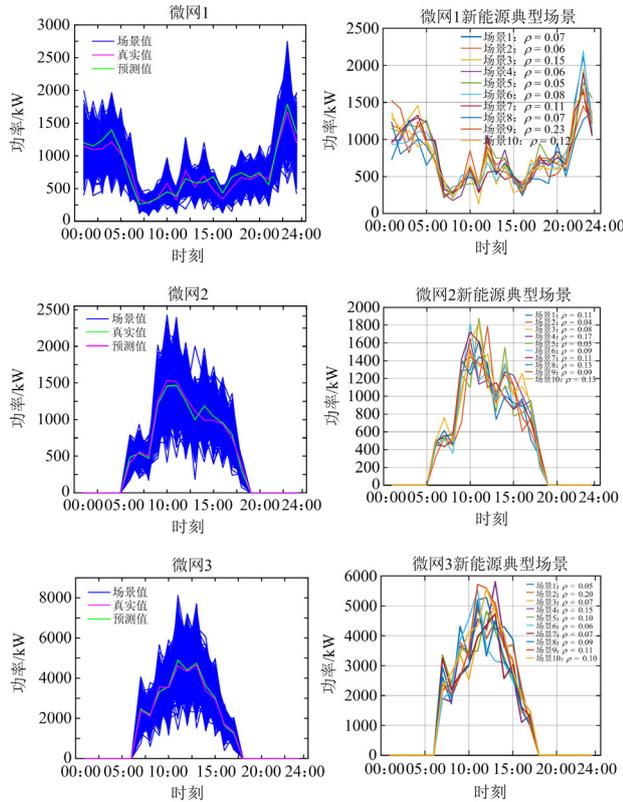


图 6 每个微网的场景生成与聚类结果

Fig. 6 Scenario generation and clustering results for each microgrid

6.3 算法收敛性分析

图 7 展示了所提可并行计算 ADMM-C&CG 算法在求解子问题 1 时的收敛情况。其中，C&CG 算法迭代曲线为 ADMM 在最后一次迭代中的收敛过程。图 8 则展示了 ADMM 算法求解子问题 2 时的支付成本收敛过程。

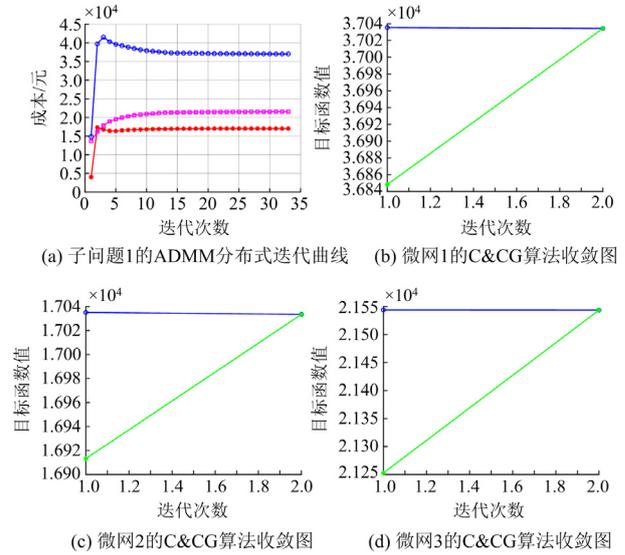


图 7 ADMM-C&CG 算法迭代收敛过程

Fig. 7 Iterative convergence results of ADMM-C&CG algorithm

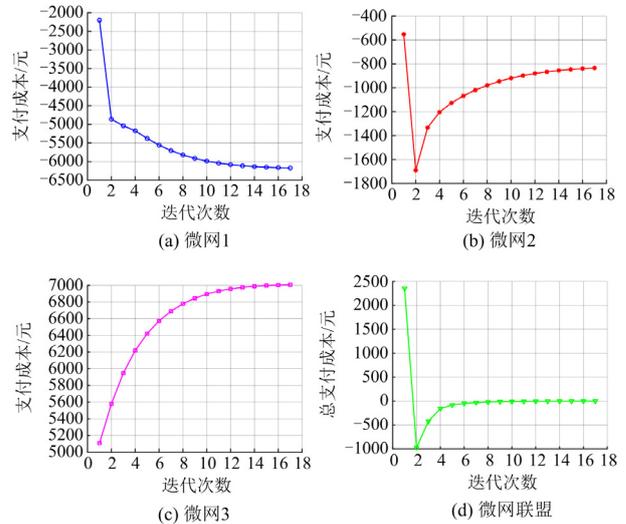


图 8 ADMM 求解支付迭代过程

Fig. 8 ADMM solution payment iteration process

可以发现，子问题 1 中 ADMM 在经过 34 次迭代后收敛，计算时间为 313 s；子问题 2 中 ADMM 在经过 17 次迭代后收敛，计算时间为 12 s。这表明 ADMM 算法对于求解所提合作优化问题具有良好的收敛性能和计算效率，同时能保护每个主体信息的隐私。此外，可以发现并行 C&CG 算法具有快速

收敛的特性,各微网内部模型均在 2 次迭代内收敛,在迭代过程中,上界与下界不断逼近,直至上界与下界之差小于给定误差,可得 C&CG 算法对各微网内部模型的求解具有很好的效果。

6.4 优化结果分析

6.4.1 能量调度分析

每个微网参与电热 P2P 交易后,各自的优化调度结果分别如图 9—图 11 所示。以微网 1 为例,微网

1 风力充沛,在 00:00—06:00 和 13:00—16:00 处于本地用电低谷时段,多余的风力发电量通过云储能充电,并通过 EC、P2G-CCS 以及 HP 进行消纳,多余的电力出售给外电网和其他微网。在 07:00—12:00 与 16:00—23:00,该时段处于用电高峰期,消纳全部的风电出力后,微网 1 通过增强 GT 机组出力、利用云储能系统放电、向其他微网和上级电网购电以及需求响应等措施来满足用电负荷需求,

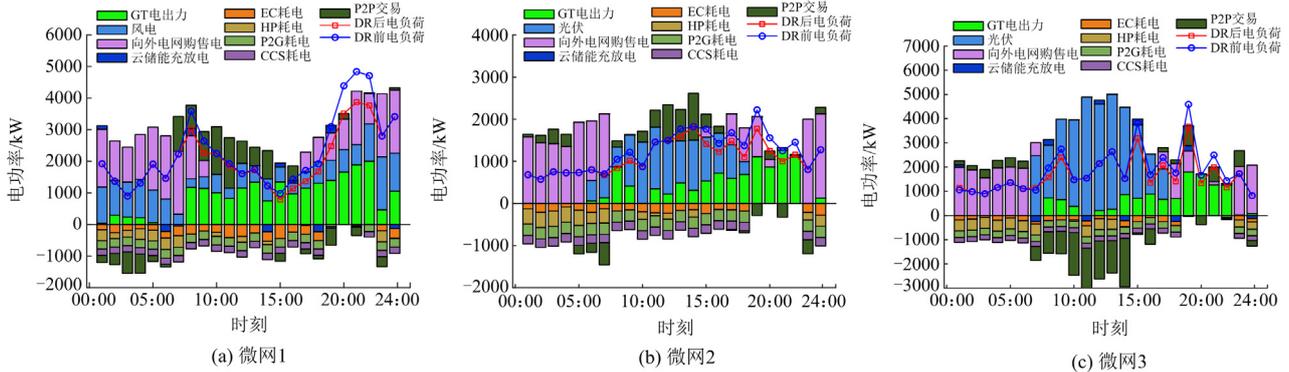


图 9 多微网的电功率平衡

Fig. 9 Electrical power balance of multiple microgrids

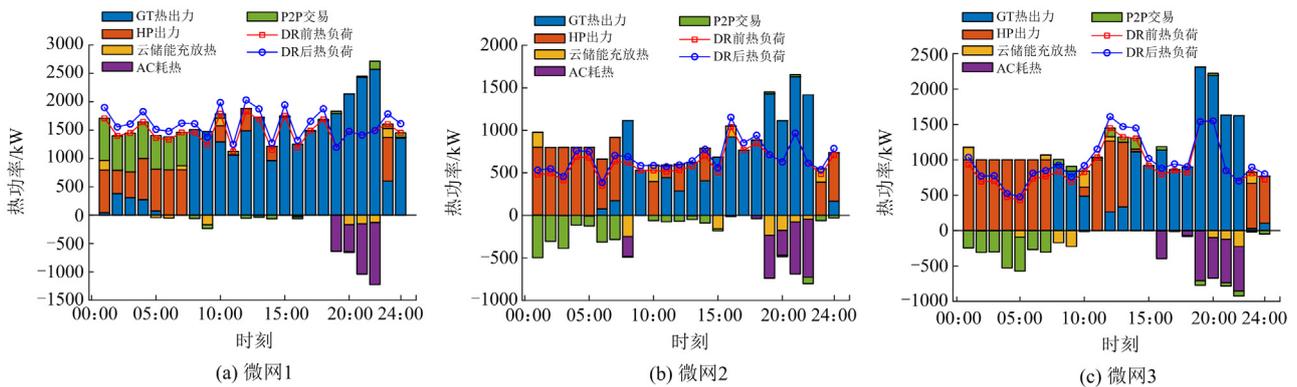


图 10 多微网的热功率平衡

Fig. 10 Thermal power balance of multiple microgrids

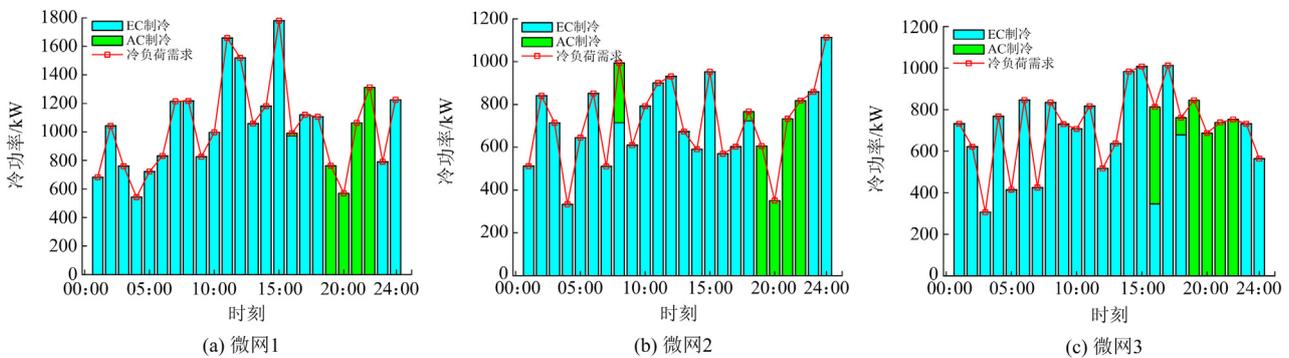


图 11 多微网的冷功率平衡

Fig. 11 Cold power balance of multiple microgrids

并降低了园区的总用能成本。在热功率的优化方面,见图 10(a),在 00:00—07:00 时段微网 1 通过 HP 出力、GT 出力、云储能充热需求响应以及 P2P 热能交易等手段维持热力平衡。在 19:00—22:00 时段 GT 机组热出力过多,通过 AC 机组耗热和云储能放热消纳多余的热量,缓解 EC 的压力。冷功率的分析同理。总体来看,微网 1 通过 P2P 交易,有效减少了向上级电网的购电成本并提高了微网系统的收益。

6.4.2 微网间的 P2P 电热交易结果

由图 12(a)可知,微网 1 在 00:00—6:00 时段风力发电充沛,用电量少,多余电量通过合作交易模式传输给其他微网盈利,不仅降低了自身的储能成本,也降低了其他微网的发电成本。在 06:00—15:00 时段,微网 3 地区光伏发电充沛,产生电能过量,而微网 1 和微网 2 新能源发电不足且处于用能高峰期,向微网 3 购买电量实现共赢。由图 7(b)知,在 00:00—07:00 时段,微网 1 热能需求量大,HP 功率受限,需要向其他微网购买热能。三个区域之间能源交易处于实时平衡,即每个时段内交互功率总和为 0。

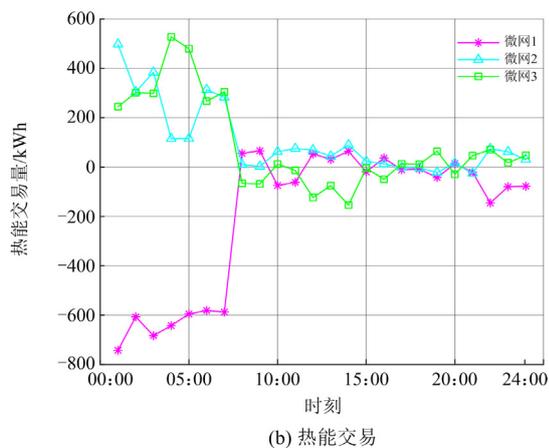
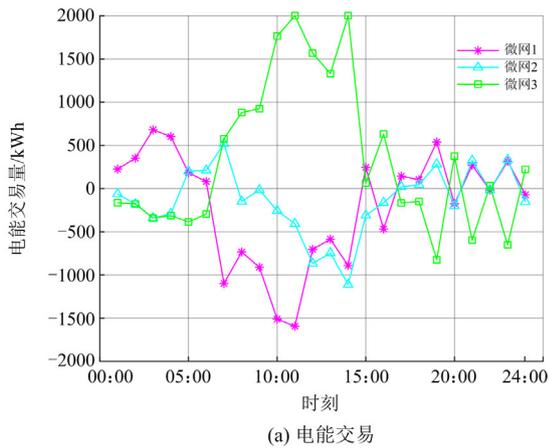


图 12 微网间的能量交互结果

Fig. 12 Energy interaction results between microgrids

6.4.3 非对称议价的交易价格

由图 13 可知,能源交易价格的变化与图 12 中的能源交易量对应:微网的议价能力随着能量交互的增加而增强,从而获得更有利的交易价格。各时段的交易电价均处于主电网购电价格之间,降低了向主网购能成本,提高了各微网的收益。

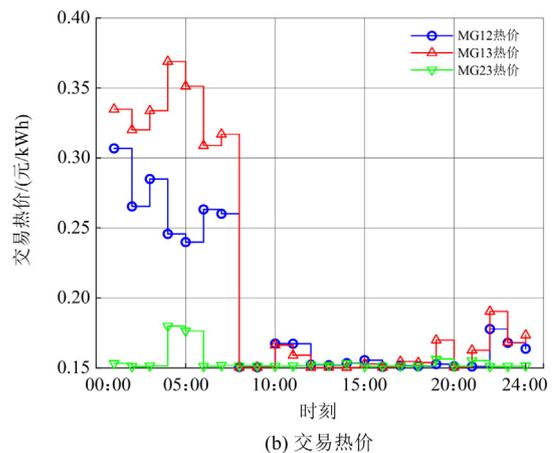
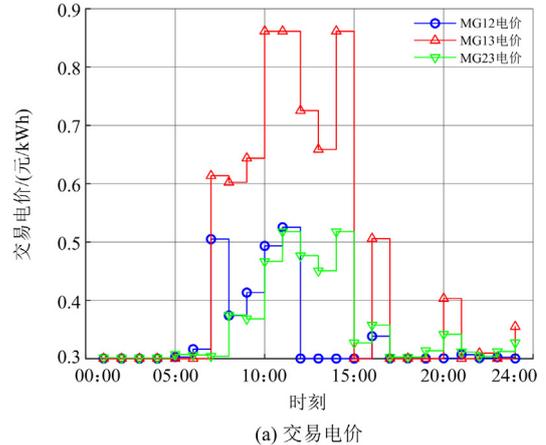


图 13 微网间的能量交易价格

Fig. 13 Energy trading prices between microgrids

6.5 不同利益分配模型的收益和成本分析

表 1 给出了各微网在参与 P2P 交易运行前后的运行成本情况。其中模式 1 为本文所提模型,模式 2 为标准纳什议价模型。

由表 1 可知,采用本文多能贡献能量的大小进行非对称利益分配,各微网收益分别提升 1042.13 元、1333.83 元、2340.95 元,避免了模式 2 平均分配。因此,所提利益分配方法通过考虑各微网的多种能量贡献水平,从而给予贡献高的 MG 更高的议价能力和更高的利润分成,更有利于实现利益分配的合理性。

表 1 两种模式下的微网成本

Table 1 Microgrid costs under two modes

模式	微网编号	P2P 交易前成本/元	P2P 交易后成本/元	支付成本/元	最终成本/元	议价能力	利润/元
模式1	微网1	44 275.51	37 034.31	6199.07	43 233.38	0.2209	1042.13
	微网2	19 181.73	17 033.55	814.35	17 847.90	0.2828	1333.83
	微网3	16 871.28	21 543.75	-7013.42	14 530.33	0.4963	2340.95
	微网联盟	80 328.52	75 611.61	0	75 611.61	1	4716.91
模式2	微网1	44 275.51	37 034.31	5668.89	42 703.21	1/3	1572.30
	微网2	19 181.73	17 033.55	575.88	17 609.43	1/3	1572.30
	微网3	16 871.28	21 543.75	-6244.77	15 298.97	1/3	1572.30
	微网联盟	80 328.52	75 611.61	0	75 611.61	1	4716.90

6.6 不同置信水平的分析

为了分析置信水平对 MMG 运营成本的影响, 设 $M=1000$ 。不同置信水平下合作联盟运营成本见表 2。随着置信水平 α_1 和 α_∞ 的增加, 合作联盟的成本增加。原因是置信区间变大, 新能源发电的最恶劣场景出现概率增加, 各微网需要调控成本来应对风光的不确定性, 而导致合作联盟总的成本增加。

表 2 不同置信水平结果成本对比

Table 2 Cost comparison of results at different confidence levels

α_1	联盟总成本/元		
	$\alpha_\infty = 0.2$	$\alpha_\infty = 0.5$	$\alpha_\infty = 0.99$
0.5	75 333.79	75 471.41	75 607.42
0.8	75 488.61	75 611.61	75 680.91
0.99	75 553.18	75 697.43	75 731.11

为了进一步分析综合范数置信区间的优越性, 表 3 选取 α_∞ 为 0.8, α_1 分别为 0.2、0.5、0.99 的综合范数与仅考虑 ∞ -范数约束的优化结果进行比较。可以看出, 当历史数据个数不变时, 综合范数置信区间下的优化结果比只考虑 ∞ -范数置信区间下的优化结果更经济。这是因为综合范数置信区间更小, 可以更准确地表征风光发电的不确定性, 从而降低了运营成本。表 4 为综合范数与仅考虑 1-范数的优化结果比较。同样地, 综合范数约束条件下的联盟总成本值较仅考虑 1-范数约束条件下的更低, 保守度更低。

6.7 与其他方法的比较

为了进一步测试所提 LSTM-CGAN 场景驱动的 DRO 方法的性能, 在本节中分别使用本文所提方法与基于拉丁超立方方法(Latin Hypercube Sampling, LHS)^[36]、基于蒙特卡洛方法(Monte Carlo, MC)^[16]、基于 LSTM 方法^[19]以及基于 CGAN 的场景生成方法^[22]的生成测试集中场景集, 不同场景集驱动的 DRO 方法的 MMG 联盟样本 MMD 均值以及总成本的优化结果如表 5 所示。由表 5 可以看出, LSTM-

CGAN 法生成的场景集的 MMD 均值明显小于其他方法, 验证了本文所提算法的生成性能更优良。这反映了所提 LSTM-CGAN 法具有较低的运营成本, 在刻画的新能源不确定性模型没有其他两种方法保守。证明了本文所提方法的准确性和优越性。

表 3 综合范数与 ∞ -范数成本对比Table 3 Comparison of comprehensive norm and ∞ -norm costs

α_1	联盟总成本/元	
	综合范数	∞ -范数
0.2	75 488.61	75 991.23
0.5	75 612.33	75 991.23
0.99	75 680.91	75 991.23

表 4 综合范数与 1-范数成本对比

Table 4 Comparison of comprehensive norm and 1-norm cost

α_∞	联盟总成本/元	
	综合范数	1-范数
0.5	75 471.41	75 873.37
0.8	75 612.33	75 873.37
0.99	75 697.43	75 873.37

表 5 不同 DRO 方法的优化结果

Table 5 Optimization results of different DRO methods

DRO 方法	MMD	联盟总成本/元
LHS	0.2635	76 379.56
MC	0.2313	76 332.79
LSTM	0.2775	76 553.21
CGAN	0.1387	75 982.15
LSTM-CGAN	0.0729	75 611.61

6.8 扩大算例规模

为了进一步验证 ADMM-C&CG 算法性能, 在本节分别考虑 6 微网和 10 微网合作运行时算法的收敛情况和计算效率。图 14 为 10 个微网参与合作的算法迭代情况, 子问题 1 在经过 47 次迭代后收敛, 计算时间为 827 s, 收敛性能良好。表 6 为 ADMM-C&CG 算法与集中式算法优化结果, ADMM-C&CG 算法与集中优化成本接近, 表明算法的全局收敛性

能良好,同时,随着微网规模增加,ADMM-C&CG算法计算时间在允许范围内,验证了所提方法的计算效率。因此,当微网规模增大时,ADMM-C&CG算法对求解多微网合作运行问题仍具有良好的收敛性能和计算效率。

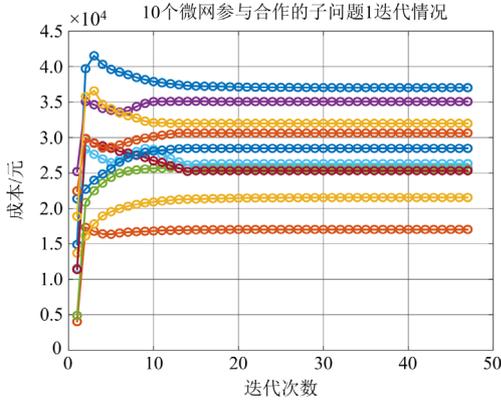


图 14 10 微网参与合作的迭代情况

Fig. 14 Iteration of 10 microgrids participating in cooperation

表 6 ADMM-C&CG 与集中式算法对比

Table 6 Comparison between ADMM-C&CG and centralized algorithms

算法	指标	微网数目		
		3	6	10
集中式优化	运行成本/元	75 617.33	180 095.21	279 060.72
	迭代次数	33	38	47
ADMM-C&CG	迭代时间/s	313	538	827
	运行成本/元	75 611.61	180 092.43	279 074.91

7 结论

本文提出了一种含云储能系统的多微网两阶段数据驱动分布鲁棒协同优化模型。为更准确地描述新能源的不确定性,提出了一种基于 LSTM-CGAN 场景生成方法,用于生成 DRO 集合的初始新能源场景。该方法采用 LSTM 网络构建 CGAN 的生成器和判别器,以更好地学习新能源出力序列的时序特征。主要结论如下:

1) 基于 ADMM-C&CG 算法求解多微网之间的能量共享优化模型时,各微网仅交换有限的信息,保护各微网的隐私。本文设计的算法求解性能良好,同时每个微网最终合作运行成本比独立运行成本都有所降低,能进一步降低微网系统独立运行时受新能源不确定性的影响。

2) 与传统的纳什议价模型相比,本文按照微网的多能交易能量贡献大小合理分配合作收益,有效地激发了微网主体参与能量交易的积极性。

3) 所提基于 LSTM-CGAN 构造的 DRO 模型相

较于 LHS 和 CGAN 场景驱动的两阶段 DRO 方法,进一步降低了模型的保守性。

在后续的研究中,将考虑配电网运营商参与的混合博弈模型并分析多重不确定性的影响。

附录 A

表 A1 微网运行参数

Table A1 Microgrid operation parameters

参数	数值	参数	数值
$\eta_{GT,e}$	0.35	δ_h	0.05
$\eta_{GT,h}$	0.45	η_e^{ch}	0.98
H_{GHV}	9.7	η_h^{ch}	0.95
$P_{i,e,max}^{GT}/kW$	2000	η_e^{dis}	0.98
η_{HP}	2.2	η_h^{dis}	0.95
$P_{i,h,max}^{HP}/kW$	800	$\alpha_{i,e}^{max}$	0.9
$P_{i,e,max}^{AC}/kW$	1500	$\alpha_{i,e}^{min}$	0.1
η_{AC}	1.2	$\alpha_{i,h}^{max}$	0.9
$P_{i,e,max}^{EC}/kW$	1000	$\alpha_{i,h}^{min}$	0.1
η_{EC}	4	$S_{e,rent}^{max}/kW$	500
η_{P2G}	0.55	$S_{h,rent}^{max}/kW$	500
η_{CC}	1.06	$P_{e,rent}^{max}/kW$	250
η_{CCS}	0.5	$P_{h,rent}^{max}/kW$	250
$P_{i,e,max}^{P2G}/kW$	300	α_e^{cut}	0.1
$P_{i,e,max}^{CCS}/kW$	200	α_h^{cut}	0.1
δ_e	0.05	α_e^{tran}	0.1
μ_e	0.5	μ_h	0.5

表 A2 能源价格

Table A2 Energy prices

能源	时段	购价/元	售价/元
电能	01:00—08:00	0.4	0.2
	23:00—24:00		
	08:00—12:00	0.75	0.4
	15:00—19:00		
	12:00—15:00		
天然气	19:00—23:00	1.2	0.6
	00:00—24:00	2.2	—

表 A3 微网运维成本参数

Table A3 Microgrid O&M cost parameters

参数	数值
$\lambda_{e,tran}, \lambda_{e,cut}$	0.03, 0.25
$\lambda_{h,cut}$	0.15
$\lambda_{GT/HP/AC/EC}$	0.03/0.02/0.025/0.01
$\lambda_{wd/pv/P2G/CCS}$	0.11/0.08/0.015/0.025
λ_{CO_2}	0.4
$\lambda_{cs}, \lambda_{cp}$	110/37
$\lambda_{hs}, \lambda_{hp}$	30/10
$\lambda_{e}^{CES}, \lambda_{h}^{CES}$	0.01/0.005

参考文献

- [1] 马跃, 孟润泉, 魏斌, 等. 考虑阶梯式碳交易机制的电网两阶段鲁棒优化调度[J]. 电力系统保护与控制, 2023, 51(10): 22-33.
MA Yue, MENG Runquan, WEI Bin, et al. Two-stage robust optimal scheduling of a microgrid with a stepped carbon trading mechanism[J]. Power System Protection and Control, 2023, 51(10): 22-33.
- [2] XU D, ZHOU B, LIU N, et al. Peer-to-peer multi-energy and communication resource trading for interconnected microgrids[J]. IEEE Transactions on Industrial Informatics, 2021, 35(6): 2522-2533.
- [3] 赵杰, 王聪, 李冠冠, 等. 考虑需求响应的多微网 P2P 能源交易低碳运行策略[J]. 电力建设, 2023, 44(12): 54-65.
ZHAO Jie, WANG Cong, LI Guanguan, et al. Low-carbon operation strategy for P2P energy trading among multiple microgrids considering demand response[J]. Electric Power Construction, 2023, 44(12): 54-65.
- [4] QIU H, GU W, XU Y, et al. Robustly multi-microgrid scheduling: stakeholder-parallelizing distributed optimization[J]. IEEE Transactions on Sustainable Energy, 2020, 11(2): 988-1001.
- [5] 姜宇, 陈翔宇, 傅守强. 计及风电功率相关性的电网日前随机优化调度方法[J]. 全球能源互联网, 2022, 5(1): 46-54.
JIANG Yu, CHEN Xiangyu, FU Shouqiang. Day-ahead stochastic optimization method of microgrid considering the correlation of wind power[J]. Journal of Global Energy Interconnection, 2022, 5(1): 46-54.
- [6] 周计晨, 吕胤杰, 杨诚之, 等. 考虑风电出力不确定性的分布鲁棒主备协同优化调度[J]. 电力系统保护与控制, 2020, 48(20): 66-73.
ZHOU Jichen, LÜ Yinjie, YANG Chengzhi, et al. Distributionally robust co-optimization of energy and reserve dispatch considering uncertain wind power output[J]. Power System Protection and Control, 2020, 48(20): 66-73.
- [7] ZHAO Z, GUO J, LUO X, et al. Distributed robust model predictive control-based energy management strategy for islanded multi-microgrids considering uncertainty[J]. IEEE Transactions on Smart Grid, 2022, 13(3): 2107-2120.
- [8] SHAMS M H, SHAHABI M, MANSOURLAKOURAJ M, et al. Adjustable robust optimization approach for two-stage operation of energy hub-based microgrids[J]. Energy, 2021, 222.
- [9] YI G, KYRI B, EMILIANO D, et al. Data-based distributionally robust stochastic optimal power flow—part I: methodologies[J]. IEEE Transactions on Power Systems, 2019, 34(2): 1483-1492.
- [10] 葛少云, 杜咏梅, 郭玥, 等. 基于分布鲁棒优化的车-站-网日前能量管理与交易[J]. 电力系统自动化, 2023, 46(9): 1-16.
GE Shaoyun, DU Yongmei, GUO Yue, et al. Day-ahead energy management and trading of electric vehicle, charging station and distribution network based on distributionally robust optimization[J]. Automation of Electric Power Systems, 2023, 46(9): 1-16.
- [11] LU X, CHAN K, XIA S, et al. Security-constrained multiperiod economic dispatch with renewable energy utilizing distributionally robust optimization[J]. IEEE Transactions on Sustainable Energy, 2019, 10(2): 768-779.
- [12] 丁涛, 贾文皓, 黄雨涵, 等. 基于分布鲁棒机会约束的移动氢能系统制-储-运氢协同优化[J]. 电力系统自动化, 2023, 46(10): 1-13.
DING Tao, JIA Wenhao, HUANG Yuhao, et al. Collaborative optimization for hydrogen generation, storage, and transportation in mobile hydrogen energy systems based on distributionally robust chance constraint[J]. Automation of Electric Power Systems, 2023, 46(10): 1-13.
- [13] 张笑演, 熊厚博, 王楚通, 等. 基于最优出力区间和碳交易的园区综合能源系统灵活经济调度[J]. 电力系统自动化, 2022, 46(16): 72-83.
ZHANG Xiaoyan, XIONG Houbo, WANG Chutong, et al. Flexible economic dispatching of park-level integrated energy system based on optimal power output interval and carbon trading[J]. Automation of Electric Power Systems, 2022, 46(16): 72-83.
- [14] ZHAO C, GUAN Y. Data-driven stochastic unit commitment for integrating wind generation[J]. IEEE Transactions on Power Systems: A Publication of the Power Engineering Society, 2016, 31(4): 2587-2596.
- [15] GAO H, WANG J, LIU Y, et al. An improved ADMM-based distributed optimal operation model of AC/DC hybrid distribution network considering wind power uncertainties[J]. IEEE Systems Journal, 2021, 15(2): 2201-2211.
- [16] 马燕峰, 骆泽榕, 赵书强, 等. 基于改进蒙特卡洛混合抽样的含风光电力系统风险评估[J]. 电力系统保护与控制, 2022, 50(9): 75-83.
MA Yanfeng, LUO Zerong, ZHAO Shuqiang, et al. Risk assessment of a power system containing wind power and photovoltaic based on improved Monte Carlo mixed sampling[J]. Power System Protection and Control, 2022, 50(9): 75-83.
- [17] FEIJO A, VILLANUEVA D. Wind farm power distribution function considering wake effects[J]. IEEE Transactions on Power Systems, 2017, 32(4): 3313-3314.
- [18] 董雷, 孟天骄, 陈乃仕, 等. 采用马尔可夫链-多场景技术的交直流主动配电网优化调度[J]. 电力系统自动化, 2018, 42(5): 147-153.
DONG Lei, MENG Tianjiao, CHEN Naishi, et al. Optimal dispatching of AC/DC hybrid active distribution network using Markov chains and multiple scenarios technique[J]. Automation of Electric Power Systems, 2018, 42(5): 147-153.

- [19] 唐俊熙, 曹华珍, 高崇, 等. 一种基于时间序列数据挖掘的用户负荷曲线分析方法[J]. 电力系统保护与控制, 2021, 49(5): 140-148.
TANG Junxi, CAO Huazhen, GAO Chong, et al. A new user load curve analysis method based on time series data mining[J]. Power System Protection and Control, 2021, 49(5): 140-148.
- [20] 王群, 董文略, 杨莉. 基于 Wasserstein 距离和改进 K-medoids 聚类的风电/光伏经典场景集生成算法[J]. 中国电机工程学报, 2015, 35(11): 2654-2661.
WANG Qun, DONG Wenlüe, YANG Li. A wind power/photovoltaic typical Scenario set generation algorithm based on Wasserstein distance metric and revised K-medoids cluster[J]. Proceedings of the CSEE, 2015, 35(11): 2654-2661.
- [21] CHEN Y, WANG Y, KIRSCHEN D, et al. Model-free renewable scenario generation using generative adversarial networks[J]. IEEE Transactions on Power Systems, 2018, 33(3): 3265-3275.
- [22] 董晓翀, 孙英云, 蒲天骄. 基于条件生成对抗网络的可再生能源日前场景生成方法[J]. 中国电机工程学报, 2020, 40(17): 5527-5536.
DONG Xiaochong, SUN Yingyun, PU Tianjiao. Day-ahead scenario generation of renewable energy based on conditional GAN[J]. Proceedings of the CSEE, 2020, 40(17): 5527-5536.
- [23] 米阳, 卢长坤, 申杰, 等. 基于条件生成对抗网络的风电功率极端场景生成[J]. 高电压技术, 2023, 49(6): 2253-2263.
MI Yang, LU Changkun, SHEN Jie, et al. Wind power extreme scenario generation based on conditional generative adversarial network[J]. High Voltage Engineering, 2023, 49(6): 2253-2263.
- [24] 周长城, 马溪原, 刘育权, 等. 基于合作博弈的工业园区综合能源系统成本分摊及收益分配方法[J]. 南方电网技术, 2018, 12(3): 60-65.
ZHOU Changcheng, MA Xiyuan, LIU Yuquan, et al. Cost sharing and income allocation method of integrated energy system in industrial parks based on cooperative games[J]. Southern Power System Technology, 2018, 12(3): 60-65.
- [25] 芮涛, 李国丽, 王群京, 等. 配电侧多微电网日前电能交易纳什议价方法[J]. 电网技术, 2019, 43(7): 2576-2585.
RUI Tao, LI Guoli, WANG Qunjing, et al. Nash bargaining method for multi-microgrid energy trading in distribution network[J]. Power System Technology, 2019, 43(7): 2576-2585.
- [26] XU J, YI Y. Multi-microgrid low-carbon economy operation strategy considering both source and load uncertainty: a Nash bargaining approach[J]. Energy, 2023, 263.
- [27] CHEN Y, PEI W, MA T, et al. Asymmetric Nash bargaining model for peer-to-peer energy transactions combined with shared energy storage[J]. Energy, 2023, 278.
- [28] CUI S, WANG Y, LIU X, et al. Economic storage sharing framework: asymmetric bargaining-based energy cooperation[J]. IEEE Transactions on Industrial Informatics, 2021, 17(11): 7489-7500.
- [29] SHUAI X, WANG X, WU X, et al. Peer-to-peer multi-energy distributed trading for interconnected microgrids: a general Nash bargaining approach[J]. International Journal of Electrical Power and Energy Systems, 2022, 138.
- [30] 刘科研, 周方泽, 周晖. 基于时序信号图像编码和生成对抗网络的配电网台区数据修复[J]. 电力系统保护与控制, 2022, 50(24): 129-136.
LIU Keyan, ZHOU Fangze, ZHOU Hui. Missing data imputation in a transformer district based on time series imaging encoding and a generative adversarial network[J]. Power System Protection and Control, 2022, 50(24): 129-136.
- [31] YU H, LI Z, ZHANG G, et al. Extracting and predicting taxi hotspots in spatiotemporal dimensions using conditional generative adversarial neural networks[J]. IEEE Transactions on Vehicular Technology, 2020, 69(4): 3680-3692.
- [32] ARTHUR D, VASSILVITSKII S. K-means++ the advantages of careful seeding[C]// Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms, 2007: 1027-1035.
- [33] ZHANG Y, AI Q, XIAO F, et al. Typical wind power scenario generation for multiple wind farms using conditional improved Wasserstein generative adversarial network[J]. International Journal of Electrical Power and Energy Systems, 2020, 114.
- [34] XU Q, HUANG G, YUAN Y, et al. An empirical study on evaluation metrics of generative adversarial networks[J]. arXiv, 2018, 1806.07755.
- [35] LI Y, LI J, WANG Y. Privacy-preserving spatiotemporal scenario generation of renewable energies: a federated deep generative learning approach[J]. IEEE Transactions on Industrial Informatics, 2021, 18(4): 2310-2320.
- [36] 付文杰, 王喻玺, 申洪涛, 等. 基于拉丁超立方抽样和场景消减的居民用户基线负荷估计方法[J]. 电网技术, 2022, 46(6): 2298-2307.
FU Wenjie, WANG Yuxi, SHEN Hongtao, et al. Residential customer baseline load estimation based on Latin hypercube sampling and scenario subtraction[J]. Power System Technology, 2022, 46(6): 2298-2307.

收稿日期: 2023-12-04; 修回日期: 2024-02-19

作者简介:

李虹(1979—), 女, 通信作者, 硕士生导师, 研究方向为新能源电力系统分析与控制; E-mail: lxy.lh@163.com

韩雨萌(2000—), 男, 硕士研究生, 研究方向为微网系统能源优化调度。E-mail: hym2877598344@163.com

(编辑 魏小丽)