考虑源-荷不确定性的电热联合系统分布鲁棒优化调度

刘鸿鹏1,李宏伟1,马建伟1,2,陈继开1,张 伟1

(1. 东北电力大学 电气工程学院 现代电力系统仿真控制与绿色电能新技术教育部重点实验室,吉林 吉林 132012;2. 国家电网有限公司 市场部,北京 100031)

摘要:可再生能源出力及负荷需求的不确定性严重影响电热联合系统的鲁棒优化运行。基于此,提出了一种 改进Wasserstein度量的考虑源-荷不确定性电热联合系统分布鲁棒优化调度模型。建立基于极端场景下改 进Wasserstein度量的风电预测功率模糊集,缩减风电预测功率模糊集的规模,进而提出基于梯度归一化改进 Wasserstein生成对抗网络方法对负荷需求的不确定性进行建模,提高负荷不确定性建模的精度;构建综合考 虑发电成本、调节成本等的分布鲁棒优化调度模型,并基于对偶理论和拉格朗日乘子法将该模型转换成可求 解的数学模型;以修改的9节点系统及IEEE 118节点系统为例验证了所提出的模型具有更高的求解效率以 及更好的经济性和鲁棒性。

关键词:Wasserstein 度量;分布鲁棒优化调度;极端场景;模糊集;生成对抗网络 **中图分类号:**TM732 **文献标志码:**A DOI:10.16081/j.epae.202302008

0 引言

电热联合优化调度为风电资源的消纳提供了有效途径^[1],但是随着大规模风电资源并入电网,其出力的间歇性和不确定性给电热联合系统的鲁棒经济运行带来了巨大挑战。

目前,关于含风电的电热联合系统不确定性相 关研究的方法主要分为随机优化(stochastic optimization,SO)方法^[2]和鲁棒优化(robust optimization, RO)方法^[3]。虽然这2种方法在一定程度上取得了 研究进展,但在处理不确定性问题时仍然具有局限 性。SO主要依据已知的概率分布来建立调度模型, 但在建模中生成的离散场景往往规模巨大并且求解 时间较长,增加了模型的计算负担。RO的原理是将 参数的不确定性约束在一个不确定性集中,与参数 的概率分布无关,但是其仅通过不确定性参数的边 界参数来进行表达,获得的决策结果过于保守。

分布鲁棒优化(distributionally robust optimization, DRO)^[45]因能结合不确定性参数的概率特性和 不确定性的范围而受到广泛关注。DRO 通过已知 的不确定性参数信息,获得满足参数信息的所有概 率分布函数,这使得它能够更好地利用有限的历史 数据,并通过计算所有可能分布的最坏预期来获得 鲁棒决策方案。文献[4]提出了计及气网管存效应 的综合能源系统 DRO 调度模型。文献[5]考虑了基 于 DRO 的可再生能源的不确定性,提出了考虑安全

收稿日期:2022-06-23;修回日期:2022-09-19 在线出版日期:2023-02-17 基金项目:国家自然科学基金资助项目(52077030) Project supported by the National Natural Science Foundation of China(52077030) 约束的多阶段经济调度模型。值得注意的是,DRO 模型的关键是构造合适的模糊集。当前构建模糊集 的方法有很多,例如基于矩信息的模糊集^[5]、基于 Kullback-Leibler(KL)散度的模糊集^[6]等。基于矩信 息构建的模糊集仅仅利用不确定参数的矩信息,而 忽略了相关矩的不确定性,会严重影响决策结果的 适应性。基于KL散度构建模糊集的关键是选择合 适的度量,将无限维凸优化的子问题转化为有限维 凸优化的子问题以加速求解,但是主问题优化依然 包含所有离散场景,其求解过程耗时较长。基于 Wasserstein 度量^[7]的 DRO 模型具有与 RO 相似的求 解效率,且在经济性和保守性之间达到了良好的平 衡。虽然 Wasserstein 度量可以直接通过计算经验分 布和真实分布之间的差异来构造模糊集,但基于 Wasserstein 度量构建的模糊集是无限的,严重影响 了模型的计算效率。为此,文献[8]提出了基于 Wasserstein 度量的鲁棒对等模型近似方法,提高了 模型计算效率。文献[9]提出了一种新的割平面算 法来解决基于 Wasserstein 度量的 DRO 机组组合问 题,以减少模型的计算时间。然而,在DRO模型中 应用新方法的同时,也进一步增加了问题的计算复 杂性。此外,相较于风电功率的不确定性,负荷的波 动性较小。这一特性使得负荷的不确定性建模得到 了广泛的研究。目前,主要通过场景法对负荷不确 定性进行分析处理^[10]。较为常见的方法有蒙特卡罗 模拟法、拉丁超立方采样方法,其主要通过概率分布 来量化生成具有概率特征的多个场景,在各场景下 优化确定性问题,进而计算所有场景下优化结果的 加权平均值来获得最终的优化结果[11]。但是,基于 场景法分析负荷的不确定性问题受负荷的概率分布 函数影响较大。不同地理和环境情况会影响负荷特

进行不确定性建模。GANs不需要预先设置数据的 分布规律,可以直接从典型区域的多能源负荷数据 中学习并生成新的负荷数据样本^[12]。但需要进一步 深入研究如何更好地构建GANs中生成器与鉴别器 的损失函数以期获得理想的负荷需求场景。

综上所述,DRO模型中模糊集的构建和负荷需 求不确定性的精确建模仍然是电热联合系统运行 研究的难点。虽然已经有很多方法可以解决这些 问题,但仍需进一步研究不确定性集的计算效率和 不确定场景集的精准度。为了深入解决这些问题, 本文从不确定性集的构造出发,构建了新型风电 预测功率模糊集,并提出了更为精确的电、热负荷 需求不确定性的场景生成模型,进而构建了两阶段 的分布鲁棒优化调度(distributionally robust optimal dispatching, DROD)模型,以修改的9节点系统和 IEEE 118节点系统为例,分析了本文所提模型和方 法的有效性和优越性。

1 不确定性建模

1.1 风电功率不确定性建模

受地理位置和气象因素的影响,在实际研究中 往往只能获取风电功率的部分信息,导致风电预测 功率与实际风电功率存在较大误差。基于此,本文 建立了基于Wasserstein度量^[8]的风电预测功率的不 确定集。该方法基于采样数据构建初始经验分布, 进而对真实的概率分布进行估计。

本文基于风电功率的历史样本集合 $\{s_1, s_2, \dots, s_N\}(N为样本数), 建立了如下经验分布:$

$$f_{\rm N} = \frac{1}{N} \sum_{i=1}^{N} \xi_{s_i}$$
(1)

式中: f_N 为根据观察样本构建的经验分布; $\xi_s(i=1, 2, \dots, N)$ 为在 s_i 上的Dirac测度, 即 ξ_s 为在 s_i 处的单位点质量。根据大数定律, 随着可获得的数据的增加, 可以证明经验分布 f_N 能收敛至真实分布 f_o

风电预测功率的模糊集可以表示为:

$$\mathcal{P} = \left\{ f \in \mathcal{R}(\Xi) \middle| E_f \Big[W \big(f, f_{\mathrm{N}} \big) \Big] \leq \varepsilon_{\mathrm{w}} \right\}$$
(2)

$$W(f, f_{\rm N}) = \inf \left(d\left(\boldsymbol{\xi}_{\rm w}, \boldsymbol{\tilde{\xi}}_{\rm w}\right) \pi \left(\mathrm{d} \,\boldsymbol{\xi}_{\rm w}, \mathrm{d} \, \boldsymbol{\tilde{\xi}}_{\rm w} \right) \right) \qquad (3)$$

式中: \mathcal{P} 表示以概率分布 f_N 为中心、以 \mathcal{E}_w 为半径的 Wasserstein球; E_f [•]表示求概率分布f的期望值; $W(\cdot, \cdot)$ 表示 Wasserstein距离; ξ_w 、 $\tilde{\xi}_w$ 分别为分布f、 f_N 的随机变量; $\mathcal{R}(\Xi)$ 为所有分布在 Ξ 上的支撑集; $d(\boldsymbol{\xi}_{w}, \boldsymbol{\tilde{\xi}}_{w}) = \|\boldsymbol{\xi}_{w} - \boldsymbol{\tilde{\xi}}_{w}\|$ 表示欧拉范数, $\boldsymbol{\xi}_{w}, \boldsymbol{\tilde{\xi}}_{w}$ 分别为 $\boldsymbol{\xi}_{w}, \boldsymbol{\tilde{\xi}}_{w}$ 的向量表示形式; $\pi(d\boldsymbol{\xi}_{w}, d\boldsymbol{\tilde{\xi}}_{w})$ 表示边缘分布为f和 f_{N} 的联合概率分布, $d\boldsymbol{\xi}_{w}, d\boldsymbol{\tilde{\xi}}_{w}$ 分别为 $\boldsymbol{\xi}_{w}, \boldsymbol{\tilde{\xi}}_{w}$ 的微分 形式; inf(•)表示下确界函数。

依据观测风电功率历史数据建立经验分布,再 根据式(2)和式(3)计算经验分布与随机分布f之间 的Wasserstein距离,进而构建满足条件的风电预测 功率的概率分布f集合,以随机分布f构成的模糊集 合来描述风电功率的不确定性。

1.2 基于极端场景的风电预测功率不确定性建模

基于Wasserstein度量建模的DROD模型可有效 弥补诸如基于矩信息建模、KL建模的缺点。然而, 随着样本集规模的增加,计算负担也会急剧增加。 与此同时,DROD模型试图在最恶劣场景下的概率 分布中做出最优决策以免疫模糊集中的其他分布。

因此,本文建立了风电功率极端场景指标,尽可 能筛选出风电功率在最恶劣场景下的概率分布集, 在不损失决策方案的鲁棒性和经济性的前提下,提 高 DROD 的计算效率。目前,主要有如下2种类型 的极端风电输出功率场景^[13]:风电输出功率为风电 出力最大值或最小值;风电功率的爬坡功率超过了 允许的阈值。对于第一种类型,采用区间优化方 法^[14]来描述*t*时刻风电功率可能的最大值和最小 值,具体如下:

$$\begin{cases} P_{\mathbf{w},t}^{\max} = (1 + \alpha^{u}) P_{\mathbf{w},t}^{WF} \\ P_{\mathbf{w},t}^{\min} = (1 - \alpha^{d}) P_{\mathbf{w},t}^{WF} \end{cases}$$
(4)

式中: P^{max}_{w,t}、P^{min}和P^{wF}分别为t时刻风电功率的最大 值、最小值和预测值; α^{u} 、 α^{d} 分别为风电预测功率概 率分布的上、下分位数。

对于第二种类型, $\hat{a}(t, t+\Delta t)$ 时段内, 风电的爬 坡功率可以表示为:

$$P^{+}_{\operatorname{ramp},t} = P_{w,t+\Delta t} - P_{w,t} > R^{+}_{\operatorname{threshold}}$$

$$P^{-}_{\operatorname{ramp},t} = P_{w,t+\Delta t} - P_{w,t} < -R^{-}_{\operatorname{threshold}}$$
(5)

式中: $P_{ramp,t}^{+}$, $P_{ramp,t}^{-}$ 分别为t时刻风电的向上、向下爬 坡功率值; $P_{w,t}$ 为t时刻的风电功率; $P_{w,t+\Delta t}$ 为 $t+\Delta t$ 时 刻的风电功率; $R_{threshold}^{+}$, $R_{threshold}^{-}$ 分别为风电的向上、向 下爬坡功率阈值。

然后,本文将风电功率的极端场景指标式(4)和 式(5)代入式(2)中,同时引入2个调节参数Λ^u和Λ^d 以调节模型的保守性。建立的改进Wasserstein度量 风电预测功率模糊集如下:

$$\mathcal{P} = \left\{ f \in \mathcal{R} \left(\Xi \right) \middle| E_{f} \left[W \left(f, f_{N} \right) \right] \leq \varepsilon_{w}, \\ \left\{ E_{f} \left[f \right] \geq \Lambda^{u} E \left[P_{w}^{WF} \right] \cup E_{f} \left[f \right] \leq \Lambda^{d} E \left[P_{w}^{WF} \right] \right\}, \\ \left\{ E_{f} \left[f_{k} \right] - E_{f} \left[f_{r} \right] \geq R_{\text{threshold}}^{+} \cup \\ E_{f} \left[f_{k} \right] - E_{f} \left[f_{r} \right] \leq -R_{\text{threshold}}^{-} \right\} \right\}$$

$$(6)$$

式中: Λ^{u} =(1+ α^{u}); Λ^{d} =(1- α^{d}); $E[\cdot]$ 为期望函数; P_{w}^{vr} 为风电预测功率; f_{k} 、 f_{r} 为模糊集中的任意分布。式 (6)的模型含义为筛选出模糊集中具有最大 / 最小 风电功率特征的概率分布,并选出任意两分布期望 值之差超过爬坡阈值特征的概率分布。

1.3 负荷不确定性建模

本文提出基于梯度归一化改进的Wasserstein生成对抗神经网络(gradient normalization Wasserstein GANs, GN-WGANs)生成电、热负荷需求场景集,并进一步采用K-medoids算法获得典型场景。

通过引入 Wasserstein 距离到 GANs 模型中,可 以直接计算 2个不同分布之间的距离,这与 GANs 模 型中 2个神经网络(分别为生成器网络和鉴别器网 络)之间的对抗博弈理论相吻合,其表达式如下:

$$W(D(s_r), D(G(z))) = \sup_{a^0} \left(E_{sr} \left[D(s_r) \right] - E_z \left[D(G(z)) \right] \right)$$

(7)

$$L_{\rm D} = -E_{\rm sr} \left[\ln D(s_{\rm r}; \theta^{\rm D}) \right] - E_{\rm z} \left[\ln \left(1 - D(s_{\rm g}; \theta^{\rm D}) \right) \right] \qquad (8)$$

 $L_{\rm G} = -E_z \Big[\ln \left(1 - D(G(z; \theta^{\rm G}); \theta^{\rm D}) \right) \Big] \tag{9}$

式中: $D(\cdot)$ 、 $G(\cdot)$ 分别表示鉴别器、生成器;z为随机 噪声; s_r 、 s_g 分别为真实样本、生成样本; $sup(\cdot)$ 表示上 确界函数; E_s [·]、 E_s [·]分别表示求所有真实样本的 期望值、生成器所有随机输入样本的期望值; L_p 为鉴 别器的损失函数; θ^p 、 θ^c 分别为鉴别器、生成器网络 参数; L_c 为生成器的损失函数。

诸多研究成果表明,式(7)是相较于GANs更有 效的成本函数,提高了GANs的训练效果,而且便于 调试和超参数搜索^[15]。然而,尽管采用WGANs可 以生成质量较好的场景,但仍需深入探索WGANs的 性能以更精准地对真实分布进行建模。同时,为在 Lipschitz约束和网络容量之间取得良好的平衡,确 保 GANs 模型上的 Lipschitz 约束仍然是一个巨大的 挑战。文献 [16-17] 采用的权重剪枝和正则化允许 网络在更大的函数空间中进行搜索,但是松弛了 Lipschitz约束。文献[18]证明了当层数增加时, 1-Lipschitz约束的Lipschitz常数可能会显著减小。 值得注意的是,这是导致光谱归一化的一个潜在因 素,即当不应用基于梯度的正则化时,GANs无法与 Wasserstein 距离进行积分^[19]。在GANs 训练过程 中,一致的Lipschitz常数可以保证未处理过的数据 的梯度稳定性,因此,认为硬约束的性能要优于软约 束。不同于现有的梯度惩罚(gradient penalty, GP)、 谱归一化等方法,梯度归一化(gradient normalization, GN)方法为鉴别器函数施加了一个硬的1-Lipschitz 约束,即GN的Lipschitz常数不会以神经网络的乘 法形式衰减,它严格约束分段线性网络几乎处处为 1-Lipschitz^[20],从而提升了鉴别器的性能,可以有效 解决基于 GP 和光谱归一化中 Lipschitz 约束问题。 相比于 GP 和光谱归一化, GN 可以同时满足模型级、 非基于采样、硬约束 3 个特性, 并且不会引入额外的 超参数, 可以在梯度范数限制和鉴别器容量之间实 现更好的折中。GN 方法同时规范化梯度和边界的 范数:

$$\hat{L}_{\mathrm{D}}(s) = \frac{L_{\mathrm{D}}(s)}{\left\|\nabla_{s} L_{\mathrm{D}}(s)\right\| + \zeta(s)} \tag{10}$$

式中: $\hat{L}_{D}(s)$ 为 $L_{D}(s)$ 的归一化函数; $L_{D}(s)$ 为 $L_{D}(s)$ 的 向量表达形式; $\nabla_{s}L_{D}(s)$ 为 $L_{D}(s)$ 的梯度; $\zeta(s)$ 为一个 通用项,可以设置为与 $L_{D}(s)$ 相关的函数或常数值。 在本文中,令 $\zeta(s)=L_{D}(s)$ 。因此式(10)可以转化为:

$$\hat{L}_{\mathrm{D}}(s) = \frac{L_{\mathrm{D}}(s)}{\left\| \nabla_{s} \boldsymbol{L}_{\mathrm{D}}(s) \right\| + L_{\mathrm{D}}(s)} \tag{11}$$

在此设置下,当鉴别器由于过拟合出现饱和时, 归一化梯度范数 $\nabla_{s} \hat{L}_{D}(s)$ 接近于0,这种自适应的 控制机制避免生成器产生爆炸梯度,从而稳定了 GANs的训练过程,相关证明见文献[18]。

$$\begin{split} & \mathcal{H} - \mathcal{F} \, \tilde{\mathbf{H}} \, \mathbb{P} \, \hat{\mathbf{J}} \, \tilde{\mathbf{K}} \, \mathbb{R} \, \tilde{\mathbf{S}} \, \tilde{\mathbf{M}}_{k} \, \mathbb{N} \, \mathcal{R} \, \mathbb{P} \, \mathbb{O} \, \mathbb{R} \, \mathbb{P} \, \mathbb{O} \, \mathbb{E} \, \mathbb{E$$

通过推导得到 W_{i} 的梯度,可以看到式(12)的第 一行等号右侧第一项表示GANs目标的梯度,其提 高了鉴别器性能;第二项表示正则化,其基于自适应 正则化系数惩罚 $L_{\rm D}(s)$ 的梯度范数。从式(12)的最 后2行可以看出,GN是自适应梯度正则化的一种特 殊形式。与GP^[21]相比,GN更加灵活,可以根据 GANs损失进行自动调节。

使用经过训练的 GN-WGANs 可以生成不同的 负荷场景。经过训练的 GN-WGANs 用于生成 M个 电、热负荷场景,因此有 M²个组合。随着 M的增大, 组合场景的数量呈指数增长,给模型的计算带来了 巨大复杂性。因此,需要减少场景以提高计算效率。 然而场景太少会导致其缺乏代表性,并影响调度结 果的准确性。聚类方法通常用于场景缩减。与传统 的 K-means 聚类方法相比, K-medoids 方法的聚类中 心是中心样本点,减少了异常数据对聚类效果的影 响,具有更强的鲁棒性。因此,本文使用*K*-medoids方法来减少多种负荷类型的场景,即从原始数 据场景中选择具有明显特征和高概率的场景^[22]。*K*medoids方法的计算步骤见文献[22]。通过采用Davies-Bouldin指数(index of Davies-Bouldin,IDB)^[23]来 确定合适的聚类中心数。设置*K*-medoids方法的聚 类中心数,在聚类过程中得到优化的聚类中心。在 减少多能量负荷场景后,每种类型第k个聚类中心场 景的概率 $\pi_k = M_k/M$,其中 M_k 为第k个聚类中心的场 景数。

削减后的系统电、热负荷需求场景数分别为 S_e 、 S_h ,系统总负荷场景数 $S=S_eS_h$,设电、热负荷场景的概 率分别为 π_e 和 π_h ,在场景 s^* 下的概率 $\pi_s=\pi_e\pi_h$,系统 的负荷场景集合定义为 $C=\{1,2,\dots,s^*,\dots,S\}$ 。

2 考虑源→荷不确定性的电热联合系统DROD 模型构建

本文综合考虑风电功率预测功率以及电、热负荷的不确定性建立了DROD数学模型,其中第一阶段是在考虑可变风电输出功率以及电、热负荷的不确定性场景下制定的日前调度,而第二阶段是在应对所有不确定性后的实时经济调度。所提模型的决策过程如附录A图A1所示。需要说明的是,热电联产(combined heating and power, CHP)机组始终处于开启状态,因此CHP机组没有启动/关闭成本。

2.1 目标函数

DROD模型的数学表达式如下:

$$\min \sum_{s^* \in C} \pi_s \left[\left(\sum_{t \in T} \sum_{i=1}^{N_c} C_{s^*,i}^{\mathrm{G}} \left(P_{s^*,i,t}^{\mathrm{G}}, u_{s^*,i,t}^{\mathrm{G}} \right) + \sum_{t \in T} \sum_{i=1}^{N_{\mathrm{CHP}}} C_{s^*,i}^{\mathrm{CHP}} \left(P_{s^*,i,t}^{\mathrm{CHP}} \right) \right) + \max \left\{ E_s \left[f_{s^*} \left(\mathbf{x}, \tilde{\boldsymbol{\xi}} \right) \right] \right\} \right]$$
(13)

$$\begin{aligned} \max_{P \in \mathcal{P}} \left\{ D_{P} \left[J_{AC}(\boldsymbol{x}, \boldsymbol{\xi}) \right] \right\} \\ f_{AC}(\boldsymbol{x}, \boldsymbol{\tilde{\xi}}) = \min \left\{ \sum_{t \in T} \sum_{i=1}^{N_{c}} c_{G,i} \omega_{s^{*}, i, t}^{G} \right| \Delta P_{s^{*}, t}^{G} \right| + \end{aligned}$$

$$\sum_{t \in T} \sum_{i=1}^{N_{\text{CHP}}} c_{\text{CHP},i} \boldsymbol{\omega}_{s,i,t}^{\text{CHP}} \left| \Delta P_{s,t}^{\text{CHP}} \right| \right\}$$
(14)

$$C_{s,i}^{C}\left(P_{s,i,t}^{G}, u_{s,i,t}^{C}\right) = g_{1,i}\left(P_{s,i,t}^{G}\right)^{2} + g_{2,i}P_{s,i,t}^{G} + g_{3,i} + c_{u,i}u_{s,i,t}^{G} + c_{d,i}\left(1 - u_{s,i,t}^{G}\right)$$
(15)

$$\begin{cases} C_{s,i}^{CHP} \left(P_{s,i,t}^{CHP} \right) = \frac{R_{ng}}{Q_{ng}} \frac{P_{s,i,t}^{CHP}}{\eta_{CHP}} \\ P_{s,i,t}^{CHP} = \eta_{CHP} Q_{ng} F_{s,i,t}^{CHP} \\ H_{s,i,t} = \gamma_{eh} P_{s,i,t}^{CHP} \end{cases}$$
(16)

式中:T为调度时间集合; $C_{s,i}^{c}(\cdot)$ 为场景 s^{*} 下常规机 组i的运行成本(包括燃料成本和启停成本)函数; N_{c} 为常规机组数; $P_{s,i,i}^{c}$ 为场景 s^{*} 下t时刻常规机组i输出 的电功率; $u_{s,i,i}^{c}$ 为0-1变量, $u_{s,i,i}^{c}$ =1表示场景 s^{*} 下t时 刻常规机组*i*启动, $u_{s,i,i}^{c}=0$ 表示场景*s*^{*}下*t*时刻常规 机组*i*停止运行; $C_{s,i}^{CHP}$ (·)为场景*s*^{*}下 CHP 机组*i*的燃 料成本函数; N_{CHP} 为 CHP 机组数; $P_{s,i,i}^{CHP}$, $H_{s,i,i}$ 分别为 场景*s*^{*}下*t*时刻 CHP 机组*i*输出的电功率、热功率; $E_{p}[\cdot]$ 表示求概率分布*P*的期望值; $f_{AC}(\cdot)$ 为第二阶 段目标函数;*x*为第一阶段的变量;*š*表示风电预测 功率的不确定性; $c_{G,i} \sim c_{CHP,i}$ 分别为常规机组*i*、CHP 机 组*i*的调整成本系数; $\omega_{s,i,i}^{C}$, $\omega_{s,i,i}^{CHP}$ 分别为场景*s*^{*}下*t*时 刻常规机组*i*、CHP 机组*i*的参与因子; $\Delta P_{s,i}^{CHP}$ 分 别为场景*s*^{*}下*t*时刻常规机组、CHP 机组可调节的电 功率; $g_{1,i} - g_{3,i}$ 为常规机组*i*的成本系数; $c_{u,i} \sim c_{d,i}$ 分别 为常规机组*i*的启动、关闭成本; R_{ng} 为天然气的购买 成本; Q_{ng} 为天然气的高热值; $F_{s,i,i}^{CHP}$ 为GHP 机组的综合 转换效率; γ_{eh} 为CHP 机组的电热转换比。

2.2 约束条件

求解 DROD 模型还需满足如下约束条件(为了 简化描述,所有约束均为在场景s^{*}下的运行约束,故 下文省略了相关变量的下标s^{*})。

1)功率平衡约束。

$$\sum_{i=1}^{N_{c}} P_{i,t}^{G} + \sum_{i=1}^{N_{CHP}} P_{i,t}^{CHPS} + \sum_{k=1}^{N_{w}} P_{k,t}^{WR} + \sum_{i=1}^{N_{bm}} \sum_{l=1}^{L} P_{i,l,t}^{TR} \mu_{i,l} = P_{t}^{load} \quad (17)$$
$$\sum_{i=1}^{N_{CHP}} H_{i,t} + H_{t}^{EBD} + H_{t}^{HSout} = H_{t}^{load} \quad (18)$$

式中: $P_{i,t}^{\text{CHPS}}$ 为t时刻 CHP 机组i的实际调度功率; $P_{k,t}^{\text{WR}}$ 为t时刻风电机组k的实际调度出力; N_w 为风电机组数; N_{bus} 为系统节点数;L为系统传输线路数; $P_{i,t,t}^{\text{TR}}$ 为t时刻传输线路l流经节点i的功率,若流入节点i则取值为正,流出则取值为负; $\mu_{i,t}$ 为0-1变量, $\mu_{i,t}$ =1表示传输线路l与节点i相连接, $\mu_{i,t}$ =0表示不相连; P_{t}^{load} 为t时刻的电负荷需求; H_{t}^{EBD} 为t时刻电锅炉的 直供热功率; H_{t}^{HSout} 为t时刻储热系统的供热功率; H_{t}^{load} 为t时刻的热负荷需求。

2)线路传输功率约束。

本文采用的是直流潮流方法计算电力网络中的 功率流,其约束如下:

$$\begin{cases} \boldsymbol{P}_{\text{line}} = \boldsymbol{B}_{\text{diag}} \boldsymbol{L}_{\text{line}} \boldsymbol{B}^{-1} \left(\boldsymbol{P}_{t}^{\text{G}} + \boldsymbol{P}_{t}^{\text{CHPS}} + \boldsymbol{P}_{t}^{\text{W}} - \boldsymbol{P}_{t}^{\text{load}} \right) \\ - \boldsymbol{\bar{T}}_{l} \leq \boldsymbol{P}_{\text{line}} \leq \boldsymbol{\bar{T}}_{l} \quad l = 1, 2, \cdots, L \\ \boldsymbol{B}_{\text{diag}} = \text{diag} \left(\frac{1}{x_{1}}, \cdots, \frac{1}{x_{l}}, \cdots, \frac{1}{x_{L}} \right) \end{cases}$$
(19)

式中: P_{line} 为线路功率向量表示形式;B为系数矩阵; x_l 为线路l的电抗; L_{line} 为系统线路节点的连接矩阵; $P_t^G \setminus P_t^{CHPS} \setminus P_t^W \setminus P_t^{load}$ 分别为t时刻常规机组输出功率、 CHP机组输出功率、风电机组输出功率、负荷需求功 率在系统总节点维度下的向量表示形式; \bar{T}_l 为线路l功率上限的向量表示形式。

常规机组、CHP机组、电锅炉、储热系统和热网

)

运行约束见附录B式(B1)-(B12)。

为了减少风电的变量,将风电的不确定性表示 为系统总误差 δ ,其值可由式(20)计算得到。

$$\begin{cases} \tilde{\delta}_{t} = \tilde{\delta}_{t}^{W} \\ \tilde{\delta}_{t}^{W} = \sum_{k=1}^{N_{w}} \left(P_{k,t}^{WF} - P_{k,t}^{WR} \right) \end{cases}$$
(20)

式中: δ_{ι}^{w} 为t时刻总的风电功率预测误差值; $P_{k,\iota}^{wF}$ 为t时刻风电机组k的预测功率。

为应对系统存在的不确定性,常规机组和CHP 机组共同参与调节。

$$\begin{cases} \tilde{\delta}_{t} = \Delta P_{t}^{C} + \Delta P_{t}^{CHP} \\ \tilde{P}_{i,t}^{C} = P_{i,t}^{C} - \omega_{i,t}^{C} \Delta P_{t}^{C} \\ \tilde{C}^{CHP} = D^{CHPS} - C^{CHPS} \\ \tilde{C}^{CHP} = D^{CHPS} - C^{CHPS} \end{cases}$$
(21)

$$\left(-\underline{\delta}_{i}^{G} \leqslant -\omega_{i,t}^{G} \Delta P_{i}^{G} \leqslant \overline{\delta}_{i}^{G}\right)$$

$$(22)$$

$$-\underline{\delta}_{i}^{\text{CHP}} \leqslant -\omega_{i,t}^{\text{CHP}} \Delta P_{t}^{\text{CHP}} \leqslant \overline{\delta}_{i}^{\text{CHP}}$$

$$\left\{ 0 \leqslant \omega_{i,t}^{\text{C}}, \omega_{i,t}^{\text{CHP}} \leqslant 1 \right\}$$

$$(22)$$

$$\begin{cases} 0 \le \omega_{i,t}, \, \omega_{i,t} \le 1 \\ \sum_{i,t} \left(\omega_{i,t}^{G} + \omega_{i,t}^{CHP} \right) = 1 \end{cases}$$
(23)

式中: $\tilde{P}_{i,\iota}^{c}$ 、 $\tilde{P}_{i,\iota}^{CHP}$ 分别为常规机组、CHP机组参与调节 后的输出功率; $\bar{\delta}_{i}^{c}$ 、 $\underline{\delta}_{i}^{c}$ 分别为常规机组的向上、向 下爬坡限值; $\bar{\delta}_{i}^{CHP}$ 、 $\underline{\delta}_{i}^{cHP}$ 分别为CHP机组的向上、向下 爬坡限值。

进一步地,考虑到 $C_i^c(P_{i,t}^c, u_{i,t}^c)$ 是一个非递减二次函数,可以近似为分段线性函数以提高计算效率。 换言之, $C_i^c(P_{i,t}^c, u_{i,t}^c)$ 可以由决策变量 $\varphi_{i,t}$ 替换,满足如下约束:

$$\varphi_{i,i} \geq \vartheta_i^n P_{i,i}^c + u_{i,i}^c v_i^n$$
 (24)
式中: ϑ_i^n, v_i^n 分别为常规机组 i 分段线性近似中第 n
个线性段的斜率、截距。该目标函数不仅可以提高
经济性,而且可以提高决策的可行性。

本文所构建的两阶段 DROD 模型的变换形式及 推导见附录 C。

3 算例分析

3.1 算例描述

本文构建了包含电力网络和供热管网的简化 模型,如附录D图D1所示。9节点系统参数如附录D表D1所示。本文算例采用Intel(R) Core(TM) i5-9300H CPU@2.40 GHz, RAM 16 GB, 64 bit 操作 系统,基于MATLAB 2016结合 CPLEX 12.5 仿真平 台进行仿真实验。

3.2 电、热负荷典型场景生成

GANs的生成器与鉴别器模型的具体参数如附录D表D2所示。本文采用中国东北某地区2016—2020年全年电、热负荷数据作为历史数据样本,分别采用WGANs、基于梯度惩罚的Wasserstein生成对抗神经网络(gradient penalty Wasserstein GANs,

GP-WGANs)和GN-WGANs方法进行场景生成。附录D图D2(a)—(c)展示了3种方法生成电负荷场景时生成器与鉴别器的训练进程。图D2的纵坐标名称 $D(s_{,}) / D(G(z))$ 表示在生成样本为G(z)时鉴别器的输出结果。

由图 D2 的仿真结果可以看出,采用 WGANs、 GP-WGANs 以及 GN-WGANs 方法在训练初期,从鉴 別器中可以很容易地区分生成样本和真实样本。随 着训练的不断加强,它们越来越难以区分。但是可 以发现本文提出的基于 GN-WGANs 方法在训练后 期,其训练效果要明显优于采用 WGANs 和 GP-WGANs 方法,生成样本和真实样本几乎重合,使得 鉴别器难以区分生成样本和真实样本,即生成的数 据场景可以作为真实数据进而作为仿真分析的 依据。

因此,本文采用 GN-WGANs 方法对电、热负荷 需求进行场景生成,生成 32 个电负荷需求场景。场 景数过多会影响模型的计算效率,而场景数过少,计 算时间会减少,但会降低解决方案的精度。因此, IDB 在区间[2,10]中确定了能够平衡求解精度和计 算时间的最小场景数。典型场景数的 IDB 值如附录 D图 D3 所示,结果表明,当场景数为5时,IDB 是最低 的。因此,设置 K-medoids 算法的聚类中心数为5个。 聚类结果如附录 D 图 D4 中粗色线条所示。基于生 成电负荷需求典型场景相同的工作原理,获得热负 荷需求场景如附录 D 图 D5 所示。

3.3 优化调度结果分析

为了对比分析基于极端场景建立的风电预测功 率模糊集对调度结果的影响,本文设置了如下3种 情景:情景1,未考虑极端场景的电热联合系统优化 调度模型;情景2,考虑极端场景的电热联合系统优 化调度模型;情景3,考虑极端场景补集的电热联合 系统优化调度模型。

3.3.1 3种情景对比分析

本节旨在对比分析情景1—3下的仿真结果,验 证本文所提模型的有效性和优越性。将Wasserstein 球的置信水平设置为95%。α⁴和α⁴分别设置为风 电预测功率概率分布的95%分位数和5%分位数。 分别在不同的历史数据规模下对比3种情景下的计 算时间和运行总成本,统计相关仿真结果如图1和 图2所示。

由图1所示的结果可以看出,随着历史数据规 模的逐渐增加,情景1—3下数学模型的数据均会增加,使得3种模型对于风电功率的处理时间会相应 增加。然而根据仿真结果可以看出,虽然3种方法 增加趋势相同,但是情景2下模型的计算时间远少 于其他2种情景下的计算时间。在数据规模达到 50000时,情景1下的计算时间达到90s左右,而情



6

Fig.2 Comparison of total cost among three scenarios

景2下模型的计算时间在20s以内,情景2的计算效 率较情景1提高80%左右,较情景3提高70%左右。 由于模型本身计算过程的复杂性,情景1下模型的 计算时间未必恒等于情景2下模型的计算时间与情 景3下模型的计算时间之和。同时结合图2所示的 仿真结果可知,情景2下的模型在历史数据规模较 小时与情景1下的运行结果有少许差异,而情景3下 模型的计算结果与情景1相同,但是随着历史数据 的规模逐渐增加,情景1和情景2下模型的优化结果 几近相同,情景3下模型表现出较低的运行成本。 以此说明在历史数据规模较小,情景2在筛洗模糊 集的场景时可能会将最差场景落在其补集中,而随 着历史数据规模增大,情景2下模型可以在极少的 计算时间内获得与情景1下模型相同的结果,情景3 下模型通过几十倍于情景2下的计算时间获得了较 低的运行成本,可能导致相对冒险的决策,影响系统 的鲁棒性。

3.3.2 RO、SO和情景2对比分析

为了便于描述,将情景2下的模型命名为EDROD 模型。进一步地,本文引入RO、SO对提出的EDROD 模型进行测试。在基于RO的调度模型中,最大风 电预测误差假定为预测值的20%。在基于SO的调 度模型中,该模型假设随机变量服从历史数据样本 集的经验分布,以使系统总成本最小。同时,本文将 Wasserstein球的置信水平从0至100%进行线性调 整,并对不同历史数据规模下的EDROD模型进行了 仿真,统计了相关仿真结果如附录D图D6所示。由 图可知,在不同的置信水平和不同的历史数据规模 下,EDROD模型的运行结果均在RO和SO的运行 结果之间,实现了RO和SO模型的优化折中。当 Wasserstein球的置信水平设置为0时,由于其模糊 集只包含经验分布,所以此时的模型可以看作是基 于SO的调度模型。同时,当Wasserstein球的置信水 平接近100%时,EDROD模型的成本接近RO模型 的成本,但是仍然比RO模型的成本小。虽然本文 基于极端场景建立了风电预测功率模糊集,但是由 于基于Wasserstein距离建立的模糊集本身是有界 的,使得模糊集中的最坏情况分布没有不确定性集 中的最坏情况保守。

3.4 灵敏度分析

本节旨在研究不同 A^u和 A^d 值对情景 2 下模型 的运行影响。α"从100%分位数至50%按每5%步 长递减;α^d从0至50%分位数按每5%步长递增。 将历史数据规模设置为20000, Wasserstein球的置 信水平设置为95%。统计了相关仿真结果,如附录 D表D3所示。表中, $\Lambda_{0.95}^{"}$ 表示 $\alpha^{"}$ 取到95%分位数, Λ_{005}^{d} 表示 α^{d} 取到 5% 分位数,其他类似。由表可知, 当 Λ^{u} 从 $\Lambda^{\mathrm{u}}_{0.95}$ 至 $\Lambda^{\mathrm{u}}_{0.50}$ 、 Λ^{d} 从 $\Lambda^{\mathrm{d}}_{0.05}$ 至 $\Lambda^{\mathrm{d}}_{0.50}$ 变化时,EDROD 模型的运行成本有些许的上升趋势,这是因为随着 概率分布的分位数的改变,构建的极端场景下的模糊 集中的概率分布随之增多,则筛选出最恶劣概率分 布的概率增加,可以获得相对保守的决策结果,但是 与此同时也降低了 EDROD 模型的计算效率。可以 发现,当 Λ^{u} 和 Λ^{d} 取值分别为 $\Lambda^{u}_{1.00}$ 和 $\Lambda^{d}_{0.00}$ 时,EDROD 模型可以近似看成SO模型,虽然通过较少的计算时 间获得了较低的运行成本,但是可能出现相对冒进 的决策结果;当 Λ^{u} 和 Λ^{d} 取值分别为 Λ^{u}_{050} 和 Λ^{d}_{050} 时, 基于极端场景构建的模糊集还原为原始的模糊集。 因此,EDROD模型可通过调整A^u和A^d值对系统的 鲁棒性和经济性进行取舍。

3.5 IEEE 118节点系统测试

基于样本外的数据研究 EDROD 模型和情景 1 模型(命名为DROD)在实际应用中的性能。在修 改的 IEEE 118 系统上进行了仿真。修改后的 IEEE 118节点系统的拓扑结构和参数见文献[24]。机组 容量范围为20~650 MW,选择其中20台100 MW发 电机作为CHP机组。3座风电场分别在节点17、66 和94连接到该系统。其他数据和参数与修改后的9 节点系统相同。表1展示了通过使用蒙特卡罗模拟 的不同大小样本的样本外数据下的性能,以进一步研 究样本外数据对模型鲁棒性的影响。将Wasserstein 球的置信度设置为95%。RO和SO的参数设置与 3.3.2节相同。将每个优化模型运行20次的平均值 作为模型的计算时间(此处指的是优化模型的整体 计算时间,非CPLEX的求解时间)。从表1中的结果 可以看出, DROD和EDROD都能保证在样本外数据 下的性能,其成本介于RO和SO之间。在计算时间 方面,本文提出的EDROD具有很大的优势。当历史

数据规模达到20000时,DROD模型的计算时间达 到852.078s,而本文提出的EDROD模型的计算时间 小于20s,速度提高了97.86%。

表1 IEEE 118节点系统的仿真结果 Table 1 Simulative results of IEEE 118-bus system

模型	历史数据规模	总成本/\$	计算时间 / s
	1 000	1.3460×10^{7}	10.657
	2000	1.3452×10^{7}	32.042
DROD	3 000	1.3444×10^{7}	70.856
DROD	5000	1.3436×10^{7}	112.274
	10000	1.3423×10^{7}	301.152
	20 000	1.3411×107	852.078
EDPOD	1 000	1.3459×10^{7}	2.981
	2000	1.3450×10^{7}	4.067
	3 000	1.3443×10^{7}	5.156
EDROD	5 000	1.3435×10^{7}	8.976
	10000	1.3423×10^{7}	12.334
	20 000	1.3411×107	18.253
RO		1.347 5×107	16.783
SO		1.3399×10 ⁷	80.652

4 结论

本文提出了一种综合考虑风电预测功率以及负 荷不确定性的电热联合系统 DROD 模型。基于 Wasserstein 度量理论、生成对抗网络理论等对源荷 不确定性进行建模。并综合考虑发电成本、调节成 本等建立了两阶段 DROD 模型,通过仿真算例验证, 得到如下结论:

1)提出的GN-WGANs较传统GANs、GP-WGANs 表现出更好的训练性能,能够更精确地生成负荷需 求场景;

2)提出的 EDROD 模型较 DROD 模型能够以更 高的计算效率获得良好的优化结果;

3)提出的EDROD模型可以实现电热联合系统 在RO及SO模型间的折中,保证了电热联合系统的 鲁棒性和经济性;

4)提出的EDROD模型可通过调整 Λ^{u} 和 Λ^{d} 值对 系统的鲁棒性和经济性进行取舍;

5)通过对一个大规模系统实例中的样本外数据 进行测试,结果表明所提出的EDROD模型具有更高 的计算效率以及更好的鲁棒性和经济性。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

- WANG Cheng, GONG Zhihao, HE Chuan, et al. Data-driven adjustable robust unit commitment of integrated electric-heat systems [J]. IEEE Transactions on Power Systems, 2021, 36 (2):1385-1398.
- [2] ZHANG Zhaosui, SUN Yuanzhang, GAO Wenzhong, et al. A versatile probability distribution model for wind power forecast errors and its application in economic dispatch[J]. IEEE Transactions on Power Systems, 2013, 28(3):3114-3125.

- [3] HUO Da, GU Chenghong, MA Kang, et al. Chance-constrained optimization for multienergy hub systems in a smart city [J].
 IEEE Transactions on Industrial Electronics, 2019, 66 (2): 1402-1412.
- [4]易文飞,卜强生,路珊,等. 计及气网管存效应的综合能源系统 分布鲁棒优化调度[J]. 电力自动化设备,2022,42(6):53-60,83.

YI Wenfei, BU Qiangsheng, LU Shan, et al. Distributionally robust optimal dispatching of integrated energy system considering line pack effect of gas network [J]. Electric Power Automation Equipment, 2022, 42(6):53-60, 83.

 [5]税月,刘俊勇,高红均,等.考虑风电不确定性的电热综合系统 分布鲁棒协调优化调度模型[J].中国电机工程学报,2018,38 (24):7235-7247.
 SHUI Yue, LIU Junyong, GAO Hongjun, et al. A distributio-

nally robust coordinated dispatch model for integrated electricity and heating systems considering uncertainty of wind power [J]. Proceedings of the CSEE, 2018, 38(24):7235-7247.

- [6] LU Xi, CHAN Kawing, XIA Shiwei, 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.
- [7] CHEN Yuwei, GUO Qinglai, SUN Hongbin, et al. A distributionally robust optimization model for unit commitment based on Kullback-Leibler divergence [J]. IEEE Transactions on Power Systems, 2019, 34(3):2190-2204.
- [8] POOLLA B K, HOTA A, BOLOGNANI S, et al. Wasserstein distributionally robust look-ahead economic dispatch[J]. IEEE Transactions on Power Systems, 2021, 36(3):2010-2022.
- [9] ZHENG Xiaodong, CHEN Haoyong. Data-driven distributionally robust unit commitment with Wasserstein metric:tractable formulation and efficient solution method [J]. IEEE Transactions on Power Systems, 2020, 35(6):4940-4943.
- [10] LIU Guodong, XU Yan, TOMSOVIC K. Bidding strategy for microgrid in day-ahead market based on hybrid stochastic / robust optimization [J]. IEEE Transactions on Smart Grid, 2016,7(1):227-237.
- [11] WANG Jianxiao,ZHONG Haiwang,TANG Wenyuan, et al. Optimal bidding strategy for microgrids in joint energy and ancillary service markets considering flexible ramping products [J]. Applied Energy, 2017, 205;294-303.
- [12] WANG Shouxiang, CHEN Haiwen, PAN Zhixin, et al. A reconstruction method for missing data in power system measurement using an improved generative adversarial network [J]. CSEE Journal of Power and Energy Systems, 2019, 39:56-64.
- [13] XU Jian, WANG Bao, SIN Yuanzhang, et al. A day-ahead economic dispatch method considering extreme scenarios based on wind power uncertainty [J]. CSEE Journal of Power and Energy Systems, 2019, 5(2):224-233.
- [14] 罗平,周濠炳,徐林,等.基于区间优化的冷热电联供型多微网 日前优化调度[J].电力系统自动化,2022,46(9):137-146. LUO Ping, ZHOU Haobing, XU Lin, et al. Day-ahead optimal scheduling of multi-microgrids with combined cooling, heating and power based on interval optimization[J]. Automation of Electric Power Systems,2022,46(9):137-146.
- [15] JIANG Congmei, MAO Yongfang, CHAI Yi, et al. Scenario generation for wind power using improved generative adversarial networks[J]. IEEE Access, 2018, 6:62193-62203.
- [16] MARTIN A, SOUMITH C, LÉON B. Wasserstein generative adversarial networks[C]//Proceedings of the 34th International Conference on Machine Learning. Sydney, Australia: ACM, 2017: 214-223.

- [17] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C] //Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, CA, USA: ACM, 2017: 5769-5779.
- [18] WU Yilun, SHUAI Honghan, TAM Z R. Gradient normalization for generative adversarial networks[C]//IEEE International Conference on Computer Vision. Montreal, Canada; IEEE, 2022;6353-6362.
- [19] MIYATO T, KATAOKA T, KOYAMA M, et al. Spectral normalization for generative adversarial networks[EB / OL]. [2022-06-23]. https://arxiv.org/abs/1802.05957.
- [20] VINEETH S B, TRISTAN A, ALLAN J, et al. GraN-GAN: piecewise gradient normalization for generative adversarial networks[C]//IEEE / CVF Winter Conference on Applications of Computer Vision. Waikoloa, HI, USA: IEEE, 2021: 1-20.
- [21] JIANG Congmei, MAO Yongfang, CHAI Yi. Day-ahead renewable scenario forecasts based on generative adversarial networks [J]. International Journal of Energy Research, 2021, 45 (5):7572-7587.
- [22] 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 Wenlue, YANG Li. A wind power / photo-voltaic 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.

- [23] LI Rui, WANG Wei, WU Xuezhi, et al. Cooperative planning model of renewable energy sources and energy storage units in active distribution systems: a bi-level model and Pareto analysis[J]. Energy, 2019, 168:30-42.
- [24] YANG Ming, WANG Mingqiang, CHENG Fenglu, et al. Robust economic dispatch considering automatic generation control with affine recourse process[J]. International Journal of Electrical Power & Energy Systems, 2016, 81:289-298.

作者简介:



刘鸿鹏

刘鸿鹏(1978—),男,教授,博士,主要 研究方向为光伏并网发电技术、微电网技 术、储能与节能技术和电力电子可靠性、电 力系统规划与运行等(E-mail:liu_hp@neepu. edu.cn);

李宏伟(1994—),男,博士研究生,主 要研究方向为电动汽车并网优化调度、电热 联合系统规划与运行、微电网系统优化运行 等(**E-mail**:lihongwei091611@163.com)。

(编辑 李玮)

Distributionally robust optimal dispatching of integrated electricity and heating system considering source-load uncertainty

LIU Hongpeng¹, LI Hongwei¹, MA Jianwei^{1,2}, CHEN Jikai¹, ZHANG Wei¹

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology,

Ministry of Education, School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China;

2. Marketing Department, State Grid Corporation of China, Beijing 100031, China)

Abstract: The robust optimal operation of integrated electricity and heating system is severe affected by the uncertainty of renewable energy output and load demand. On this basis, a distributionally robust optimal dispatching (DROD) model of integrated electricity and heating system based on the improved Wasserstein metric considering the uncertainty of source-load is proposed. The ambiguity set of wind power prediction value based on the improved Wasserstein metric in extreme scenarios is established to reduce the scale of the ambiguity set for wind power prediction value. Furthermore, the improved Wasserstein generative adversarial networks based on gradient normalization is proposed to model the uncertainty of load demand and improve the accuracy of load uncertainty modeling. Then, the DROD model considering generation cost, regulation cost and so on is constructed. And the model is transformed into a solvable mathematical model based on dual theory and the Lagrange multiplier method. Taking the modified 9-bus system and IEEE 118-bus system as the example, it is proved that the proposed model has higher solution efficiency, better economy and robustness.

Key words: Wasserstein metric; distributionally robust optimal dispatching; extreme scenarios; ambiguity set; generative adversarial networks





图 A1 两阶段 DROD 模型 Fig.A1 Two-stage DROD model

附录 B

1) 常规机组运行约束。

$$\underline{P}_{i}^{G} \leq P_{i,t}^{G} \leq P_{i}^{G}$$
(B1)
$$\begin{pmatrix}
P_{i,t-1}^{G} - P_{i,t}^{G} - R_{i,t}^{GD} \leq \underline{\delta}_{i}^{G} \Delta t \\
R_{i,t}^{GD} \leq \underline{\delta}_{i}^{G} \\
P_{i,t}^{G} - P_{i,t-1}^{G} + R_{i,t}^{GU} \leq \overline{\delta}_{i}^{G} \Delta t \\
R_{i,t}^{GU} \leq \overline{\delta}_{i}^{G}$$
(B2)

式中: $\overline{P}_i^G \land \underline{P}_i^G 分别为常规机组的最大、最小出力值限值; R_{i,t}^{GU} \land R_{i,t}^{GD} 分别为常规机组在 t 时刻的向上、向下的旋转备用容量; <math>\overline{\delta}_i^G \land \underline{\delta}_i^G 分别为常规机组的向上、向下爬坡限值。$

2) CHP 机组运行约束。

$$\underline{P}_{i}^{\text{CHP}} \le \underline{P}_{i,t}^{\text{CHP}} \le \overline{P}_{i}^{\text{CHP}} \tag{B3}$$

$$\begin{cases} P_{i,t-1}^{\text{CHP}} - P_{i,t}^{\text{CHP}} - R_{i,t}^{\text{CHPD}} \leq \underline{\delta}_{i}^{\text{CHP}} \Delta t \\ R_{i,t}^{\text{CHPD}} \leq \underline{\delta}_{i}^{\text{CHP}} \\ P_{i,t}^{\text{CHP}} - P_{i,t-1}^{\text{CHP}} + R_{i,t}^{\text{CHPU}} \leq \overline{\delta}_{i}^{\text{CHP}} \Delta t \\ R_{i,t}^{\text{CHPU}} \leq \overline{\delta}_{i}^{\text{CHP}} \end{cases}$$
(B4)

式中: \overline{P}_{i}^{CHP} 、 \underline{P}_{i}^{CHP} 分别为 CHP 机组的最大、最小出力值限值; $R_{i,t}^{CHPU}$ 、 $R_{i,t}^{CHPD}$ 分别为 CHP 机组提供的向上、 向下旋转备用容量; $\overline{\delta}_{i}^{CHP}$ 、 $\underline{\delta}_{i}^{CHP}$ 分别为 CHP 机组向上、向下爬坡限值。

3) 电锅炉运行约束。

$$P_t^{\text{EB}} = \sum_{i=1}^{N_{\text{CHP}}} \left(P_{i,t}^{\text{CHP}} - P_{i,t}^{\text{CHPS}} \right)$$
(B5)

$$H_t^{\rm EB} = \eta^{\rm EB} P_t^{\rm EB} \tag{B6}$$

$$H_t^{\text{EB}} = H_t^{\text{EBD}} + H_t^{\text{HSin}} \tag{B7}$$

式中: P_t^{EB} 为电锅炉在 t 时刻的电消耗功率; H_t^{EB} 为电锅炉在 t 时刻输出的热功率; η^{EB} 为电锅炉的电热转换比; H_t^{HSin} 为储热系统的储热功率。

4) 储热系统运行约束。

$$S_t^{\rm HS} = S_{t-1}^{\rm HS} + \left(\eta_{\rm in}^{\rm HS} H_t^{\rm HSin} - \eta_{\rm out}^{\rm HS} H_t^{\rm HSout}\right) \Delta T$$
(B8)

$$0 \le H_t^{\mathrm{HSin}} \le \eta_{\mathrm{in}}^{\mathrm{HS}} S^{\mathrm{HS}} u_t \tag{B9}$$

$$0 \le H_t^{\text{HSout}} \le \eta_{\text{out}}^{\text{HS}} S^{\text{HS}} \left(1 - u_t \right)$$
(B10)

$$H_t^{\rm HSin} H_t^{\rm HSout} = 0 \tag{B11}$$

式中: S_t^{HS} 为热电厂配置的储热设备在 t 时刻内的储热量; $\eta_{\text{in}}^{\text{HS}} \land \eta_{\text{out}}^{\text{HS}}$ 分别为储热设备的吸热、放热效率; H_t^{HSout} 为储热设备在 t 时刻内的放热功率; S^{HS} 为储热设备的储热容量; u_t 为 0-1 变量。

5) 热网能量流约束。

$$H_{t}^{\text{load}} = \sum_{j} H_{j,t}^{\text{load}} = c^{H} m_{p}^{\text{HS}} \left(T_{p,t}^{S+} - T_{p,t}^{R-} \right)$$
(B12)

式中: $H_{j,t}^{\text{load}}$ 为 t 时刻流入节点 j 对应采暖用户区域的热功率; c^{H} 为水的比热容; m_p^{HS} 为连接换热站的管道 p 的质量流; $T_{p,t}^{S+}$ 、 $T_{p,t}^{R-}$ 为供应网络中管道的入口温度、回流网络中管道的出口温度。

附录 C

为了对 DROD 模型进行分析, 文中提出的 DROD 模型的紧凑形式如下:

$$\min_{\mathbf{x}} \mathbf{c}^{\mathsf{T}} \mathbf{x} + \sup_{\boldsymbol{p} \in \mathcal{P}} E_{\boldsymbol{p}} \left\{ f_{\mathsf{AC}}(\mathbf{x}, \tilde{\boldsymbol{\xi}}) \right\}$$
(C1)

s.t.
$$Ax \leq b$$
 (C2)

s.t.
$$Ex + Fy + G\tilde{\xi} \le f$$
 (C3)

式中: c^{T} 为式(13)的系数;x为第一阶段的决策变量;A、b、E、F、G、f分别为 DROD 模型的系数矩阵或 向量。

由于式(6)中的概率分布是需要优化的变量,因此 DROD 模型包含有限数量的约束和无限数量的变量。用一般的数学方法很难直接求解。为了使提出的 DROD 模型易于处理,基于对偶理论将原始问题式(C1)第二阶段模型转化为对偶形式。

$$\sup_{P \in \mathcal{P}} E_P\left\{L(\boldsymbol{x}, \tilde{\boldsymbol{\xi}})\right\} = \inf_{\boldsymbol{\kappa} \ge 0} \left\{\boldsymbol{\kappa}\boldsymbol{\varepsilon} + \frac{1}{N} \sum_{k=1}^N \sup_{\tilde{\boldsymbol{\xi}} \in \Xi} \left(L(\boldsymbol{x}, \tilde{\boldsymbol{\xi}}) - \boldsymbol{\kappa}(\|\tilde{\boldsymbol{\xi}} - \hat{\boldsymbol{\xi}_k}\|_1)\right)\right\}$$
(C4)

式中: κ为陡度因子。然后引入辅助变量 v_k,式(C4)可以转化为:

$$\inf_{\kappa \ge 0} \kappa \varepsilon + \frac{1}{N} \sum_{k=1}^{N} v_k$$
s.t.
$$\sup_{\tilde{\xi} \in \Xi} \left(L(\boldsymbol{x}, \tilde{\boldsymbol{\xi}}) - \kappa(\left\| \tilde{\boldsymbol{\xi}} - \hat{\boldsymbol{\xi}}_k \right\|_1) \right) \le v_k$$
(C5)

如果 $L(\mathbf{x}, \tilde{\boldsymbol{\xi}})$ 是凸的,则式(C5)中的上确界的最优解必须在任何 κ 的顶点处获得,即 $\boldsymbol{\xi}, \boldsymbol{\xi}$ 或 $\hat{\boldsymbol{\xi}}_{k}$ 。通过将上述结果直接应用到所提出的模型中,最坏情况期望问题的 DROD 可以转换为:

$$\sup_{P \in \mathcal{P}} E_{P} \left\{ L(\mathbf{x}, \tilde{\boldsymbol{\xi}}) \right\} = \left\{ \begin{cases} \inf_{\kappa \geq 0} \kappa \varepsilon + \frac{1}{N} \sum_{k=1}^{N} v_{k} \\ \text{s.t.} \sup_{\underline{\xi} \leq \tilde{\boldsymbol{\xi}} \leq \overline{\xi}} \left(L(\mathbf{x}, \tilde{\boldsymbol{\xi}}) - \kappa(\left\| \tilde{\boldsymbol{\xi}} - \hat{\boldsymbol{\xi}}_{k} \right\|_{1}) \right) \leq v_{k} \end{cases} \right\} = \left\{ \begin{cases} \inf_{\kappa \geq 0} \kappa \varepsilon + \frac{1}{N} \sum_{k=1}^{N} v_{k} \\ \text{s.t.} \left(L(\mathbf{x}, \overline{\boldsymbol{\xi}}) - \kappa(\left| \overline{\boldsymbol{\xi}} - \hat{\boldsymbol{\xi}}_{k} \right|) \right) \leq v_{k} \\ \text{s.t.} \left(L(\mathbf{x}, -\underline{\boldsymbol{\xi}}) - \kappa(\left| \underline{\boldsymbol{\xi}} - \hat{\boldsymbol{\xi}}_{k} \right|) \right) \leq v_{k} \\ \left(L(\mathbf{x}, \left| \underline{\boldsymbol{\xi}} \right| \right) \right) \leq v_{k} \end{cases} \right\}$$
(C7)

可以看到,最坏情况的预期成本已经转化为具有线性目标函数和凸二次约束的易于处理的确定性公式 (C7)。然而,问题式(C7)有一个显著的计算缺点:辅助变量和二次约束的数量与历史样本集的大小成正比。 若当下数据集较大时,较大的计算负担可能会影响对历史数据的充分利用。为了解决上述问题,将拉格朗日 乘子λ和 *u* 引入式(C7),式(C7),可以重新表示为:

$$\inf_{\substack{\kappa \ge 0\\ \kappa \ge 0}} \kappa \varepsilon + \lambda \overline{\xi} - u \underline{\xi} + \frac{1}{N} \sum_{k=1}^{N} \left(L(\boldsymbol{x}, \left| \hat{\boldsymbol{\xi}}_{k} \right|) + (\lambda - u) \hat{\boldsymbol{\xi}}_{k} \right)$$
s.t. $\|\lambda - u\| \le \kappa$
 $\lambda, u, \kappa \ge 0$
(C8)

式(C8)的证明详见参考文献[18]。可以发现,变换后的式(C8)是一个混合整数线性规划问题,其约束不会随着样本集大小的增加而改变。因此,式(C8)相较于式(C7)可以通过商业求解器 CPLEX 更有效地求解。



附录 D

图 D1 电热联合系统结构简化图

Fig.D1 Simplified structure diagram of the combined heat and power system

Table D1 Branch data of 9-bus system						
支路起点	支路终点	支路阻抗	支路起点	支路终点	支路阻抗	
1	7	j0.0576	5	7	0.017+j0.092	
2	8	j0.0625	5	9	0.032+j0.161	
3	9	j0.0586	6	8	0.0119+j0.072	
4	7	0.01+j0.085	6	9	0.0119+j0.101	
4	8	0.032+j0.161				
まのころも時間は均						

表 D1 9 节点系统支路数据 Table D1 Branch data of 9-bus system

表 D2 GANs 模型结构 Table D2 GANs model structure

网络属性	生成器	鉴别器
输入	100	24*24
第一层	MLP, 2048	Conv_Layer, 64
第二层	MLP, 1024	Conv_Layer, 128
第三层	MLP, 128	MLP, 1024
第四层	Conv_trans, 128	MLP, 128
第五层	Conv_trans, 64	

注: MLP 为多层感知器,后面数字为神经元数量; Conv_Layer 和 Conv_trans 分别表示为卷积层和反卷积层,后面数字为滤波器数量,该文采用 Sigmoid 函数来约束鉴别器模型的输出。



Fig.D3 IDB value of typical scenes



图 D6 RO、EDROD、SO 在不同历史数据规模及不同 Wasserstein 半径置信水平下运行成本对比 Fig.D6 Comparison of operating costs of RO, EDROD and SO under different historical data scales and different confidence levels of Wasserstein radius

表 D3 不同 Л^u 和 Л^d 值下运行结果

Table D3 Operation results of different Λ^{u} and Λ^{d}						
调节参数	$\Lambda^{\mathrm{u}}_{\mathrm{1.00}}$	$\Lambda^{\mathrm{u}}_{0.95}$	$\Lambda^{\mathrm{u}}_{0.90}$	$\Lambda^{\mathrm{u}}_{0.85}$	$arLambda_{0.80}^{ m u}$	$\Lambda^{\mathrm{u}}_{0.75}$
	$\Lambda^{ m d}_{ m 0.00}$	$\Lambda^{ m d}_{0.05}$	$\Lambda^{\mathrm{d}}_{0.10}$	$\Lambda^{ m d}_{0.15}$	$arLambda_{0.20}^{ m d}$	$\Lambda^{\mathrm{d}}_{0.25}$
总成本(107\$)	1.7514	1.7555	1.7555	1.7555	1.7557	1.7557
计算时间(s)	7.224	8.268	13.620	19.977	24.125	29.326
调节参数	$arLambda_{0.70}^{ m u}$	$arLambda_{0.65}^{ m u}$	$\Lambda^{\mathrm{u}}_{0.60}$	$\Lambda^{\mathrm{u}}_{0.55}$	$arLambda_{0.50}^{ m u}$	
	$\Lambda^{ m d}_{0.30}$	$\Lambda^{ m d}_{0.35}$	$\Lambda^{ m d}_{ m 0.40}$	$arLambda_{0.45}^{ m d}$	$arLambda_{0.50}^{ m d}$	
总成本(107\$)	1.7557	1.7559	1.7559	1.7559	1.7559	
计算时间(s)	35.262	40.102	46.865	50.253	55.690	

注: $A_{0.95}^{u}$ 表示 α^{u} 取到 95%分位数, $A_{0.05}^{d}$ 表示 α^{d} 取到 5%分位数,依此类推。