引用格式:郭创新,陈坤,林雨眠,等.考虑电动汽车接入的园区综合能源系统数据驱动分布鲁棒调度方法[J].电力科学与技术学报,2026,41(4):223-234.
Citation: Guo Chuangxin, Chen Kun, Lin Yumian, et al. Data-driven distributionally robust scheduling method for park-level integrated energy system considering electric vehicle integration[J]. Journal of Electric Power Science and Technology,2026,41(4):223-234.

考虑电动汽车接入的园区综合能源系统数据驱动分布鲁棒调度方法

郭创新[1],陈　坤[1],林雨眠[1],熊厚博[1],燕　磊[1],杜力伟[2]
(1.浙江大学电气工程学院,浙江 杭州 310027;2.国网福建省电力有限公司福州供电公司,福建 福州 350116)

摘　要:可再生能源出力的波动与电动汽车(electric vehicle, EV)的数量日益增长,其随机的充电需求带来的源荷双侧不确定性显著影响了园区综合能源系统(park-level integrated energy system, PIES)的调度计划。为提升PIES运行的经济性和鲁棒性,提出考虑电动汽车接入的园区综合能源系统数据驱动分布鲁棒调度方法。首先,由于EV的接入不确定性难以准确描述,选取EV充电行为的5个特征,通过高斯混合模型刻画EV充电多模式行为,结合Neyman抽样与综合范数约束构建不确定集;其次,设计延时与错峰协同的充电管理方案,在满足用户充电需求的前提下实现削峰填谷;再次将EV充电管理纳入PIES经济调度框架,构建数据驱动的分布鲁棒优化(distributionally robust optimization, DRO)模型;最后,提出改进列与约束生成算法求解DRO调度问题。算例分析表明,所提的延时充电管理实现PIES电负荷曲线平滑化,显著提升可再生能源消纳率,降低外购电依赖;同时,所提方法相较于常规两阶段鲁棒优化模型总成本降低10.26%,验证其可行性与经济性,为EV高渗透下的PIES的高效调度提供新路径。

关　键　词:园区综合能源系统;电动汽车;充电管理;数据驱动;分布鲁棒优化
DOI:10.19781/j.issn.1673-9140.2026.04.018　　**中图分类号**:TM73　　**文章编号**:1673-9140(2026)04-0223-12

Data-driven distributionally robust scheduling method for park-level integrated energy system considering electric vehicle integration

Guo Chuangxin[1], Chen Kun[1], Lin Yumian[1], Xiong Houbo[1], Yan Lei[1], Du Liwei[2]
(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China; 2. Fuzhou Power Supply Company, State Grid Fujian Electric Power Co., Ltd., Fuzhou 350116, China)

Abstract: Fluctuations in renewable energy output and the growing and stochastic electric vehicle (EV) charging demand introduce source- and load-side uncertainties that significantly affect the scheduling plan of the park-level integrated energy system (PIES). To improve the economy and robustness of PIES operation, this paper proposes a data-driven distributionally robust scheduling method for PIES considering EV integration. First, given that the uncertainty associated with EV integration is difficult to characterize accurately, five features of EV charging behavior are selected. A Gaussian mixture model is used to characterize the multimodal behavior of EV charging, and an uncertainty set is constructed by combining Neyman sampling with comprehensive norm constraints. Second, a coordinated delayed and staggered charging management scheme is designed to achieve peak shaving and valley filling while meeting users' charging requirements. Then, EV charging management is incorporated into the economic scheduling framework of PIES to construct a data-driven distributionally robust optimization (DRO) model. Finally, an improved column-and-constraint generation algorithm is proposed to solve the DRO scheduling problem. The case study results show that the proposed delayed charging management scheme smooths the PIES electric load curve, significantly increases the

收稿日期:2025-11-20;**修回日期**:2026-01-27
基金项目:国家自然科学基金联合基金集成项目(U24B600017)
通信作者:林雨眠(2000—),男,博士研究生,主要从事电力系统调度优化、优化算法方面的研究;E-mail:12410107@zju.edu.cn

renewable energy accommodation rate, and reduces dependence on purchased electricity. Meanwhile, compared with a conventional two-stage robust optimization model, the proposed method reduces the total cost by 10.26%, verifying its feasibility and economic efficiency and providing a new pathway for efficient PIES scheduling under high EV penetration.

Key words: park-level integrated energy system; electric vehicle; charging management; data-driven; distributionally robust optimization

为应对环境变化加剧、世界能源转型等能源格局变化,在双碳战略目标指引下,中国正致力于清洁低碳安全高效的新型能源体系建设[1]。园区综合能源系统(park-level integrated energy system,PIES)能够实现能源的互补与耦合,有效提升能源利用效率和可再生能源消纳水平[2-4]。与此同时,随着电动汽车(electric vehicle,EV)技术发展,EV可作为重要的资源参与PIES运行,位于中国湖南省汨罗市的PIES通过建设固定和移动式充电装置,初步实现了源荷储充的协同运行[5],德国的EUREF能源系统实现交通-建筑-电力多能协同运行[6]。尽管EV已经被纳入PIES调度中,但其作为灵活性资源参与PIES调度的潜力尚未得到充分挖掘。

在灵活性资源参与PIES需求响应及优化调度方面,文献[7]综合考虑了电、热、气负荷的可调范围,发挥了需求侧资源的灵活调度能力,降低了运行成本。进一步地,文献[8]在需求响应方面设置动态能源价格机制,提出了PIES双层优化配置模型,降低了园区的运行成本与弃风弃光率。文献[9]研究不同时间段的负荷响应能力,提出了价格引导策略,以增强PIES在不同时段的调节能力。文献[10-11]则在此基础上,考虑了多种负荷之间的替代,进一步扩大了需求侧的调节空间。然而,目前的大多数PIES研究主要通过园区内部资源提升系统整体的灵活性,对EV这一类新型负荷的关注仍有不足,难以充分协调常规用户侧的调度与EV充电需求的冲突。因此,为实现PIES高效运行,不仅应考虑用户侧的用能情况,还须进一步考虑EV的负载特性。

对EV负载特性与充电管理,文献[12]将EV集群建模为广义储能,并通过两阶段可调度潜力评估模型分析其调度容量。文献[13]通过几何多面体模型描述了EV的功率和能量调度范围。基于获得的EV可调节范围,文献[14]将EV建模为移动储能资源,并纳入博弈模型,提高了多方综合经济效益及可再生能源消纳能力。尽管这些研究对EV的充电行为进行了刻画,但多将其建模为实体储能并执行相应的管理措施,忽视了EV用户的充电行为,难以充分保障EV的实际充电需求。文献[15]提出了一种车-桩信息融合的双层聚类模型,实现其可调度容量评估。进一步地,文献[16-18]提出了一种EV灵活性聚合及解聚方法,实现EV灵活参与配电网调度。但由于EV充电行为表现为复杂的时空不确定性,因此通过聚合-解聚进行精准追踪较为困难。

文献[19-20]采用蒙特卡洛法对EV用户出行行为的不确定性进行采样,降低了用户成本的同时提升IES的运行经济性。文献[21]通过区间数学方法描述风电与EV的不确定性,提高IES的灵活性。文献[22]在利用模糊理论刻画EV不确定性的基础上进行了PIES优化调度,实现了PIES经济性的小幅改善;文献[23]考虑N-1故障状态,搭建了计及EV和可再生能源出力不确定性的EV-IES日前鲁棒优化模型;文献[24-26]考虑IES的负荷、可再生能源及EV充电需求的多重不确定性,构建了IES鲁棒运行模型。尽管这些研究对EV参与IES优化调度进行了探讨,但仅通过蒙特卡洛、模糊理论、鲁棒优化等方法模拟,对EV充电行为的不确定性刻画不足,难以获得更加精确的运行信息。

随着新型电力系统的发展以及充电桩的广泛部署应用,已积累了充足的历史数据,可通过数据驱动的手段对其运行状态进行更为精准的刻画。文献[27-28]利用历史数据构建配电网随机优化调度模型,获得更经济的调度策略。而随机优化问题往往伴随着维数爆炸等问题,文献[29-31]进一步采用数据驱动方法,构建了IES的优化调度模型,更高效地使用历史数据。然而,尽管数据驱动的方法在配电网优化调度、IES经济低碳运行等方面表现出了显著效果,但其在刻画EV充电行为中尚未体现。

综上所述,本文提出一种考虑EV接入不确定性的PIES数据驱动优化调度模型,本文的创新点如下:

1)采用高斯混合模型-Neyman抽样的混合数据驱动方式刻画EV的充电场景,并在尊重EV充电特

性的前提下提出一种延时充电方案，高效管理EV充电行为，实现削峰填谷；

2）将EV充电行为管理纳入PIES经济调度问题中，并进一步地将可再生能源出力、EV充电等用能场景转化为可应用的不确定集形式，构建考虑EV不确定性与可再生能源协调的数据驱动PIES分布鲁棒优化模型；

3）将分布鲁棒中的不确定集转化为易求解的形式，进一步地将整个模型重构为一个三层优化问题，引入改进的列与约束生成算法，求解PIES两阶段优化调度问题。通过算例分析验证了本文所提模型和算法的有效性。

1　EV充电行为建模与管理

不同于PIES中的常规负荷，EV充电需求不仅受到接入数量、到达和离开行为、充电功率与时长的影响，还受到PIES运营商的管理，表现出复杂的时间-功率耦合关系。因此，本文采用高斯混合模型（gaussian mixture model，GMM）与Neyman抽样的融合数据驱动方法建模EV充电行为，并提出延时与错峰充电管理方案进行协调。

1.1　EV充电行为GMM模型

EV充电是由用户行为偏好主导的用能行为，其受到多种社会因素的影响[32]。本文选取充电量、平均充电功率、开始充电时间、充电时长及可调度时间区间5个指标作为EV充电行为的特征数据。但由于其存在量纲差异、测量误差等数据质量问题，因此通过缺失与异常值处理、归一化等手段进行数据清洗与预处理。值得注意的是，对于样本中的充电时间和可调度时间区间这两类信息，可通过sin/cos编码表示。

清洗数据后，EV的充电行为可由包含充电量、平均充电功率、开始充电时间、充电时长以及可调度时间区间的样本$\boldsymbol{x}$描述。由于实际充电模式呈现显著的多样性，例如下班集中慢充、上午临时补电、夜间长时慢充等多种行为类型，其整体充电行为分布可视为由多种潜在模式叠加形成的混合分布。而GMM能够通过多个高斯成分的线性组合，对多种模式叠加形成的混合分布进行刻画。对于任意一个样本$\boldsymbol{x}$，其GMM概率密度函数$P(\boldsymbol{x})$为

$$P(\boldsymbol{x})=\sum_{k=1}^{|K|}\lambda_k\mathcal{N}\left(\boldsymbol{x}|\boldsymbol{\Theta}_k\right) \tag{1}$$

$$\lambda_k\geqslant 0,\ \sum_{k=1}^{|K|}\lambda_k=1 \tag{2}$$

式中，$|K|$为高斯成分数量；λ_k为GMM中第k个成分的权重；$\mathcal{N}(\cdot)$为样本数据$\boldsymbol{x}$的高斯概率密度函数；$\boldsymbol{\Theta}_k=\left(\boldsymbol{\mu}_k,\boldsymbol{\Sigma}_k\right)$为第$k$个成分的GMM参数矩阵，$\boldsymbol{\mu}_k$为第$k$个成分的均值向量，$\boldsymbol{\Sigma}_k$为第$k$个成分的协方差矩阵。

GMM对EV充电行为建模准确程度不仅与参数$\boldsymbol{\Theta}_k$有关，还与选定的最优混合成分数$|K|$相关。常规的K-means、K-means＋＋等聚类方法先确定聚类数量，再进行参数估计[33]，但这会损失估计精度。因此，本文提出一种基于期望最大化（expectation maximization，EM）的参数-成分数联合估计方法，具体步骤可分为5步。

1）选定一个初始混合成分数$|K|$与混合成分迭代步长与最大混合成分数，定义赤池信息量准则ω_A与贝叶斯信息量准则ω_B两个最优指标：

$$\omega_A=2p-2\log\mathcal{L}\left(\hat{\boldsymbol{\Theta}}\right) \tag{3}$$

$$\omega_B=p\ln|N|-2\log\mathcal{L}\left(\hat{\boldsymbol{\Theta}}\right) \tag{4}$$

$$\mathcal{L}=\sum_{i=1}^{|N|}\log\left(\sum_{k=1}^{|K|}\lambda_k\cdot\mathcal{N}\left(\boldsymbol{x}_i|\boldsymbol{\Theta}_k\right)\right) \tag{5}$$

式中，$|N|$为样本数量；p为模型参数数量；$\mathcal{L}\left(\hat{\theta}\right)$为最优参数组合$\hat{\theta}$下的最大似然值。

2）计算第i个样本属于第k成分的后验概率γ_{ik}：

$$\gamma_{ik}=\frac{\lambda_k\mathcal{N}\left(\boldsymbol{x}_i|\boldsymbol{\Theta}_k\right)}{\sum_{k=1}^{|K|}\lambda_k\mathcal{N}\left(\boldsymbol{x}_i|\boldsymbol{\Theta}_k\right)} \tag{6}$$

3）利用步骤2）给出的后验概率，更新GMM参数λ_k^{new}、$\boldsymbol{\mu}_k^{\text{new}}$和$\boldsymbol{\Sigma}_k^{\text{new}}$，计算公式如下：

$$\lambda_k^{\text{new}}=\frac{1}{|N|}\sum_{i=1}^{|N|}\gamma_{ik} \tag{7}$$

$$\boldsymbol{\mu}_k^{\text{new}}=\frac{\sum_{i=1}^{|N|}\gamma_{ik}\boldsymbol{x}_i}{\sum_{i=1}^{|N|}\gamma_{ik}} \tag{8}$$

$$\boldsymbol{\Sigma}_k^{new}=\frac{\sum_{i=1}^{|N|}\gamma_{ik}\left(\boldsymbol{x}_i-\boldsymbol{\mu}_k^{new}\right)\left(\boldsymbol{x}_i-\boldsymbol{\mu}_k^{new}\right)^T}{\sum_{i=1}^{|N|}\gamma_{ik}} \tag{9}$$

4）将步骤3）更新后的GMM参数带入到步骤2）中，直至式（5）所示的GMM对数似然函数收敛为止；否则，继续进行迭代。

5）将步骤4）获得的最优参数组合$\hat{\boldsymbol{\Theta}}$代入式（3）、（4），计算$\omega_A$和$\omega_B$指标，并对混合成分数步进迭代

步长数，回到步骤2）。当达到最大混合成分数后，获得ω_A和ω_B关于混合成分数$|K|$的关系，选取其中拐点对应的混合成分数与对应的最优参数组合$\hat{\boldsymbol{\Theta}}$，即得到最优的GMM模型。

1.2 EV充电行为不确定集

GMM给出了每个样本$\boldsymbol{x}$的连续概率分布，但难以嵌入PIES优化调度问题中，且由于样本数据存在偏差等问题，获得的GMM模型难以涵盖全部的EV充电行为分布。因此，本文采用基于Neyman抽样的采样技术，并提出基于1-范数约束和∞-范数约束构建的不确定集，以实现EV充电行为概率分布的嵌入与不确定性表征。

Neyman抽样是一种分层抽样方法，通过抽取每个层的样本以构建典型有限场景。本文利用GMM模型中每个成分k作为抽样层，其每层分配的样本数量计算方式为

$$n_k=|N_s|\cdot\frac{|N_k|\cdot S_k}{\sum_{j=1}^{|K|}|N_j|S_j} \tag{10}$$

式中，n_k为在第k层即成分k中抽取的样本数；$|N_s|$为计划抽取的样本总数；$|N_k|$为第k层中的个体总数；σ_k为第k层的标准差，其计算方式为

$$\sigma_k=\sqrt{\frac{1}{|N_k|-1}\sum_{\boldsymbol{x}_i\in N_k}(Y_i-\bar{Y}_i)^2} \tag{11}$$

式中，$Y_i=q(\boldsymbol{x}_i)$为第k层样本x_i中各指标的线性组合；$\bar{Y}_i$为历史数据指标的线性组合。

在确定每层的抽样数量后，按照简单随机不放回方案在每层内进行抽样，筛选出有限的N_s个样本，对应包含5种指标的EV充电行为场景，该场景s的初始概率p_s^0被初始化为$1/|N_s|$。但这些场景样本可以作为PIES模拟运行场景，以构建两阶段随机规划（stochastic programming，SP）问题。但一方面，这仅表示EV充电行为历史数据中的有限场景，难以表示全部潜在分布情况；另一方面，尽管增加抽样数量$|N_s|$可以获得更精准的分布情况，但这也会导致维度爆炸，使优化问题不可行。因此，本文提出一种包含1-范数约束和∞-范数约束的综合范数约束的不确定集[34]，描述EV充电行为更准确的分布情况：

$$\Omega=\begin{cases}\sum_{s=1}^{|N_s|}p_s=1,\ p_s\geqslant 0,\ s=1,2,\cdots,|N_s|\\ \sum_{s=1}^{|N_s|}|p_s-p_s^0|\leqslant\theta_1 m,\ \max\limits_{1\leqslant s\leqslant N_s}|p_s-p_s^0|\leqslant\theta_\infty\end{cases} \tag{12}$$

式中，Ω为综合范数约束下场景概率值的可行域；p_s为场景s的待求概率值。

其中参数ρ_1和ρ_∞可通过下式求解：

$$\begin{cases}\rho_1=\dfrac{1}{2}\ln\dfrac{2|N_s|}{1-\alpha_1}\\ \rho_\infty=\dfrac{1}{2|N_s|}\ln\dfrac{2|N_s|}{1-\alpha_\infty}\end{cases} \tag{13}$$

式中，α_1、α_∞分别为1-范数和∞-范数约束中的置信度，本文均取0.95。

求解得到的ρ_1和ρ_∞分别表示综合范数不确定集中基于1-范数和∞-范数的最大允许偏差。

1.3 延时与错峰充电管理方案

尽管通过GMM模型获得不确定集可以表示EV充电行为的时间-功率耦合关系，但EV充电行为也受到PIES运营商管理。PIES运营商基于EV充电行为数据，将其分解为多组具有相同延时时长的EV，该延时时长不是随机或任意确定的，而是由PIES运营商求解多能互补优化调度计划得到的，并将延时与错峰充电方案反馈给EV用户。该EV充电行为延时管理模型表示为

$$P_t^{\mathrm{EV}}=\sum_{e\in\mathcal{E}}\sum_{d=0}^{d_{\max}}z_{e,d}P_{e,t-d}^{\mathrm{EV}} \tag{14}$$

式中，$\mathcal{E}$为所有接入PIES的EV分组；$P_{e,t}^{\mathrm{EV}}$为第e组EV的充电负荷；$z_{e,d}$为0-1变量（$z_{e,d}=1$，则第e组EV选择延时充电d个时段，否则，$z_{e,d}=0$）；$P_{e,t-d}^{\mathrm{EV}}$为第e组延充EV延时d个时段后的负荷；$d_{\max}$为最大可延时时间，其取值由EV离开时段和所需充电时长共同确定。

此外，每组EV只能选择一个延时，即

$$\sum_{d=0}^{d_{\max}}z_{e,d}=1 \tag{15}$$

延时充电策略将在较长时间尺度内降低PIES负荷峰谷差，但其效果仍有限，还须与EV错峰充电管理策略配合。定义负荷高峰时段t_{peak}为16:00—23:00，低谷时段$t_{\mathrm{non\text{-}peak}}$为00:00—08:00。理想的EV充电应避开负荷高峰段，仅在低谷段充电，以减小系统峰谷差。因此，将EV充电负荷划分为非高峰时段和高峰时段接入负荷，分别进行延时管理与错峰管理。但值得注意的是，即使是在高峰时段，部分EV用户的充电行为仍是即时且刚性的，无法进行错峰充电管理。因此，本文将高峰时段t_{peak}内的EV充电负荷分为即时充电负荷和延时充电负荷以进行分别管理。当EV用户到达PIES时的荷电状态$S_{e,t}$低于充电阈值S_{th}时，为即时充电；否则，为延

时充电负荷。即时充电负荷为

$$P_{e,t}^{\mathrm{EV}im}=\begin{cases}\sum_{e\in\mathcal{E}}P_{e,t}^{\mathrm{EV}}, & t=t_{\text{non-peak}}\\ \sum_{e\in\mathcal{E}}\Pr(S_{e,t}\leqslant S_{\mathrm{th}})P_{e,t}^{\mathrm{EV}}, & t=t_{\text{peak}}\end{cases}\tag{16}$$

式中，$P_{e,t}^{\mathrm{EV}im}$为即时充电负荷；$\Pr(\cdot)$为事件概率算子；$P_{e,t}^{\mathrm{EV}}$为无管理下t时段的EV接入负荷；$S_{e,t}$为在t时段接入PIES的EV的荷电状态；S_{th}为EV的充电阈值。

以某日到达PIES的EV充电功率分布为例，进行延时充电管理，仅将负荷高峰时段的EV转移到负荷低谷时段，延时充电管理后的EV充电功率曲线如图1所示。其余时段的EV充电功率与无序充电模式的一致，说明该时段所有EV都可在到达时立即充电。

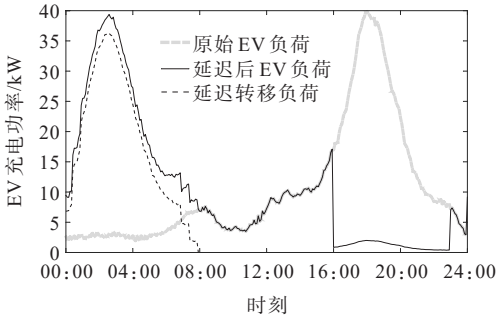

图1　延时充电管理后的EV充电曲线

Figure 1　EV charging curve after delayed charging management

获得即时充电负荷后，进行延时与错峰充电管理后的EV充电负荷为

$$P_t^{\mathrm{EV}}=\sum_{e\in\mathcal{E}}P_{e,t}^{\mathrm{EV}im}+\sum_{e\in\mathcal{E}}\sum_{d=d_{\min}}^{d_{\max}}\gamma_{e,d}P_{e,t-d}^{\mathrm{EV}d}\tag{17}$$

式中，$P_{e,t-d}^{\mathrm{EV}d}$为第e组EV延时d个时段的延充负荷；$d_{\min}$为避开负荷高峰的最小延时。

另外，错峰充电策略也需满足式(15)。最后，为保证延时充电不影响第二天使用，在t_{end}时段前必须完成充电，即

$$\sum_{d=0}^{d_{\max}}\gamma_{e,d}P_{e,t-d}^{\mathrm{EV}d}\leqslant 0,\quad t-d\geqslant t_{\mathrm{end}}\tag{18}$$

2　PIES运行模型

2.1　PIES运行框架

本文所提PIES框架如图2所示。PIES中的常规电负荷与EV充电负荷由热电联产机组(combined heat and power，CHP)、风电机组(wind turbine，WT)、光伏机组(photovoltaics，PV)供给。其中，缺额可向上级电网购电满足，热负荷则由CHP机组、电热锅炉(electric boiler，EB)供给，气负荷由上级气网供给。同时，为平抑PIES内的功率不平衡，配置相应的电池储能系统(battery energy storage system，BESS)，增强系统运行灵活性。

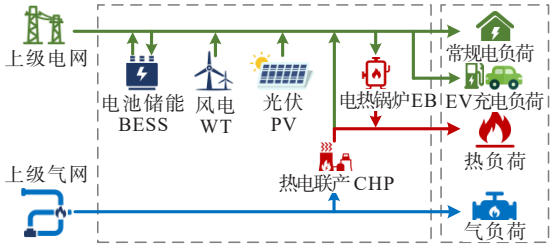

图2　PIES框架

Figure 2　Framework of PIES

由于PV和WT出力以及EV充电的不确定性，本文引入两阶段框架进行管理。在第一阶段，基于对PV和WT出力的预测值，考虑CHP机组等设备的启停、各设备出力以及系统功率平衡等约束，构建以运行成本最小的优化调度问题；在第二阶段，当系统内各不确定性取定后，通过调整机组出力、PV和WT的消纳量以满足常规负荷与EV充电负荷。所构建的两阶段问题为

$$\begin{cases}\min\limits_{\boldsymbol{x}} f(\boldsymbol{x})+\max\limits_{\boldsymbol{\xi}} g(\boldsymbol{x},\boldsymbol{\xi})\\ \text{s.t. } A(\boldsymbol{x})\leqslant 0\\ \quad g(\boldsymbol{x},\boldsymbol{\xi})=\min\limits_{\boldsymbol{y}} h(\boldsymbol{y})\\ \text{s.t. } B(\boldsymbol{x},\boldsymbol{\xi},\boldsymbol{y})\leqslant 0\end{cases}\tag{19}$$

式中，$f(\boldsymbol{x})$、$A(\boldsymbol{x})\leqslant 0$、$\boldsymbol{x}$分别为第一阶段目标函数、约束条件、决策变量；$h(\boldsymbol{y})$、$B(\boldsymbol{x},\boldsymbol{\xi},\boldsymbol{y})\leqslant 0$、$\boldsymbol{y}$分别为第二阶段目标函数、约束条件、决策变量；$g(\boldsymbol{x},\boldsymbol{\xi})$为第二阶段问题的值函数，评估第一阶段决策$\boldsymbol{x}$的效果。

2.2　目标函数

PIES运行调度首先考虑分时能源价格以及系统运行约束，取单位时段长度为1，制定逐时段运行计划，以启停、购能、弃风弃光惩罚成本、切负荷成本与EV充电收益之和最小化为目标函数，其目标函数为

$$\begin{cases}\min f=f_{\mathrm{du}}+f_{\mathrm{buy}}+f_{\mathrm{cut}}-f_{\mathrm{ev}}\\ f_{\mathrm{du}}=\sum_t c_c^{\mathrm{CHP,on}}u_{c,t}^{\mathrm{CHP}}+c_c^{\mathrm{CHP,off}}v_{c,t}^{\mathrm{CHP}}\\ f_{\mathrm{buy}}=\sum_t c_t^G G_t^{\mathrm{buy}}+c_t^P P_t^{\mathrm{buy}}\\ f_{\mathrm{cut}}=\sum_t\begin{pmatrix}c^{\mathrm{L}}P_t^{\mathrm{cut}}+c_w^{\mathrm{WT}}\left(P_{w,t}^{\mathrm{WT,pre}}-P_{w,t}^{\mathrm{WT}}\right)+\\ c_v^{\mathrm{PV}}\left(P_{v,t}^{\mathrm{PV,pre}}-P_{v,t}^{\mathrm{PV}}\right)\end{pmatrix}\\ f_{\mathrm{ev}}=\sum_t c_t^{\mathrm{EV}}P_t^{\mathrm{EV}}\end{cases}\tag{20}$$

式中，$c_c^{\mathrm{CHP,on}}$、$c_c^{\mathrm{CHP,off}}$分别为CHP机组c的开机成本与停机成本；$u_{c,t}^{\mathrm{CHP}}$为CHP机组开机0-1指示变量，$\nu_{c,t}^{\mathrm{CHP}}$为CHP机组停机0-1指示变量；c_t^{G}、c_t^{P}为分时气价和电价；G_t^{buy}、P_t^{buy}分别为t时段的购气功率、购电功率；c^{L}为切负荷单位惩罚成本；P_t^{cut}为t时段的切负荷功率；c_w^{WT}、c_v^{PV}分别为风电机组w、光伏机组v弃风弃光单位惩罚成本；$P_{w,t}^{\mathrm{WT,pre}}$、$P_{v,t}^{\mathrm{PV,pre}}$分别为风电和光伏的预测出力；$P_{w,t}^{\mathrm{WT}}$、$P_{v,t}^{\mathrm{PV}}$分别为风电机组$w$、光伏机组$v$在$t$时段的可再生能源出力；$c_t^{\mathrm{EV}}$为充电桩分时电价；$P_t^{\mathrm{EV}}$为$t$时段的EV充电负荷。

2.3 PIES运行约束

1)网络平衡约束。

PIES运行需要满足系统内电、热、气负荷需求与功率平衡。

电功率平衡约束为

$$P_t^{\mathrm{buy}}+P_{w,t}^{\mathrm{WT}}+P_{v,t}^{\mathrm{PV}}+P_{c,t}^{\mathrm{CHP}}+P_{i,t}^{\mathrm{dis}}-P_{i,t}^{\mathrm{cha}}-P_{b,t}^{\mathrm{EB}}=P_t^{\mathrm{L}}+P_t^{EV}-P_t^{\mathrm{cut}} \tag{21}$$

式中，$P_{c,t}^{\mathrm{CHP}}$为CHP机组在t时段的电功率；$P_{i,t}^{\mathrm{dis}}$、$P_{i,t}^{\mathrm{cha}}$分别为BESS在t时段的放电功率与充电功率；$P_{b,t}^{\mathrm{EB}}$为EB机组b在t时段消耗的电功率；P_t^{L}为PIES在t时段的常规电负荷功率。

热功率平衡约束为

$$H_{c,t}^{\mathrm{CHP}}+H_{b,t}^{\mathrm{EB}}=H_t^{\mathrm{L}} \tag{22}$$

式中，$H_{c,t}^{\mathrm{CHP}}$、$H_{b,t}^{\mathrm{EB}}$分别为CHP机组c和EB机组b在t时刻产生的热功率；H_t^{L}为PIES的热负荷功率。

气功率平衡约束为

$$G_t^{\mathrm{buy}}-G_{c,t}^{\mathrm{CHP}}=G_t^{\mathrm{L}} \tag{23}$$

式中，$G_{c,t}^{\mathrm{CHP}}$为CHP机组c消耗的天然气功率；G_t^{L}为系统气负荷功率。

2)CHP机组运行约束。

CHP机组通过对天然气的高效利用，能够以较高的效率同时供给电能和热能，但其启停过程较为复杂。因此，在本文中考虑CHP机组的最小启停时间约束，即

$$u_{c,t}^{\mathrm{CHP}}-\nu_{c,t}^{\mathrm{CHP}}=i_{c,t}^{\mathrm{CHP}}-i_{c,t-1}^{\mathrm{CHP}} \tag{24}$$

$$u_{c,t}^{\mathrm{CHP}}+\nu_{c,t}^{\mathrm{CHP}}\leqslant 1 \tag{25}$$

$$0\leqslant P_{c,t}^{\mathrm{CHP}}\leqslant i_{c,t}^{\mathrm{CHP}}P_{c,\max}^{\mathrm{CHP}} \tag{26}$$

$$\left(i_{c,t+1}^{\mathrm{CHP}}-i_{c,t}^{\mathrm{CHP}}\right)T_c^{\mathrm{CHP,on}}-\sum_{k=t+2}^{\min\left\{t+T_c^{\mathrm{CHP,on}},T\right\}}i_{c,k}^{\mathrm{CHP}}\leqslant \max\left\{1,T_c^{\mathrm{CHP,on}}-T+t-1\right\} \tag{27}$$

$$\left(i_{c,t}^{\mathrm{CHP}}-i_{c,t+1}^{\mathrm{CHP}}\right)T_c^{\mathrm{CHP,off}}-\sum_{k=t+2}^{\min\left\{t+T_c^{\mathrm{CHP,off}},T\right\}}i_{c,k}^{\mathrm{CHP}}T_c^{\mathrm{CHP,off}}\leqslant \max\left\{1,T_c^{\mathrm{CHP,off}}+t-1\right\} \tag{28}$$

式中，$i_{c,t}^{\mathrm{CHP}}$为CHP机组c状态0-1指示变量；$P_{c,\max}^{\mathrm{CHP}}$为CHP机组的最大发电功率；$T_c^{\mathrm{CHP,on}}$、$T_c^{\mathrm{CHP,off}}$分别为CHP机组$c$最小开机、停机时间。

而CHP机组出力受到多种因素影响，且会以一定热电比同时供给电能和热能，其输出电热功率为：

$$\begin{cases}P_{c,t}^{\mathrm{CHP}}=\dfrac{\varepsilon_c^{\mathrm{CHP}}\eta_c^{\mathrm{CHP}}G_{c,t}^{\mathrm{CHP}}L_{\mathrm{Gas}}}{1+\varepsilon_c^{\mathrm{CHP}}}\\ H_{c,t}^{\mathrm{CHP}}=\varepsilon_c^{\mathrm{CHP}}P_{c,t}^{\mathrm{CHP}}\end{cases} \tag{29}$$

$$\begin{cases}P_{c,t}^{\mathrm{CHP}}-P_{c,t-1}^{\mathrm{CHP}}\leqslant R_c^{\mathrm{CHP,u}}\\ P_{c,t-1}^{\mathrm{CHP}}-P_{c,t}^{\mathrm{CHP}}\leqslant R_c^{\mathrm{CHP,d}}\end{cases} \tag{30}$$

式中，$\varepsilon_c^{\mathrm{CHP}}$为CHP机组的热电比；$\eta_c^{\mathrm{CHP}}$为CHP机组$c$的气-电转换效率；$G_{c,t}^{\mathrm{CHP}}$为CHP机组$c$消耗的天然气功率；$L_{\mathrm{Gas}}$为天然气的低热值；$R_c^{\mathrm{CHP,u}}$、$R_c^{\mathrm{CHP,d}}$分别为CHP机组$c$的上爬坡与下爬坡最大功率。

3)EB机组运行约束。

$$0\leqslant P_{b,t}^{\mathrm{EB}}\leqslant P_{b,\max}^{\mathrm{EB}} \tag{31}$$

$$H_{b,t}^{\mathrm{EB}}=\eta_b^{\mathrm{EB}}P_{b,t}^{\mathrm{EB}} \tag{32}$$

$$\begin{cases}P_{b,t}^{\mathrm{EB}}-P_{b,t-1}^{\mathrm{EB}}\leqslant R_b^{\mathrm{EB},u}\\ P_{b,t-1}^{\mathrm{EB}}-P_{b,t}^{\mathrm{EB}}\leqslant R_b^{\mathrm{EB},d}\end{cases} \tag{33}$$

式中，η_b^{EB}为EB机组b的电-热转换效率；$P_{b,\max}^{\mathrm{EB}}$为EB机组的最大电功率；$R_b^{\mathrm{EB},u}$、$R_b^{\mathrm{EB},d}$分别为EB机组b的上爬坡与下爬坡最大功率。

4)BESS运行约束。

为提升运行灵活性与可再生能源消纳率，本文在电能流中都引入了BESS设备，其运行约束为

$$\begin{cases}S_{i,t}^{\min}\leqslant E_{i,t}\leqslant S_{i,t}^{\max}\\ E_{i,t}=E_{i,t-1}+P_{i,t}^{\mathrm{cha}}\eta_i^{\mathrm{cha}}-P_{i,t}^{\mathrm{dis}}/\eta_i^{\mathrm{dis}}\\ 0\leqslant P_{i,t}^{\mathrm{cha}}\leqslant i_{i,t}^{\mathrm{cha}}P_i^{\mathrm{cha,max}}\\ 0\leqslant P_{i,t}^{\mathrm{dis}}\leqslant i_{i,t}^{\mathrm{dis}}P_i^{\mathrm{dis,max}}\\ i_{i,t}^{\mathrm{cha}}+i_{i,t}^{\mathrm{dis}}\leqslant 1\end{cases} \tag{34}$$

式中，$E_{i,t}$、$P_{i,t}^{\mathrm{dis}}$、$P_{i,t}^{\mathrm{cha}}$分别为BESS在t时段的荷电状态、放电功率、充电功率；$S_{i,t}^{\min}$、$S_{i,t}^{\max}$分别为BESS的最小荷电状态与最大荷电状态；$i_{i,t}^{\mathrm{cha}}$、$i_{i,t}^{\mathrm{dis}}$为0-1变量分别为BESS的充电与放电指示；η_i^{cha}、η_i^{dis}、$P_i^{\mathrm{cha,max}}$、$P_i^{\mathrm{dis,max}}$分别为充、放电效率、最大充、放电功率。

3 求解算法

3.1 不确定性模型嵌入

文2.1中构建的两阶段框架虽可通过决策-校核的方式用于评估日前调度计划的合理性，但第二阶段需要求解不确定变量$\boldsymbol{\xi}_s$实现后的调度计划y_s。常规方法诸如SP通过场景概率与不确定变量取值

模拟不确定变量实现后的调度计划，以对第一阶段决策$\boldsymbol{x}$进行评估，但随着场景数量的增多，易出现维数爆炸等问题。而鲁棒优化（robust optimization，RO）仅关注最恶劣的不确定变量取值避免了这一问题，但其过于关注发生概率较低的极端场景，导致调度策略的成本效率有限。基于文1.2中构建的不确定性集合，本文提出一种基于数据驱动的DRO模型实现不确定性嵌入方法，捕获不确定性，实现兼顾经济性与鲁棒性的调度策略。其模型由式（19）改写为

$$\begin{aligned}&\min_{\boldsymbol{x}\in\mathcal{X}}\boldsymbol{c}^{\mathrm{T}}\boldsymbol{x}+\max_{p_s\in\Omega}\min_{\boldsymbol{y}_s\in\mathcal{Y}}\sum_{s=1}^{|N_s|}p_s\boldsymbol{d}^{\mathrm{T}}\boldsymbol{y}_s\\&\text{s.t. }\mathcal{X}=\left\{\boldsymbol{x}\middle|\boldsymbol{A}\boldsymbol{x}\leqslant\boldsymbol{b}\right\}\\&\quad\Omega=\left\{p_s\middle|\begin{array}{l}p_s\geqslant0,\quad\sum\limits_{s=1}^{|N_s|}p_s=1\\\sum\limits_{s=1}^{|N_s|}\left|p_s-p_s^0\right|\leqslant\theta_1,\ \max\limits_{1\leqslant s\leqslant N_s}\left|p_s-p_s^0\right|\leqslant\theta_\infty\end{array}\right\}\\&\quad\mathcal{Y}=\left\{\boldsymbol{y}_s\middle|\boldsymbol{E}\boldsymbol{x}+\boldsymbol{G}\boldsymbol{y}_s+\boldsymbol{M}\boldsymbol{\xi}\leqslant\boldsymbol{h}\right\}\end{aligned}\tag{35}$$

式中：$\boldsymbol{x}$、$\boldsymbol{y}_s$分别为第一阶段和第二阶段决策变量，其中$\boldsymbol{x}$包括CHP机组的启停状态及计划出力、各类可调设备的日前出力计划以及购电、购气等日前决策；$\boldsymbol{y}_s$为包括在场景s下的机组出力调整、PV、WT的实际消纳出力以及常规负荷与EV充电负荷的调整量；$\boldsymbol{c}^{\mathrm{T}}$、$\boldsymbol{d}^{\mathrm{T}}$由式（20）中的各类成本与收益系数按$\boldsymbol{x}$、$\boldsymbol{y}_s$的排列顺序构成；$\mathcal{X}$、$\mathcal{Y}$、$\boldsymbol{\Omega}$分别对应式（21）～（34）中对第一阶段和第二阶段决策的运行约束构成的可行域以及式（12）给出的综合范数不确定变量可行域；$\boldsymbol{A}$、$\boldsymbol{E}$、$\boldsymbol{G}$、$\boldsymbol{M}$分别为电、热、气功率平衡约束及机组出力约束的系数矩阵；$\boldsymbol{b}$、$\boldsymbol{h}$为相应约束的右端项；θ_1、θ_∞根据式（13）确定，以给定综合范数不确定集的偏差界限。

通过数据驱动的DRO方法将不确定变量嵌入到考虑EV接入的PIES优化调度问题中，并将其表述为两阶段三层min-maxmin优化问题。在第一阶段制定包含机组启停、功率平衡的日前决策；在max问题中找到文1中的抽样得到的EV充电行为场景的最不利场景概率分布，进而在第二阶段求解$\boldsymbol{y}_s$决策，并将其成本添加到目标函数中用于评估第一阶段决策$\boldsymbol{x}$的可行性。

3.2　改进列与约束生成算法

式（35）构建的两阶段三层优化问题，先应确定最优第一阶段决策$\boldsymbol{x}^*$，并将其作为常数传递给第二阶段优化问题。而第二阶段优化问题是由多个不同概率p_s支撑的场景支持的，在max问题中找到最不利的场景概率分布p_s^*，并在该分布下求解内层调整问题，以获取兼顾经济性与鲁棒性的调度结果。因而，该两阶段问题被分解为

$$\begin{cases}\min\limits_{\boldsymbol{x}\in\mathcal{X}}\boldsymbol{c}^{\mathrm{T}}\boldsymbol{x}\\\text{s.t. }\mathcal{X}=\left\{\boldsymbol{x}\middle|\boldsymbol{A}\boldsymbol{x}\leqslant\boldsymbol{b}\right\}\end{cases}\tag{36}$$

$$\begin{cases}\max\limits_{p_s\in\Omega}\min\limits_{\boldsymbol{y}_s\in\mathcal{Y}}\sum\limits_{s=1}^{|N_s|}p_s\boldsymbol{d}^{\mathrm{T}}\boldsymbol{y}_s\\\text{s.t. }\Omega=\left\{p_s\middle|\begin{array}{l}p_s\geqslant0,\quad\sum\limits_{s=1}^{|N_s|}p_s=1\\\sum\limits_{s=1}^{|N_s|}\left|p_s-p_s^0\right|\leqslant\theta_1,\ \max\limits_{1\leqslant s\leqslant N_s}\left|p_s-p_s^0\right|\leqslant\theta_\infty\end{array}\right\}\\\quad\mathcal{Y}=\left\{\boldsymbol{y}_s\middle|\boldsymbol{E}\boldsymbol{x}+\boldsymbol{G}\boldsymbol{y}_s+\boldsymbol{M}\boldsymbol{\xi}\leqslant\boldsymbol{h}\right\}\end{cases}\tag{37}$$

子问题为maxmin优化问题，在本文中考虑了储能设备的0-1状态变量，一般来说应通过嵌套列与约束生成（column-and-constraint generation，C&CG）对其进行迭代求解。而本文采用的数据驱动的DRO方法，可以并行求解各个场景对应的问题。因而，本文提出一种改进的列与约束生成算法，将式（36）、（37）调整为主子问题迭代的形式求解，具体步骤可分为4步。

1）初始化，设置迭代次数$r=1$，上界$\overline{B}=\infty$，下界$\underline{B}=-\infty$；设置收敛判据ε。

2）求解主问题，得到主问题目标函数值V_r^*，最优解$\boldsymbol{x}^*$，将下界$\underline{B}$更新为V_r^*。

3）将步骤2）中获得的最优解$\boldsymbol{x}^*$代入到$|N_s|$个子问题中并行求解，获得最恶劣场景概率分布$p_{s,r}^*$以及场景s下的子问题最优值$J_{s,r}^*$以及最优解$\boldsymbol{y}_{s,r}^*$，更新上界$\underline{B}$为$\min\left\{\underline{B},\boldsymbol{c}^{\mathrm{T}}\boldsymbol{x}_r^*+\sum\limits_{s=1}^{|N_s|}p_{s,r}^*J_{s,r}^*\right\}$。

4）收敛性判断。如果$\left|(\overline{B}-\underline{B})/\underline{B}\right|\leqslant\varepsilon$，则问题收敛，停止迭代；否则回到步骤2），向其添加变量和约束后，令$r=r+1$继续迭代，主问题为

$$\begin{cases}\min\limits_{\boldsymbol{x}\in\mathcal{X}}\boldsymbol{c}^{\mathrm{T}}\boldsymbol{x}_r+\eta\\\text{s.t. }\mathcal{X}=\left\{\boldsymbol{x}\middle|\boldsymbol{A}\boldsymbol{x}\leqslant\boldsymbol{b}\right\}\\\quad\eta\geqslant\sum\limits_{s=1}^{|N_s|}p_{s,r}^*\boldsymbol{d}^{\mathrm{T}}\boldsymbol{y}_{s,r}^*,\ \ \forall r\\\quad\boldsymbol{E}\boldsymbol{x}+\boldsymbol{G}\boldsymbol{y}_{s,c}^*+\boldsymbol{M}\boldsymbol{\xi}\leqslant\boldsymbol{h},\ \ \forall r\end{cases}\tag{38}$$

式中，η为子问题评估变量，用于评估子问题在当前决策$\boldsymbol{x}$下给出最高调整成本。当算法收敛时，η与该最坏情形下的第二阶段最优调整成本相等，即不等式$\eta \geqslant \sum_{s=1}^{|N_s|} p_{s,r}^{*} \boldsymbol{d}^{\mathrm{T}} \boldsymbol{y}_{s,r}^{*}$取等，实现子问题对主问题优化结果的调整。

求解完上述问题后，可以得到PIES最优的日前调度计划$\boldsymbol{x}_{r+1}^{*}$。其中，$r+1$所提改进列与约束生成算法的迭代次数。

4 算例分析

4.1 算例系统说明

本文设置的PIES系统连接关系如图2所示。考虑EV接入不确定性的PIES分布鲁棒优化调度模型在MATLAB R2024a和Yalmip工具包建模，并通过Gurobi优化求解器求解。调度周期选择为24 h，优化时间间隔为1 h。

PIES典型设备参数见表1。购买天然气价格经过天然气低热值换算，设为3.35元/(kW·h)，PIES常规负荷/EV充电负荷的分时电价见表2。

表1 PIES典型设备参数

Table 1 Typical equipment parameters of PIES

η_b^{EB}	$\eta_i^{\mathrm{cha}}/\eta_i^{\mathrm{dis}}$	η_c^{CHP}	L_{Gas}/(kW·h/m³)	($T_c^{\mathrm{CHP,on}}$、$T_c^{\mathrm{CHP,off}}$)/h	$\varepsilon_c^{\mathrm{CHP}}$
0.93	0.95	0.86	9.7	3、4	1.35

表2 PIES常规负荷/EV充电负荷的分时电价

Table 2 Time-of-use electricity prices for conventional load and EV charging load of PIES 元·(kW·h)$^{-1}$

时段	常规负荷电价	EV充电负荷电价
峰段(08:00—11:00，16:00—23:00)	1.33	1.55
平段(13:00—16:00，23:00—24:00)	1.11	1.23
谷段(00:00—08:00，11:00—13:00)	0.45	0.55

4.2 算法有效性分析

4.2.1 DRO求解方法优势分析

本文先对所提的基于数据驱动的DRO求解算法的性能进行对比分析，设置了3个场景进行求解分析，不同求解算法优化结果对比如图3所示。

1)场景1：采用随机优化方法求解，各类不确定性均通过文1.1、1.2提出的GMM模型及Neyman抽样方法描述得到，选取可再生能源出力、EV负荷及其他负荷波动场景作为分布集；

2)场景2：采用鲁棒优化方法求解，选取与场景1相同的可再生能源出力、EV负荷及其他负荷波动信息，并选取这些数据每小时的最值作为不确定集合边界，以描述PIES最恶劣运行调度场景；

3)场景3：采用本文所提出基于数据驱动的分布鲁棒优化方法求解，选取与场景1相同的可再生能源出力、EV负荷及其他负荷波动信息，并按照文3.2所提的算法进行优化求解。

不同求解算法优化结果对比如图3所示。从图3中可以看出，在可再生能源出力与多种负荷的不确定性影响下，3种求解方法得到的优化结果存在一定差异。场景1采用随机优化方法得到的机组启停、购能成本较低，相比其他两种求解方法，在经济性上有一定优势。但其难以应对PIES中各种不确定性因素相互作用的情况，因而在实际调度中缺乏鲁棒性，难以应对恶劣场景，更易导致弃风弃光和切负荷惩罚，使整体成本偏高。鲁棒优化依赖最恶劣场景进行决策，保守性最强，但其保守策略带来了频繁的机组启停和较高的购能需求，导致PIES调度总成本显著增加。相比之下，分布鲁棒优化能够识别场景差异并在经济性与鲁棒性之间取得较好折衷。DRO通过更有效地调配储能和灵活资源，具有更高的可再生能源利用率，较少触发惩罚项，使得其总成本相较随机优化方法仅增加6.83%、相较鲁棒优化方法降低10.26%，体现出显著的综合优势。

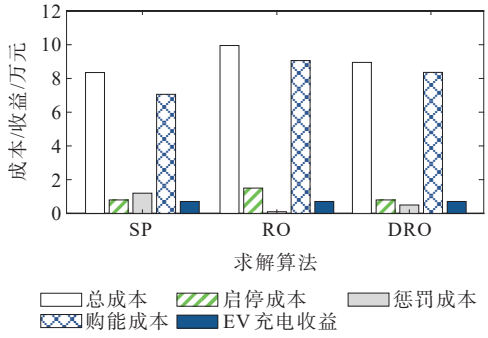

图3 不同求解算法优化结果对比

Figure 3 Comparison of optimization results obtained using different solution algorithms

4.2.2 参数敏感性分析

在基于数据驱动的DRO模型中，可再生能源出力、EV充电负荷及其他负荷波动场景的概率分布不确定性由1-范数和∞-范数共同刻画，其综合范数用于约束场景概率的可行域。置信度参数α_1和α_∞的不同取值会改变多个维度历史场景被计入不

确定集合的范围，导致场景概率结果不同，对 PIES 优化调度决策产生影响。

在这里选取 1 000 个历史场景，1-范数约束参数 α_1 以及 ∞-范数约束参数 α_∞ 的取值均自 0.20 起按 0.20 的间隔递增，按照场景 3 设定的条件进行求解，数据驱动的 DRO 参数敏感性分析见表 3。

表 3　数据驱动的 DRO 参数敏感性分析

Table 3　Sensitivity analysis of data-driven DRO parameters

α_∞	不同 α_1 下的总调度成本/万元				
	0.20	0.40	0.60	0.80	0.99
0.20	7.401 8	7.610 2	7.818 7	7.950 4	8.276 5
0.40	7.632 0	7.840 4	7.940 2	8.222 8	8.433 8
0.60	7.843 0	8.038 6	8.277 8	8.442 7	8.635 8
0.80	8.064 2	8.259 9	8.453 0	8.649 9	8.914 6
0.99	8.225 3	8.561 7	8.665 2	8.860 9	9.046 3

由表 3 可知，当 α_1 取值固定时，随着 α_∞ 的取值增大，PIES 总调度成本呈上升趋势；而当 α_∞ 取值固定时，随着 α_1 的取值增大，PIES 总调度成本呈现类似趋势。这表明置信度参数 α_1 和 α_∞ 共同影响了不确定集合的范围，共同决定了决策的鲁棒程度，较高的置信度意味着综合范数约束对偏离历史场景均值的极端样本容忍度增加，更多恶劣的历史场景会被纳入可再生能源出力、负荷波动场景的分布集中。而在 PIES 运行调度中，为应对更大的不确定性，PIES 需采取更保守的调度策略，因而总成本也会随之上升。参数的可调性使得基于数据驱动的 DRO 模型能在经济性与鲁棒性之间灵活权衡，根据运行需求实现最优折衷。

4.2.3　延时充电管理方案分析

为验证延时充电管理方案对考虑 EV 接入的 PIES 调度的有效性，设置场景 4 与场景 3 进行对比分析，这两种场景下得到的电功率平衡分别如图 4、5 所示。

场景 4 采用延时充电管理方案优化 EV 负荷曲线，对于可再生能源出力与其余负荷波动场景使用与场景 3 相同的分布集，并采用本文提出的方法求解计算。

对比分析图 4、5 可知，延时充电管理方案显著改善了 PIES 的总电负荷曲线，特别是其用电高峰特性。延时充电前的 EV 负荷在 16:00—23:00 时段集中、高峰尖锐，导致该时段的外购电功率大幅增加，并带动 BESS 在负荷低谷充电、负荷高峰放电的调节行为，而负荷低谷时段则出现部分 CHP 机组停

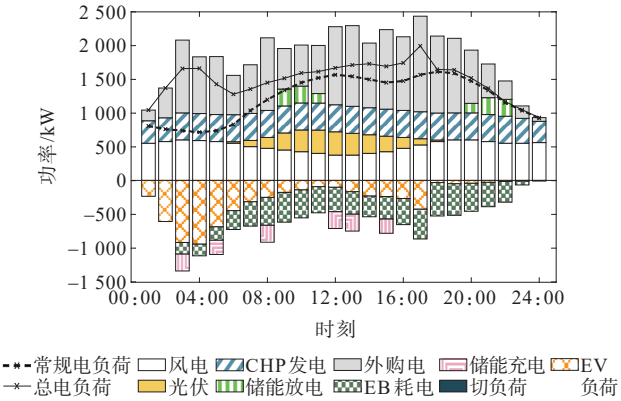

图 4　场景 4 的电功率平衡

Figure 4　Electric power balance in scenario 4

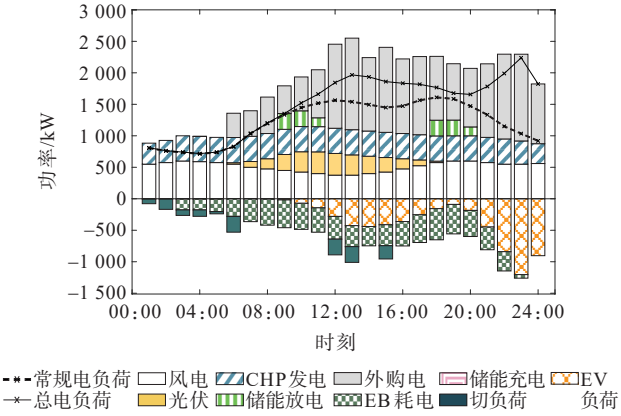

图 5　场景 3 的电功率平衡

Figure 5　Electric power balance in scenario 3

运的情况，增大 PIES 运行调度总成本。在考虑延时充电管理方案后，部分高峰充电需求被转移至低谷时段，使 PIES 电负荷曲线明显平滑，可再生能源可被更充分吸纳，外购电量显著下降，储能充电负荷几乎消失，仅在必要时用于削峰，PIES 整体调度趋于稳定，实现了更低的外购电依赖、更高的可再生能源利用率以及更平稳的储能运行方式，提升了 PIES 经济性与运行可靠性。

5　结语

本文围绕 EV 接入场景下的 PIES 优化调度问题，针对 EV 充电行为的不确定性刻画不足、调度策略难以兼顾经济性与鲁棒性等关键挑战，开展了数据驱动的建模、优化与求解方法研究，主要结论如下：

1）所提的 GMM-Neyman 抽样方法能高效捕获多种 EV 充电行为特征，基于混合范数构建其不确定集合，在避免单一场景抽样的局限性的同时，又克服了维度爆炸问题；

2)提出的延时与错峰协同的充电管理方案通过即时充电和延时充电的协调管理有效平抑了PIES的峰谷差；

3)所提的基于DRO的PIES调度模型能够兼顾经济性与鲁棒性，相较于常规两阶段鲁棒模型总成本降低了10.26%，改进的列与约束生成算法通过主子问题迭代方式实现了DRO模型的高效求解。

参考文献：

[1] 张彩玲, 王爽, 葛淑娜, 等. 计及灵活需求响应和碳-绿证交易的综合能源系统优化调度[J]. 中国电力, 2024(5): 14-25.
Zhang Cailing, Wang Shuang, Ge Shuna, et al. Optimal scheduling of integrated energy systems considering flexible demand response and carbon emission-green certificate joint trading[J]. Electric Power, 2024(5): 14-25.

[2] 张沈习, 王丹阳, 程浩忠, 等. 双碳目标下低碳综合能源系统规划关键技术及挑战[J]. 电力系统自动化, 2022, 46(8): 189-207.
Zhang Shenxi, Wang Danyang, Cheng Haozhong, et al. Key technologies and challenges of low-carbon integrated energy system planning for carbon emission peak and carbon neutrality[J]. Automation of Electric Power Systems, 2022, 46(8): 189-207.

[3] 杨明, 李明冰, 张玉敏, 等. 基于纳什议价模型的园区综合能源系统低碳优化调度[J]. 电力系统自动化, 2025, 49(19): 39-48.
Yang Ming, Li Mingbing, Zhang Yumin, et al. Low-carbon optimal dispatch of park-level integrated energy system based on Nash bargaining model[J]. Automation of Electric Power Systems, 2025, 49(19): 39-48.

[4] 刘硕, 吴旭, 马速良, 等. 基于模型预测控制的光-氢-储耦合系统的功率优化分配方法研究[J]. 高压电器, 2024, 60(7): 23-33.
Liu Shuo, Wu Xu, Ma Suliang, et al. Research on power optimization allocation method for solar-hydrogen-storage coupled system based on model predictive control[J]. High Voltage Apparatus, 2024, 60(7): 23-33.

[5] 刘维民, 肖辉, 曾林俊, 等. 考虑电动汽车充电模式和供需灵活性的综合能源系统优化调度[J]. 电力建设, 2025, 46(6): 1-12.
Liu Weimin, Xiao Hui, Zeng Linjun, et al. Optimal scheduling of integrated energy systems considering electric vehicle charging patterns and supply-demand flexibility[J]. Electric Power Construction, 2025, 46(6): 1-12.

[6] 祝良瑜. 柏林欧瑞府科技园: 2050年德国的零碳园区[J]. 能源, 2025(7): 54-58.
Zhu Liangyu. Orifu science park in berlin: zero-carbon park in Germany in 2050[J]. Energy, 2025(7): 54-58.

[7] 邱彬, 宋绍鑫, 王凯, 等. 计及需求响应和阶梯型碳交易机制的区域综合能源系统优化运行[J]. 电力系统及其自动化学报, 2022, 34(5): 87-95+101.
Qiu Bin, Song Shaoxin, Wang Kai, et al. Optimal operation of regional integrated energy system considering demand response and ladder-type carbon trading mechanism[J]. Proceedings of the CSU-EPSA, 2022, 34(5): 87-95+101.

[8] 孙欣, 向柯颖, 谢敬东. 考虑动态能价机制的综合能源系统优化调度[J]. 电力科学与技术学报, 2025, 40(4): 205-216.
Sun Xin, Xiang Keying, Xie Jingdong. Optimal scheduling of integrated energy systems considering dynamic energy pricing mechanisms[J]. Journal of Electric Power Science and Technology, 2025, 40(4): 205-216.

[9] 刘光宇, 韩东升, 刘超杰, 等. 考虑双重需求响应及阶梯型碳交易的综合能源系统双时间尺度优化调度[J]. 电力自动化设备, 2023, 43(5): 218-225.
Liu Guangyu, Han Dongsheng, Liu Chaojie, et al. Dual time scale optimal scheduling of integrated energy system considering dual demand response and stepped carbon trading[J]. Electric Power Automation Equipment, 2023, 43(5): 218-225.

[10] 盛四清, 张佳欣, 李然, 等. 考虑综合需求响应的综合能源系统多能协同优化调度[J]. 电力自动化设备, 2023, 43(6): 1-9.
Sheng Siqing, Zhang Jiaxin, Li Ran, et al. Multi-energy collaborative optimization scheduling of integrated energy system considering integrated demand response [J]. Electric Power Automation Equipment, 2023, 43(6): 1-9.

[11] 刘钊,郭子豪,申安,等.考虑冷热电灵活性负荷需求响应的区域综合能源系统运行优化[J].南方能源建设, 2024,11(6):153-163.
Liu Zhao, Guo Zihao, Shen An, et al. Optimization of regional integrated energy system operation considering flexible load demand response for cooling, heating and power[J]. Southern Energy Construction, 2024, 11(6): 153-163.

[12] 詹祥澎, 杨军, 韩思宁, 等. 考虑电动汽车可调度潜力的充电站两阶段市场投标策略[J]. 电力系统自动化, 2021, 45(10): 86-96.
Zhan Xiangpeng, Yang Jun, Han Sining, et al. Two-stage market bidding strategy of charging station considering schedulable potential capacity of electric vehicle[J]. Automation of Electric Power Systems, 2021, 45(10): 86-96.

[13] Jian J, Zhang M Y, Xu Y L, et al. An analytical polytope

approximation aggregation of electric vehicles considering uncertainty for the day-ahead distribution network dispatching[J]. IEEE Transactions on Sustainable Energy, 2024, 15(1): 160-172.

[14] 杨钰君，于艾清，丁丽青．基于停车需求的电动汽车移动储能多目标充放电协调控制[J]. 电力科学与技术学报，2022, 37(4): 65-77.
Yang Yujun, Yu Aiqing, Ding Liqing. Multi-objective coordinated control of charging and discharging for mobile energy storage of electric vehicles based on parking demand[J]. Journal of Electric Power Science and Technology, 2022, 37(4): 65-77.

[15] 王杨洋，茆美琴，杨铖，等．面向多场景辅助服务的大规模电动汽车聚合可调度容量建模[J]. 电力系统自动化，2024, 48(7): 103-115.
Wang Yangyang, Mao Meiqin, Yang Cheng, et al. Aggregated and schedulable capacity modeling of large-scale electric vehicles for multi-scenario auxiliary services[J]. Automation of Electric Power Systems, 2024, 48(7): 103-115.

[16] 王珂，李玮桁，王正风，等．基于两阶段鲁棒优化的电动汽车可调容量聚合及解聚方法[J]. 电力系统自动化，2025, 49(24): 115-124.
Wang Ke, Li Weiheng, Wang Zhengfeng, et al. Adjustable capacity aggregation and disaggregation method for electric vehicles based on two-stage robust optimization[J]. Automation of Electric Power Systems, 2025, 49(24): 115-124.

[17] 刘祺，王承民，谢宁，等．新型配电系统中考虑电动汽车差异化行为特性的充换电站规划方法[J]. 智慧电力，2024, 52(9): 18-24+64.
Liu Qi, Wang Chengmin, Xie Ning, et al. Charging and swapping stations planning method considering differentiated behavior characteristics of electric vehicles in new distribution system[J]. Smart Power, 2024, 52(9): 18-24+64.

[18] 侯慧，何梓姻，罗超，等．计及需求响应潜力的电动汽车聚合商多主体日前投标策略[J]. 全球能源互联网，2024, 7(2): 220-227.
Hou Hui, He Ziyin, Luo Chao, et al. Multi-agent day-ahead bidding strategy of electric vehicle aggregators upon demand response potential[J]. Journal of Global Energy Interconnection, 2024, 7(2): 220-227.

[19] 王精，邢海军，王华昕，等．考虑电动汽车及负荷聚合商参与的综合能源系统优化调度[J]. 上海交通大学学报，2023, 57(7): 814-823.
Wang Jing, Xing Haijun, Wang Huaxin, et al. Optimal Scheduling of integrated energy system considering integration of electric vehicles and load aggregators [J]. Journal of Shanghai Jiao Tong University, 2023, 57(7): 814-823.

[20] 戈文祺，王晓彤．计及电动汽车的区域综合能源系统双层配置调度优化策略[J]. 太阳能学报，2025, 46(8): 656-665.
Ge Wenqi, Wang Xiaotong. Optimisation of regional integrated energy system scheduling strategies taking into account electric vehicles[J]. Acta Energiae Solaris Sinica, 2025, 46(8): 656-665.

[21] 朱永胜，常稳，武东亚，等．考虑充放储一体站与电动汽车互动的主从博弈优化调度策略[J]. 电力系统保护与控制，2024, 52(7): 157-167.
Zhu Yongsheng, Chang Wen, Wu Dongya, et al. A Stackelberg game optimization scheduling strategy considering the interaction between a charging-discharging-storage integrated station and an electric vehicle[J]. Power System Protection and Control, 2024, 52(7): 157-167.

[22] Wu S C, Pang A P. Two-stage optimal scheduling strategy for community integrated energy system based on uncertainty and integrated demand response model [J]. Renewable Energy, 2025, 251: 123373.

[23] Bian H H, Ren Q C, Guo Z Y, et al. Optimal scheduling of integrated energy system considering electric vehicle battery swapping station and multiple uncertainties[J]. World Electric Vehicle Journal, 2024, 15(4): 170.

[24] Emdadi K, Gandomkar M, Nikoukar J. Adaptive robust energy management of smart grid with renewable integrated energy system, fuel cell and electric vehicles stations and renewable distributed generation[J]. Results in Engineering, 2025, 27: 106857.

[25] 张浩，陆海，罗恩博，等．考虑资源灵活性的多区域综合能源系统协同调度[J]. 电网与清洁能源，2024, 40(9): 148-154.
Zhang Hao, Lu Hai, Luo Enbo, et al. Coordinated scheduling of multi-region integrated energy systems considering resource flexibility[J]. Power System and Clean Energy, 2024, 40(9): 148-154.

[26] 曾珠梅，孙建梅．计及电–气–热需求响应的区域综合能源系统运行优化[J]. 电力工程技术，2024, 43(5): 48-57.
Zeng Zhumei, Sun Jianmei. Operation optimization of regional integrated energy system with electricity-gas-thermal demand response[J]. Electric Power Engineering Technology, 2024, 43(5): 48-57.

[27] 刘安迪．高恢复力主动配电网规划研究[D]. 武汉：华中科技大学，2021:5-40.
Liu Andi. Research on planning of high resilience active distribution network[D]. Wuhan: Huazhong University of Science and Technology, 2021:5-40.

[28] 程礼临，罗子杰，李群，等．融合模糊神经网络预决策的有源配电网实时随机调度方法[J]. 电力系统自动化，2025, 49(19): 75-85.

Cheng Lilin, Luo Zijie, Li Qun, et al. Real-time stochastic dispatch method for active distribution network using fuzzy neural network pre-decision[J]. Automation of Electric Power Systems, 2025, 49(19): 75-85.

[29] 王梓璇, 郝禹, 刘星辰, 等. 历史数据驱动的综合能源系统分布式鲁棒低碳优化模型[J]. 综合智慧能源, 2026,48(3):47-55.
Wang Zixuan, Hao Yu, Liu Xingchen, et al. Distributed robust low-carbon optimization model for integrated energy systems driven by historical data[J]. Integrated Intelligent Energy, 2026,48(3):47-55.

[30] Zou S, Zong X J, Chen Q, et al. Optimization scheduling of integrated energy systems considering power flow constraints[J]. Energies, 2025, 18(10): 2442.

[31] 王宇绅, 陈皓勇, 黄宇翔, 等. 多重不确定性下的虚拟电厂参与电能量和需求响应市场鲁棒优化调度策略[J]. 发电技术, 2024, 45(6): 1173-1185.
Wang Yushen, Chen Haoyong, Huang Yuxiang, et al. Robust optimal scheduling strategy for virtual power plant participation in electric energy and demand response markets under multiple uncertainties[J]. Power Generation Technology, 2024, 45(6): 1173-1185.

[32] 杨乐. 基于数据驱动的电动汽车充电负荷预测研究[D]. 北京: 华北电力大学, 2023:12-26.
Yang Le. Research on electric vehicle charging load prediction based on data driven[D]. Beijing: North China Electric Power University, 2023:12-26.

[33] 夏时哲, 王傲群, 蔡梦路. 考虑电动汽车储能特性的充电聚合管控策略研究[J]. 电力需求侧管理, 2024, 26(4): 61-67.
Xia Shizhe, Wang Aoqun, Cai Menglu. Research on charging aggregation management strategies considering energy storage characteristics of electric vehicles[J]. Power Demand Side Management, 2024, 26(4): 61-67.

[34] Ding T, Yang Q R, Liu X Y, et al. Duality-free decomposition based data-driven stochastic security-constrained unit commitment[J]. IEEE Transactions on Sustainable Energy, 2019, 10(1): 82-93.