

计及用户出行信息不确定性的 电动汽车可行域重构聚合与鲁棒决策方法

胡俊杰, 马旭睿, 吴俊

(新能源电力系统国家重点实验室(华北电力大学), 北京市 昌平区 102206)

Reconstructive Aggregation and Robust Decision-making Method for Electric Vehicle Feasible Regions Considering Uncertainties in User Travel Information

HU Junjie, MA Xurui, WU Jun

(State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources

(North China Electric Power University), Changping District, Beijing 102206, China)

ABSTRACT: The effective quantification and aggregation of the flexibility feasible domain for large-scale electric vehicles is a prerequisite for electric vehicle aggregators to participate in market bidding. However, the uncertainty of user travel information leads to a strong random characteristic in the adjustable capacity boundaries of aggregated electric vehicles, affecting the effectiveness of the aggregator's day-ahead bidding strategy. To address the randomness of user behavior and the uncertainty of frequency regulation prices, this paper proposes a method for reconstructing the feasible domain of electric vehicles and robust decision-making that accounts for the uncertainty of user travel information. First, we develop an inner approximation Minkowski reconstruction aggregation model that balances approximation accuracy and computational efficiency, incorporating uncertainties related to disconnection time and initial battery levels to characterize the robust boundary of the aggregation feasible domain. Second, we establish an ellipsoidal uncertainty set for frequency regulation prices and formulate a two-stage three-layer robust optimization model aimed at maximizing the aggregator's net revenue when participating in the joint market, and solve it using an improved column-and-constraint generation(C&CG) algorithm based on the extreme scenario method. Finally, through comparative analysis of numerical examples, we demonstrate the effectiveness and practicality of the proposed reconstruction aggregation method. The robust optimization model significantly mitigates the risks posed by real-world uncertainties, balancing revenue and risk, and guiding aggregators in formulating more reliable bidding strategies.

KEY WORDS: electric vehicles; inner approximation Minkowski aggregation; multiple uncertainties; robust boundary; energy and frequency regulation markets

摘要: 规模化电动汽车灵活性可行域的有效量化和聚合是电动汽车聚合商参与市场申报的前提。但用户出行信息的不确定性将导致聚合后的电动汽车可调节容量边界呈现较强的随机特征, 影响聚合商日前申报策略的有效性。针对用户行为随机性及调频市场价格不确定性, 提出计及用户出行信息不确定性的电动汽车可行域重构聚合与鲁棒决策方法。首先, 构建兼顾逼近精度与计算效率的内逼近闵可夫斯基重构聚合模型, 并在聚合过程中融入初始电量、入离网时间的不确定性建模, 对聚合可行域的鲁棒边界进行刻画; 其次, 构建调频价格椭圆不确定集, 建立以自身净收益最大为目标的聚合商参与联合市场的两阶段三层鲁棒优化模型, 并采用基于极限场景法的改进二阶锥的列与约束生成(column-and-constraint generation, C&CG)算法求解; 最后, 通过算例对比分析重构聚合方法的有效性与实用性, 所提鲁棒优化模型可在很大程度上规避实际不确定性环境带来的风险, 平衡收益与风险, 指导聚合商制定更加可靠的申报策略。

关键词: 电动汽车; 内逼近闵可夫斯基聚合; 多重不确定性; 鲁棒边界; 能量-调频市场

0 引言

双高特性凸显的新型电力系统中, 系统转动惯量不断降低^[1], 调频能力和资源不足问题日益严峻^[2], 亟需挖掘新型调频资源。规模化电动汽车(electric vehicle, EV)呈现出快速精准的动态响应能力及可观的集群容量, 为解决高比例新能源发电并网下的系统调频问题提供了新思路^[3]。据国

基金项目: 国家自然科学基金项目(52177080)。

Project Supported by National Natural Science Foundation of China (52177080).

际能源署统计, 预计到 2030 年, 全球电动汽车保有量将达到 2.28 亿辆, 我国电动汽车保有量将超 8000 万辆, 将在未来的全球电动汽车市场中占据主要地位^[4]。

考虑到 EV 资源分布特性, 对 EV 个体进行单独调控将产生大量的通信和计算负担^[5], 电动汽车聚合商(electric vehicle aggregator, EVA)作为电网和用户之间的中间代理机构, 可将众多 EV 聚合成一个可调节资源池及利益主体, 提高规模化 EV 的灵活性与可调度性^[6]。

对于高维可行域空间的精确聚合通常采用闵可夫斯基求和, 然而, 该方法的计算复杂度随问题维度和资源数量的增加呈指数增长, 严重制约其在大规模场景中的应用。目前, 已有研究对其进行简化, 采用数学复杂度低的模型对资源可行域进行近似。近似处理方法主要分为外逼近和内逼近两类^[7]。外逼近方法采用传统均值近似模型^[8-9]或改进约束增广模型^[10], 计算复杂度较低, 但外近似过程增大了资源聚合可行域, 在实际调度中可能存在不可解的问题^[11], 且在资源异质性较高的场景下难以兼顾聚合精度与效率; 内逼近方法利用凸优化问题构建资源内部近似可行域(如内盒近似^[12]、奇诺多面体内近似^[13]、同质多面体变换^[14]等), 保证聚合结果严格位于真实可行域内, 从而提高后续调度策略的安全可行性, 但在处理 EV 等多时间尺度异质性资源时保守性高, 导致资源聚合可行域牺牲较多灵活性。因此, 在处理大规模高异质性 EV 资源时, 如何建立兼顾可行性、逼近精度与计算效率的可行域聚合模型还有待进一步研究。

EV 用户具有分散性与随机性, 同时, 市场环境也处于不断动态变化之中。用户出行信息和调频价格具有不确定性将给 EVA 的聚合及日前申报带来一定挑战。文献[15]对 EV 用户响应意愿、调频信号和市场电价的不确定性进行建模; 文献[16]考虑电力需求和电价的双重不确定性, 建立了两阶段鲁棒定价策略; 文献[17]对用户行为不确定性建模, 上述研究从不同角度分析不确定因素对 EVA 申报策略的影响, 但鲜有研究综合考虑用户行为随机性及市场环境不确定性, 不确定性因素单一; 文献[18]根据 EV 历史数据进行用能规律挖掘, 确定 GES 模型的容量、功率边界; 文献[19]构建了大规模充换电设施的集总能量-功率边界。上述研究建立了灵活性资源可调能力聚合边界, 但未在聚合过程

中对用户出行信息不确定性进行处理建立聚合可行域鲁棒边界。

针对上述研究的不足, 本文提出计及用户出行信息不确定性的 EV 可行域重构聚合与鲁棒决策方法。首先, 基于内逼近闵可夫斯基重构聚合方法, 对 EV 集群可行域进行量化聚合; 其次, 在聚合过程中融入初始电量、入离网时间不确定性建模, 对 EV 聚合可行域的鲁棒边界进行刻画; 在此基础上, 构建调频市场价格椭圆不确定集, 建立 EVA 参与联合市场的两阶段三层鲁棒优化模型, 并采用基于极限场景法的改进二阶锥的列与约束生成(column-and-constraint generation, C&CG)算法求解; 最后, 通过算例证明重构聚合方法的有效性和实用性, 所提鲁棒优化模型能够平衡 EVA 收益与风险, 可在很大程度上保证解的可行性, 规避实际不确定性环境带来的风险, 指导聚合商申报策略的制定。

1 EV 集群可调节容量量化聚合方法

本节基于自下而上的可行域聚合思路。首先, 建立 EV 个体的充放电模型, 采用半平面形式表征的多胞体集对 EV 的功率可行域进行刻画; 其次, 采用内逼近闵可夫斯基重构聚合方法对 EV 集群进行聚合, 在仿射变换中引入重构过程, 得到 EV 集群功率聚合可行域, 实现 EV 集群可调节容量的量化聚合。

1.1 EV 个体功率可行域表征

EV 功率可行域不仅受电池自身充放电功率限制影响, 也受到电能限制影响。当 EV 个体入网期间, 其充放电模型为

$$\begin{cases} 0 \leq P_t^C \leq P_{\max,t}^C, t^{\text{arr}} \leq t \leq t^{\text{dep}} \\ 0 \leq P_t^D \leq P_{\max,t}^D, t^{\text{arr}} \leq t \leq t^{\text{dep}} \\ E_t = E_{t-1} + (P_t^C \eta^C - P_t^D / \eta^D) \Delta t \\ E_{\min,t} \leq E_t \leq E_{\max,t} \\ E_{t^{\text{dep}}} \geq E^{\text{exp}} \end{cases} \quad (1)$$

式中: t^{arr} 、 t^{dep} 分别为 EV 的入离网时间; P_t^C 、 P_t^D 分别为 EV 在时段 t 的充放电功率; η^C 、 η^D 分别为 EV 的充放电效率; E_t 、 E^{exp} 分别为 EV 在时段 t 的运行容量及车主离网时的期望电量值; $P_{\max,t}^C$ 、 $P_{\max,t}^D$ 、 $E_{\max,t}$ 、 $E_{\min,t}$ 分别为 EV 在时段 t 实际所能达到的最大充放电功率及能量边界。能量上下限约束

及能量范围影响下对应时段的功率上限约束如下：

$$\begin{cases} E_{\max,t} = \min\{E_{\max}, E_0 + P_{\max}^C \eta^C (t - t^{\text{arr}})\} \\ E_{\min,t} = \max\{E_{\min}, E_0 - P_{\max}^D (t - t^{\text{arr}}) / \eta^D, \\ E^{\text{exp}} - P_{\max}^C \eta^C (t^{\text{dep}} - t)\} \\ P_{\max,t}^C = P_{\max,t} = \min\{(E_{\max,t+1} - E_{\min,t}) / \Delta t, P_{\max}^C\} \\ P_{\max,t}^D = -P_{\min,t} = \max\{(E_{\min,t+1} - E_{\max,t}) / \Delta t, -P_{\max}^D\} \end{cases} \quad (2)$$

式中： $E_{\max}$ 、 $E_{\min}$ 、 E_0 分别为EV电池运行容量的上下限及EV初始电量； $P_{\max}^C$ 、 $P_{\max}^D$ 分别为EV的最大充放电功率。

单辆EV的充放电灵活性可由其功率和能量边界共同刻画。将上述可调节容量的功率与能量表征模型转化为在欧几里得空间下以半平面形式表征的polytope集进行表达^[17]，其紧凑形式为

$$\Phi_i = \{P_i \in \mathbb{R}^{2m} \mid M_i P_i \leq H_i\} \quad (3)$$

式中： Φ_i 为EV的功率可行域，表示为功率约束、能量约束的集合，在可行域内，EV可以允许的任意功率水平进行充放电； m 为充放电总时段数； $P_i = [(P_i^C)^T, (P_i^D)^T]^T$ 、 P_i^C 、 P_i^D 均为 m 维列向量； M_i 、 H_i 分别为单个EV可行域的不等式系数矩阵和列向量，可表示为

$$M_i = \begin{bmatrix} I_m & 0 \\ 0 & I_m \\ -I_m & 0 \\ 0 & -I_m \\ U_m & -U'_m \\ -U_m & U'_m \\ A_{1 \times m} & -A'_{1 \times m} \end{bmatrix}, \quad H_i = \begin{bmatrix} P_{\max,t}^C \\ P_{\max,t}^D \\ 0 \\ 0 \\ E_{\max,t} - E_0 \\ E_0 - E_{\min,t} \\ E_0 - E^{\text{exp}} \end{bmatrix} \quad (4)$$

式中： I_m 为单位矩阵； U_m 、 U'_m 、 $A_{1 \times m}$ 、 $A'_{1 \times m}$ 为与充放电效率有关的能量约束系数矩阵，其具体表述形式如下：

$$\begin{cases} U_m = \begin{bmatrix} \eta^C \Delta t & & \\ \vdots & \ddots & \\ \eta^C \Delta t & \cdots & \eta^C \Delta t \end{bmatrix} \\ U'_m = \begin{bmatrix} \Delta t / \eta^D & & \\ \vdots & \ddots & \\ \Delta t / \eta^D & \cdots & \Delta t / \eta^D \end{bmatrix} \\ A_{1 \times m} = [-\eta^C \Delta t \quad -\eta^C \Delta t \quad \cdots \quad -\eta^C \Delta t] \\ A'_{1 \times m} = [-\Delta t / \eta^D \quad -\Delta t / \eta^D \quad \cdots \quad -\Delta t / \eta^D] \end{cases} \quad (5)$$

考虑到各时段EV充放电功率间的时耦关系，其功率可行域本质为空间中的 N 维凸多胞体结构，

如图1所示。当进行可行域聚合时，若仅基于式(1)对各EV可行域进行逐时段线性叠加，将忽略充放电行为的时间耦合特性，产生非可行区域，因此亟需建立计及功率时耦关系的EV可行域高效聚合方法。




图1 EV功率可行域示意图

Fig. 1 Diagram of EV power feasible region

1.2 基于内逼近闵可夫斯基重构聚合方法的EV集群功率可行域刻画

为提高优化决策的效率，EVA将其管辖区内参与充放电的电动汽车个体聚合形成集群聚合可行域，该可行域表征了EVA参与日前市场申报时可调节的功率范围，表达式如(6)所示。

$$\Phi = \Phi_1 \oplus \cdots \oplus \Phi_N = \{P \in \mathbb{R}^{2m} \mid P = \sum_{i=1}^N P_i, P_i \in \Phi_i\} \quad (6)$$

式中： P 为聚合后EV集群的充放电功率； Φ 为 N 辆EV的功率-能量约束共同作用下的聚合功率可行域空间； $\oplus$ 为闵可夫斯基求和符号。

以两辆EV的可行域聚合过程来示意上述聚合方法， $(k, k+1)$ 为两相邻时间步长，EV1与EV2的可调节容量分别表示为 P_1 与 P_2 。聚合后的功率可行域表示为 P_2 的顶点沿 P_1 的可行域包络线连续运动一周扫过的区域与 P_1 本身的并集^[10]。虽然上述聚合方法得到的可行域是精确的，但是在半平面中多胞体的闵可夫斯基求和为NP-hard问题，具有很大的计算复杂度。因此，本文采用一种改进的内逼近闵可夫斯基聚合方法，在提高计算效率的同时，最大化内逼近聚合区域，提高聚合精度。

该内逼近重构聚合过程主要包含基集构造、仿射变换和集群整合3个环节，其原理如图2所示。首先，在EVA中构造一个可行域基集 Φ_0 ，现有的基集设定方法包括正方形法^[20]、多面值法^[6]、平均化法^[21]等，本文通过平均聚合商内所有EV的参数得到 M_0 和 H_0 。对于异质性的EV集群，对 Φ_0 进行

伸缩和平移来近似每辆 EV 的功率可行域, 通过计算最优多胞体包含问题生成一系列最优同构多胞体 Φ'_i , 得到各异质 EV 的最优近似可行域。仿射变换及同构多胞体求和过程可表示为:

$$\Phi'_i = \beta_i \Phi_0 + \mathbf{v}_i = \{\mathbf{P}_i \in \mathbb{R}^{2m} \mid \mathbf{M}_0(\mathbf{P}_i - \mathbf{v}_i) \leq \beta_i \mathbf{H}_0\} \quad (7)$$

$$\left(\sum_{i=1}^N \beta_i\right)\Phi_0 + \left(\sum_{i=1}^N \mathbf{v}_i\right) \subseteq \bigoplus_{i=1}^N (\beta_i \Phi_0 + \mathbf{v}_i) \subseteq \bigoplus_{i=1}^N \Phi'_i \quad (8)$$

式中: Φ'_i 为 Φ_i 的内部近似可行域; $\beta_i \in \mathbb{R}$, 为第 i 辆 EV 的缩放因子, 用于缩放基集并确定可行域的大小; $\mathbf{v}_i \in \mathbb{R}^{m \times 1}$, 为第 i 辆 EV 的平移因子, 用于平移基集并确定可行域的位置。式(8)反应了本文内逼近闵可夫斯基聚合可行域、传统内逼近闵可夫斯基聚合可行域与精确闵可夫斯基聚合可行域之间的包含关系。




图2 内逼近重构聚合原理图

Fig. 2 Inner approximation aggregation principle diagram

为了得到单辆 EV 的最大内近似区域, 需保证基集经仿射变换后形成的内逼近多胞体体积最大, 建立如下最优多胞体包含问题:

$$\begin{cases} \max \text{Vol}(\Phi'_i) \\ \Phi'_i = \beta_i \Phi_0 + \mathbf{v}_i \subseteq \Phi_i \end{cases} \quad (9)$$

式中: $\text{Vol}(\cdot)$ 表示 $2m$ 维体积函数; 同构多胞体 Φ'_i 的体积可由式(10)确定^[14]:

$$\text{Vol}(\Phi'_i) = |\det(\beta_i \mathbf{I}_{2m})| \text{Vol}(\Phi_0) = \beta_i^{2m} \text{Vol}(\Phi_0) \quad (10)$$

可行域基集 Φ_0 体积为一定值, 因此, 有 $\text{Vol}(\Phi'_i) \propto \beta_i^{2m}$, 式(9)可转化为如下问题。对第 i 辆 EV 的缩放因子 β_i 和平移因子 $\mathbf{v}_i$ 进行优化, 求解该最大化问题即可准确得到第 i 辆 EV 的最大内近似区域。

$$\begin{cases} \max_{\beta_i, \mathbf{v}_i} \beta_i \\ \beta_i \Phi_0 + \mathbf{v}_i \subseteq \Phi_i, \beta_i \geq 0 \end{cases} \quad (11)$$

考虑到高维多胞体体积精确计算的困难度, 本

文不直接求解式(11)的优化问题, 而是通过强对偶原理引入高维变量 $\mathbf{G}$, 将其转化为一个易于求解的凸规划问题。基于 Farkas 引理, 上述最优多胞体包含问题等价于如下线性规划问题:

$$\begin{cases} \max_{\beta_i, \mathbf{v}_i} \beta_i \\ \mathbf{G} \mathbf{M}_0 = \mathbf{M}_i \\ \beta_i \mathbf{G} \mathbf{H}_0 + \mathbf{M}_i \mathbf{v}_i \leq \mathbf{H}_i \\ \beta_i \geq 0 \end{cases} \quad (12)$$

各 EV 充放电时段、充放电效率的差异性使其系数矩阵 $\mathbf{M}_i$ 和 $\mathbf{M}_0$ 存在异构性, 随着 EV 规模的增大, 上述凸规划问题的求解速率仍难以满足聚合时间要求。为进一步提高计算效率, 本文引入多胞体结构的重构过程, 通过重构 $\mathbf{M}_0$, 将基集的多胞体可行域变形, 使其具有与每辆 EV 的可行域空间相同的结构, 避免了高维变量的引入, 使式(12)的求解得到简化, 具体示意图见图3。




图3 重构过程

Fig. 3 Reconstruction process

现以 Φ_0 及 Φ_i 为例说明此重构过程。对比两者系数矩阵, 记 $\mathbf{M}_i$ 中与 $\mathbf{M}_0$ 有差异的行向量组成的矩阵为 $\mathbf{m}_i$, 对于多胞体 Φ_0 , 在 Φ_0 上增加一系列额外的线性约束 $\mathbf{m}_i \mathbf{P}_i \leq \mathbf{h}_i$, 若满足式(13), 则 $\mathbf{m}_i \mathbf{P}_i \leq \mathbf{h}_i$ 为冗余约束, 增加或删除不会改变原多胞体。

$$\Phi_0 \subseteq \{\mathbf{P}_i \in \mathbb{R}^{2m} \mid \begin{bmatrix} \mathbf{M}_0 \\ \mathbf{m}_i \end{bmatrix} \mathbf{P}_i \leq \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{h}_i \end{bmatrix}\} \quad (13)$$

式中列向量 $\mathbf{h}_i$ 为待定参数。

为得到更精确的解, $\mathbf{h}_i$ 的取值应尽可能的保证式(13)的成立, $\mathbf{h}_i$ 中各元素的最优取值可通过求解如下线性规划问题获得:

$$\begin{cases} \mathbf{h}_i(s) = \max_{\mathbf{P}_i} \mathbf{m}_i(s) \mathbf{P}_i \\ \mathbf{M}_0 \mathbf{P}_i \leq \mathbf{H}_0 \end{cases} \quad (14)$$

式中 $\mathbf{m}_i(s)$ 、 $\mathbf{h}_i(s)$ 分别为差异系数矩阵和待定参数向量的第 s 行。对于式(14)计算得到的 $\mathbf{h}_i$, 冗余约束

$\mathbf{m}_1 \mathbf{P}_i \leq \mathbf{h}_i$ 表示与基集多胞体 Φ_0 相切的超平面集。将 Φ_0 中对应位置的约束式替换为 $\mathbf{m}_1 \mathbf{P}_i \leq \mathbf{h}_i$ ，记生成的新多胞体为 Φ'_0 ，有：

$$\Phi'_0 = \{\mathbf{P}_i \in \mathbb{R}^{2m} | \mathbf{G} \mathbf{M}_0 \mathbf{P}_i \leq \mathbf{G} \mathbf{H}_0\} = \{\mathbf{P}_i \in \mathbb{R}^{2m} |$$

$$[\mathbf{M}'_0 \ \mathbf{m}_1]^T \mathbf{P}_i \leq [\mathbf{H}'_0 \ \mathbf{h}_1]^T\} = \{\mathbf{P}_i \in \mathbb{R}^{2m} | \mathbf{M}_i \mathbf{P}_i \leq \hat{\mathbf{H}}_0\} \quad (15)$$

式中： $\mathbf{M}'_0$ 、 $\mathbf{H}'_0$ 分别为 $\mathbf{M}_0$ 去掉差异行向量后形成的系数矩阵和列向量； $\hat{\mathbf{H}}_0$ 为重构后的基集多胞体列向量。

通过上述重构过程实现对 Φ_0 的变形，重构后的 $\mathbf{M}_0$ 与 $\mathbf{M}_i$ 完全相同。此时式(12)的求解可简化为

$$\begin{cases} \max_{\beta_i, \mathbf{v}_i} \beta_i \\ \beta_i \hat{\mathbf{H}}_0 + \mathbf{M}_i \mathbf{v}_i \leq \mathbf{H}_i \\ \beta_i \geq 0 \end{cases} \quad (16)$$

由式(4)可知， $\mathbf{M}_i$ 与 $\mathbf{M}_0$ 中大部分元素相同，只有与能量约束有关的后 $(2m+1)$ 行可能存在差异，因此，重构过程计算效率较高。同时，新生成多胞体 Φ'_0 的系数矩阵与每辆 EV 多胞体 Φ_i 的系数矩阵具有相同的结构，在此基础上进行的仿射变换保留了每辆 EV 个体可行域的结构，也显著提高内逼近方法的近似精度。

通过上述过程完成每辆 EV 缩放因子及平移因子的优化，EV 集群最大内逼近聚合可行域可表示为

$$\Phi = \Phi_1 \oplus \dots \oplus \Phi_N = \left(\sum_{i=1}^N \beta_i\right) \Phi_0 + \left(\sum_{i=1}^N \mathbf{v}_i\right) \quad (17)$$

2 计及用户出行信息不确定性的EV集群聚合可行域鲁棒边界建模

确定性可行域边界在聚合过程中未考虑 EV 用户行为的随机性，提高了 EVA 参与联合市场申报策略的失效风险。因此，本节在聚合过程中融合 EV 初始电量和用户入离网时间的不确定性建模，实现确定性边界到鲁棒边界的转化。

2.1 初始电量不确定性建模

由式(4)可知，EV 初始电量仅对能量约束的右侧列向量，即 $\mathbf{H}_i$ 的后 $(2m+1)$ 行产生影响，因此 EV 初始电量的不确定性表现为矩阵 $\mathbf{H}_i$ 的不确定性。将 $\mathbf{H}_i$ 视为随机变量，引入联合机会约束描述用户初始电量的不确定性，将式(3)描述为

$$P_{f(\mathbf{H}_i)}\{\mathbf{M}_i \mathbf{P}_i \leq \mathbf{H}_i\} \geq 1 - \varepsilon \quad (18)$$

式中： ε 为允许的违反概率； $1-\varepsilon$ 为置信水平； $f(\mathbf{H}_i)$ 为 $\mathbf{H}_i$ 的概率分布函数。该式表示不确定性环境下

满足 EV 功率-能量约束的概率应不低于给定置信水平。

考虑到 EV 集群初始电量的概率分布虽无法准确获取，但其均值、协方差矩阵等部分广义矩信息可估计，因此，本文基于初始电量分布的广义矩信息，构建如下概率分布的模糊集：

$$D = \left\{ f(\mathbf{H}_i) \left| \begin{array}{l} E[\mathbf{H}_i] = \boldsymbol{\mu} \\ E[(\mathbf{H}_i - \boldsymbol{\mu})(\mathbf{H}_i - \boldsymbol{\mu})^T] = \boldsymbol{\Sigma} \end{array} \right. \right\} \quad (19)$$

式中： $E[\cdot]$ 为期望算子； $\boldsymbol{\mu}$ 和 $\boldsymbol{\Sigma}$ 分别为初始电量分布的经验均值向量和协方差矩阵。

同时，为增强聚合可行域的鲁棒性，基于上述构造的模糊集 D ，本文在分布鲁棒框架下对联合机会约束式(18)进行处理，将其重新描述为如下分布鲁棒联合机会约束 (distributionally robust joint chance constraints, DRJCC) 形式。

$$\inf_{f(\mathbf{H}_i) \in D} P\{\mathbf{M}_i \mathbf{P}_i \leq \mathbf{H}_i\} \geq 1 - \varepsilon \quad (20)$$

将式(20)与内逼近闵可夫斯基重构聚合方法相结合，在考虑最大内逼近问题时引入上述 DRJCC，式(11)中约束所示的最优多胞体包含问题可写为如下形式：

$$\inf_{f(\mathbf{H}_i) \in D} P\{\mathbf{M}_i \mathbf{P}_i \leq \mathbf{H}_i | \mathbf{M}_0(\mathbf{P}_i - \mathbf{v}_i) \leq \beta_i \mathbf{H}_0\} \geq 1 - \varepsilon \quad (21)$$

式(21)表示计及 $\mathbf{H}_i$ 不确定性的聚合过程中，最大内近似多胞体 Φ'_i 仍内包含于原 EV 可行域 Φ_i 的概率不低于给定置信水平。通过重构过程，在式(16)框架下可将式(21)等效转化为

$$\inf_{f(\mathbf{H}_i) \in D} P\{\beta_i \hat{\mathbf{H}}_0 + \mathbf{M}_i \mathbf{v}_i \leq \mathbf{H}_i\} \geq 1 - \varepsilon \quad (22)$$

根据文献[22]，式(22)可转化为式(23)所示线性规划问题，实现式(3)及(11)由确定性条件到计及初始电量不确定性条件的转化。考虑到 EV 可行域为一完整的高维凸多胞体，在整个调度周期内其鲁棒性应统一进行概率刻画，因此，本文对每条约束统一设定相同的违反概率 ε_s 。

$$\begin{cases} \beta_i \hat{\mathbf{H}}_0(s') + \mathbf{M}_i(s', :)\mathbf{v}_i \leq \mathbf{H}_i(s') \\ \beta_i \hat{\mathbf{H}}_0(s) + \mathbf{M}_i(s, :)\mathbf{v}_i + \sqrt{\frac{1 - \varepsilon_s}{\varepsilon_s}} \boldsymbol{\Sigma}(s) - \boldsymbol{\mu}(s) \leq 0 \\ \varepsilon_s = \varepsilon / L \\ s' \in C_n, s \in C_u \end{cases} \quad (23)$$

式中： C_n 为 $\mathbf{H}_i$ 中不含不确定性参数 E_0 的前 $4m$ 行的集合； C_u 为 $\mathbf{H}_i$ 中含有不确定性参数 E_0 的后 $(2m+1)$ 行的集合； ε_s 为第 s 行约束的允许违反概

率; L 为 C_u 中所含元素的个数。

2.2 入离网时间不确定性建模

在使用上述内逼近聚合方法时, 必须保证参与聚合的所有 EV 具有相同的充放电时段, 即当 Φ_0 与 Φ_i 具有相同维度时, 各多胞体才具有闵可夫斯基可加性。但由于 EV 入离网行为的随机性, 将导致各 Φ_i 维度不同, 无法直接进行聚合, 因此, 需要对多胞体的维度进行预处理, 将其统一扩展至 T 个充放电时段。增广后的 $\tilde{\mathbf{M}}_i$ 矩阵如式(24)所示。

$$\tilde{\mathbf{M}}_i = \begin{bmatrix} 0 & \mathbf{I}_m & 0 & 0 & 0 \\ 0 & 0 & 0 & \mathbf{I}_m & 0 \\ 0 & -\mathbf{I}_m & 0 & 0 & 0 \\ 0 & 0 & 0 & -\mathbf{I}_m & 0 \\ 0 & \mathbf{U}_m & 0 & -\mathbf{U}_m' & 0 \\ 0 & -\mathbf{U}_m & 0 & \mathbf{U}_m' & 0 \\ 0 & -\mathbf{A}_{1 \times m} & 0 & \mathbf{A}_{1 \times m}' & 0 \end{bmatrix} \quad (24)$$

$$m = t^{\text{dep}} - t^{\text{arr}} \quad (25)$$

对每辆 EV, 考虑其入离网时间可能在前后 t 时段内波动, 入离网时间将影响可行域维度, 因此, 其不确定性表现为矩阵 $\tilde{\mathbf{M}}_i$ 的不确定性, 为离散形式变化, 因此, 构建入离网时间影响下矩阵 $\tilde{\mathbf{M}}_i$ 的盒式不确定集。

$$\mathbf{U} = \left\{ \tilde{\mathbf{M}}_{i,n} \left| \begin{array}{l} m_n = \tilde{t}_n^{\text{dep}} - \tilde{t}_n^{\text{arr}} \\ \tilde{t}_n^{\text{arr}} = t^{\text{arr}} \pm \Delta t_n \\ \tilde{t}_n^{\text{dep}} = t^{\text{dep}} \pm \Delta t_n \\ \Delta t_n \in [0, t] \end{array} \right. \right\} \quad (26)$$

式中: $\tilde{\mathbf{M}}_{i,n}$ 为第 i 辆 EV 在第 n 个场景下的可行域不等式系数矩阵; $\tilde{t}_n^{\text{arr}}$ 和 $\tilde{t}_n^{\text{dep}}$ 分别为考虑波动后的入离网时间; Δt_n 为 EV 在第 n 个场景下入离网时段波动数的取值; m_n 为 EV 在第 n 个场景下的充放电总时段数。

为有效应对入离网时间不确定性, 生成灵活性功率聚合可行域, 本文将入离网时间波动的各场景融入式(23), 将其转化为如下计及多场景的分布鲁棒(distributed robust optimization, DRO)约束形式:

$$\begin{cases} \beta_{i,n} \hat{\mathbf{H}}_0(s') + \tilde{\mathbf{M}}_{i,n}(s';:)\mathbf{v}_{i,n} \leq \mathbf{H}_i(s') \\ \beta_{i,n} \hat{\mathbf{H}}_0(s) + \tilde{\mathbf{M}}_{i,n}(s,:)\mathbf{v}_{i,n} + \sqrt{(1-\varepsilon_s)/\varepsilon_s} \boldsymbol{\Sigma}(s) - \boldsymbol{\mu}(s) \leq 0 \\ \varepsilon_s = \varepsilon/L \\ \tilde{\mathbf{M}}_{i,n} \in \mathbf{U}, s' \in C_n, s \in C_u \end{cases} \quad (27)$$

式中 $\beta_{i,n}$ 、 $\mathbf{v}_{i,n}$ 分别为第 i 辆 EV 在第 n 个场景下的缩放因子和平移因子。

2.3 EV 聚合可行域鲁棒边界建模

考虑到上述不确定性因素对 EV 聚合可行域边界的影响, 在优化求解第 i 辆 EV 的缩放因子 β_i 和平移因子 $\mathbf{v}_i$ 时, 基于 2.1 与 2.2 节中的不确定因素建模, 刻画 EV 集群可行域鲁棒边界。此时式(16)将转化为计及用户不确定性因素的式(28)。

$$\begin{cases} \max_{\beta_{i,n}} (\min_{\{\lambda_n \in \psi\}} \sum_{n=1}^N \lambda_n \beta_{i,n}) \\ \beta_{i,n} \hat{\mathbf{H}}_0(s') + \tilde{\mathbf{M}}_{i,n}(s';:)\mathbf{v}_{i,n} \leq \mathbf{H}_i(s') \\ \beta_{i,n} \hat{\mathbf{H}}_0(s) + \tilde{\mathbf{M}}_{i,n}(s,:)\mathbf{v}_{i,n} + \sqrt{\frac{1-\varepsilon_s}{\varepsilon_s}} \boldsymbol{\Sigma}(s) - \boldsymbol{\mu}(s) \leq 0 \\ \varepsilon_s = \varepsilon/L \\ s' \in C_n, s \in C_u \\ \tilde{\mathbf{M}}_{i,n} \in \mathbf{U} \end{cases} \quad (28)$$

式中: λ_n 为第 n 个场景的概率; ψ 为场景概率模糊分布的置信集。

所提出的综合考虑用户出行信息不确定性的聚合可行域鲁棒边界模型为双层结构, 内层问题通过最小化 EV 缩放因子确定入离网时间最恶劣场景的概率分布, 外层问题则通过内逼近闵可夫斯基重构造聚合方法求解单辆 EV 的最大缩放因子, 以确定最大内近似可行域。

内层模型在求解入离网时间最恶劣场景的概率分布时, 为了使场景概率在一定范围内波动并贴合实际数据, 设置包含 1-范数和 ∞ -范数的综合范数约束, 构造场景概率模糊分布的置信集^[23]。

3 基于数据驱动不确定集的 EVA 参与联合市场的鲁棒决策方法

本节聚焦 EVA 参与能量-调频辅助服务市场, 验证所提聚合方法的有效性, 并进一步分析用户出行信息与市场价格等多元不确定因素对 EVA 申报策略与收益水平的影响。

3.1 基于极限场景法的椭圆不确定集构建

为改善区间不确定集忽略不确定参数分布特性导致保守性过高的问题, 本文结合 MVEE、lift-and-project 算法与极限场景法的思想建立了调频价格的数据驱动不确定集, 有效剔除了区间不确定集中调频价格的不合理组合, 在降低保守性的同时保证了方案的鲁棒性^[24]。

其中, 极限场景定义为沿椭圆对称轴方向生成的四顶点场景, 即图 4 中红色“x”表示的 4 个顶点, 其物理意义为价格波动的极端相关性组合, 因

此椭球不确定集构建已涵盖调频价格显著波动的典型工况。




图4 调频价格不确定集构建流程

Fig.4 Construction process of the frequency regulation price uncertainty set

调频价格椭球不确定集构建流程见图4。

最后，修正后的极限场景可通过式(29)求得，修正后的不确定集^[25]如式(30)所示。

$$\Pi_{e,i} = c + k_{\max} \mathbf{P}_{\text{rot}}^{-1} \Pi'_{e,i} = c + k_{\max} (\Pi_{e,i} - c) \quad (29)$$

$$\Pi \in \Pi_{\text{cor}} = \left\{ \Pi \in \mathbb{R}^n \left| \begin{array}{l} \Pi = \sum_{i=1}^{N_e} p_i \Pi_{e,i} \\ \sum_{i=1}^{N_e} p_i = 1, p_i \geq 0 \end{array} \right. \right\} \quad (30)$$

式中： $\Pi_{e,i}$ 、 $\Pi'_{e,i}$ 分别为初始极限场景及修正后的极限场景； $\Pi'_{e,i}$ 为旋转变换后的椭球顶点坐标； c 为椭球体中心顶点； $k_{\max}$ 为引入的比例因子； $\mathbf{P}_{\text{rot}}$ 为正定矩阵； Π 为修正后的不确定集； N_e 为顶点个数； p_i 为 $\Pi_{e,i}$ 对应的系数。

3.2 能量-调频市场的两阶段三层鲁棒优化模型

目前，对不确定性的处理主要分为随机优化与鲁棒优化两大类^[26]，考虑到随机优化对历史数据准确度依赖性强，而传统鲁棒优化模型存在求解效率低、保守性高等问题，本节采用数据驱动的椭球集刻画调频市场价格的不确定性，以EVA净收益最大化为目标，建立EVA参与联合市场的两阶段三层鲁棒优化模型。

其中，第一阶段为确定性优化，在预测的调频市场价格下，最大化EVA净收益。第二阶段则考虑不确定性发生后，最大化最恶劣场景下的调频市场收益。该结构体现了“收益-风险-可行性”的三重权衡，在EVA面临多重不确定性的背景下，能够提供兼顾鲁棒性与经济性的申报策略，保证解有效性的同时加快了其求解效率。

考虑到EVA的基线功率及提供的调频容量不足以影响区域电力市场的出清价格，因此EVA被当作能量市场价格接收者。模型的目标函数为

$$\max_{P_t^{\text{base}}} \min_{\xi \in \Pi} \max_{R_t^{\text{up}}, R_t^{\text{dn}}} (F_{\text{RC}} + F_{\text{RM}} - F_{\text{DA}} - F_{\text{DEG}}) \quad (31)$$

式中： P_t^{base} 为EV集群在第 t 时段内的基线功率，为第一阶段决策变量； R_t^{up} 和 R_t^{dn} 分别为第 t 时段内EVA提供的上、下调频容量，为第二阶段决策变量； Π 为调频价格不确定集； F_{RC} 、 F_{RM} 、 F_{DA} 分别为EVA参与调频辅助服务市场的调频容量收益、调频里程收益和参与日前能量市场的购电成本； F_{DEG} 为EVA因提供调频辅助服务造成的额外电池损耗成本。具体表达式如下：

$$F_{\text{RC}} = \sum_{t=1}^T \pi_t^{\text{RC}} (R_t^{\text{up}} + R_t^{\text{dn}}) \eta_t \Delta t \quad (32)$$

$$F_{\text{RM}} = \sum_{t=1}^T \pi_t^{\text{RM}} M_t \eta_t \Delta t \quad (33)$$

$$F_{\text{DA}} = \sum_{t=1}^T \pi_t^{\text{DA}} P_t^{\text{base}} \Delta t \quad (34)$$

$$F_{\text{DEG}} = \sum_{t=1}^T \pi^{\text{DEG}} (R_t^{\text{up}} l_t^{\text{up}} + R_t^{\text{dn}} l_t^{\text{dn}}) \Delta t \quad (35)$$

$$P_t = P_t^{\text{base}} + R_t^{\text{dn}} l_t^{\text{dn}} - R_t^{\text{up}} l_t^{\text{up}} \quad (36)$$

$$M_t = \sum_{\tau} |R_t^{\text{up}} (\delta_{\tau}^{\text{up}} - \delta_{\tau-1}^{\text{up}}) + R_t^{\text{dn}} (\delta_{\tau}^{\text{dn}} - \delta_{\tau-1}^{\text{dn}})| \quad (37)$$

$$l_t^{\text{up}} = \sum_{l=1}^{N_l} \frac{\max(q(t, l), 0)}{N_l} \quad (38)$$

$$l_t^{\text{dn}} = -\sum_{l=1}^{N_l} \frac{\min(q(t, l), 0)}{N_l} \quad (39)$$

式中： π_t^{DA} 、 π_t^{RC} 、 π_t^{RM} 分别为第 t 时段的能量市场、调频容量、调频里程价格； π^{DEG} 为电池传输单位电能所造成的电池损耗成本； $\delta_{\tau}^{\text{up}}$ 和 $\delta_{\tau}^{\text{dn}}$ 分别为上、下调频信号， $\delta_{\tau}^{\text{up}} \in [0, 1]$ ， $\delta_{\tau}^{\text{dn}} \in [-1, 0]$ ； M_t 为第 t 时段内的调频里程； τ 为实际运行中的时间点； η_t 为时段 t 内的运行准确度； Δt 为时间间隔； P_t 为第 t 时段内EVA的实际响应功率； l_t^{up} 和 l_t^{dn} 分别为第 t 个时段的上、下调频能量系数； $q(t, l)$ 为第 t 个时段内第 l 个调频信号，表示每次调频指令占该时

段调频服务容量的比例。

EVA 参与联合市场优化过程中的约束条件如式(40)–(43)所示。

$$\Phi = \{P \in R^{2m} \mid M_0(P_t - \sum_{i=1}^N v_i) \leq \sum_{i=1}^N \beta_i H_0, \forall t \in T\} \quad (40)$$

$$R_t^{\text{up}} \leq P_t^{\text{base}} + P_{\max}^{\text{D}} \quad (41)$$

$$R_t^{\text{dn}} \leq P_{\max}^{\text{C}} - P_t^{\text{base}} \quad (42)$$

$$-P_{\max}^{\text{D}} \leq P_t^{\text{base}} \leq P_{\max}^{\text{C}} \quad (43)$$

式(40)表示聚合后的 EV 集群功率可行域,为 3 节中聚合优化结果,其将以一系列功率、能量约束形式放入本节优化问题中。

3.3 模型求解

该优化问题为两阶段三层问题,无法直接求解,因此,本文采用基于极限场景法的改进 C&CG 算法,将原问题分解为主问题和子问题,通过两者间的交替迭代求得最优解。相较于传统近似算法可提升结果的准确性,相较于传统分解法,在每轮迭代中显式添加约束,可有效加快收敛速度。

主问题的优化模型表述如下:

$$\begin{cases} \max_{P_{\xi_k}^{\text{base}}, R_{\xi_k}^{\text{up}}, R_{\xi_k}^{\text{dn}}} (-F_{\text{DA}} + \gamma) \\ P_{\xi_k, t} = P_t^{\text{base}} + R_{\xi_k, t}^{\text{dn}} l_t^{\text{dn}} - R_{\xi_k, t}^{\text{up}} l_t^{\text{up}} \\ M_0(P_{\xi_k, t} - v) \leq \beta H_0 \\ R_{\xi_k, t}^{\text{up}} \leq P_t^{\text{base}} + P_{\max}^{\text{D}} \\ R_{\xi_k, t}^{\text{dn}} \leq P_{\max}^{\text{C}} - P_t^{\text{base}} \\ -P_{\max}^{\text{D}} \leq P_t^{\text{base}} \leq P_{\max}^{\text{C}} \\ \gamma_k \leq F_{\text{RC}}^{\xi_k} + F_{\text{RM}}^{\xi_k} - F_{\text{DEG}}^{\xi_k}, \forall k = 1, 2, \dots, n \end{cases} \quad (44)$$

式中: n 为当前算法迭代次数; ξ_k 为第 k 次迭代时选取的极限场景,由子问题计算得到并传递给主问题; γ 为主问题在多个极限场景下 EVA 参与调频市场的最大净收益。

主问题在当前已知的最恶劣极限场景下,以 EVA 净收益最大为目标,优化第一阶段决策变量 P_t^{base} , 保证其在所有场景下的可行性,并将优化所得的决策变量值传递给子问题。

子问题的优化模型表述如下:

$$\begin{cases} \min_{\xi \in \Pi} \max_{R^{\text{up}}, R^{\text{dn}}} (F_{\text{RC}} + F_{\text{RM}} - F_{\text{DEG}}) \\ P_t = P_{t, n}^{\text{base}^*} + R_t^{\text{dn}} l_t^{\text{dn}} - R_t^{\text{up}} l_t^{\text{up}} \\ M_0(P_t - v) \leq \beta H_0 \\ R_t^{\text{up}} \leq P_{t, n}^{\text{base}^*} + P_{\max}^{\text{D}} \\ R_t^{\text{dn}} \leq P_{\max}^{\text{C}} - P_{t, n}^{\text{base}^*} \end{cases} \quad (45)$$

式中 $P_{t, n}^{\text{base}^*}$ 为第 n 次迭代时主问题求解得到的 EVA 参与联合市场申报时的基线功率取值。

子问题在主问题给定的决策基础上,以 EVA 调频净收益最大为目标,在调频价格不确定集中优化第二阶段决策变量 R_t^{up} 及 R_t^{dn} , 搜索并选取最恶劣的极限场景,并将该极限场景反馈给主问题。

初始化下界 $L_B = -\infty$ 、上界 $U_B = +\infty$ 、收敛误差 $\varepsilon = 10^{-3}$ 。主问题与子问题交替迭代,上界逐步收缩、下界逐步提升,当上下界差值满足收敛误差的要求时,即可得到该问题的全局最优解。

数据驱动鲁棒优化算法流程如图 5 所示。

4 算例分析

4.1 算例设置

本文采用的市场数据为美国 PJM 市场 2020 年 1 月 25 日的 RegD 调频指示信号和市场价格数据^[27]。本文算例基于居民区典型场景,设置 EV 集群规模为 200 辆, EV 仿真参数参考文献[28],采用蒙特卡洛方法模拟生成 EV 数据,具体参数如表 1 所示, EV 的电池运行容量下限为 $0.2E_{\text{cap}}$, EV 用户的期望离网电量为 $0.9E_{\text{cap}}$ 。该参数设置能够有效反映 EV 出行行为的多样性特征,同时,也较好契合居民区场景中 EV 用户的实际出行规律。

依照本文设定市场规则,模型仿真时长为 24 个时段,每时段为 1 h, RegD 信号的采样时长为 5 min,每小时 12 个时间段。

4.2 聚合方法有效性验证

为了证明本文所提聚合方法的有效性和优越性,设置如下算例,与现有文献中其他几种传统聚合方法进行对比验证:

方法 1: 基于盒子的内逼近方法;

方法 2: 基于奇诺多面体的内逼近方法;

方法 3: 外逼近方法;

方法 4: 单辆 EV 参与市场的集中控制方法;

方法 5: 本文所提内逼近闵可夫斯基重构聚合方法。

考虑到实际运行中, EVA 所管理和服务的 EV 数量通常达到成百上千辆, EVA 往往聚合数百辆 EV 用于资源申报,以满足市场准入门槛的要求,因此本节仍采用 4.1 节算例设置,基于 200 辆 EV 的场景对各聚合方法进行对比分析。此外,为直观展现不同聚合方法聚合边界的差异,设置小规模场景对比,参数设置及对比结果详见附录 A。




图 5 数据驱动鲁棒优化算法

Fig. 5 Data-driven robust optimization algorithm

表 1 EV 仿真参数设置	
Table 1 EV Simulation parameter settings	
参数	数值
t^{arr}	$N(19.2^2)$
t^{dep}	$N(8.2^2)$
SOC_0	$N(0.5, 0.03^2)$
$E_{\text{cap}}/(\text{kW} \cdot \text{h})$	$U(50, 60)$
$P_{\text{max}}^{\text{C}}, P_{\text{max}}^{\text{D}}/\text{kW}$	$U(6, 7)$
$\eta^{\text{C}}, \eta^{\text{D}}$	$U(0.85, 0.95)$

分别采用上述 5 种聚合方法得到 EVA 聚合可行域,以 EVA 参与能量-调频市场为例对计算时间、EVA 收益、近似精度、时间增量等数据进行对比分析。目前,对于高维凸多胞体的体积仍无精确计算方法,但不同聚合方法形成的可行域在优化问题中能保持最优解所在区域的一致性,因此,优化结果可间接反映聚合模型的近似精度。时间增量是指 EV 规模从 100 辆增加到 200 辆时增加的计算时间。对比结果如图 6 所示。

对比图 6 各聚合方法的结果可知,方法 3 可使 EVA 获得更大的净收益,但是,该外逼近方法中,每次聚合均对异构多胞体可行域依次增加额外线




图 6 不同聚合方法的比较

Fig. 6 Comparison of different aggregation methods

性约束, EV 规模增大时计算复杂度增加,将增大聚合时间,且外逼近方法会引入额外冗余区域,使集群的可行域扩大,在实际运行时可能无法满足系统调频需求及 EV 充电需求,存在越限风险,具有较大局限性。除此之外,方法 4 表现出较好的经济性,在该方法中,每辆 EV 个体均单独建模并参与能量-调频市场申报,无聚合误差引入,因此其优化结果最贴近实际情况,但计算时间过长,在实际申报过程中应用该方法并不现实,其聚合结果可作为基准值,以评估各聚合方法的有效性。

不同内逼近闵可夫斯基聚合方法下 EVA 响应能力边界如图 7 所示。本文方法通过生成最优同构多胞体,在满足实际运行可行性的同时,使 EVA 具有更大的内近似聚合可行域,各时刻集群功率边界增大,聚合精确度更高,在参与市场申报时具备更大的灵活性。




图 7 不同内逼近聚合方法下 EVA 功率边界
Fig. 7 Power boundaries of EVAs under different inner approximation aggregation methods

与方法 1、2 两种内逼近聚合方法相比,本文提出的内逼近重构聚合方法降低了购电成本,提高了调频收益,使 EVA 净收益分别提高了 59.41% 和 24.96%,相对于基准值的误差更小,仅有 3.32%。同时,由于重构方法的引入,本文方法计算时间仅需 9.91 s,相较于前两种方法分别提高 61.5% 和 88.3%。且该方法支持多线程并行计算,在理想化计算与通信条件下,聚合千辆级 EV 时可求解时间维持在秒级,在处理大规模 EV 集群聚合问题时效率更高。因此,本文所提聚合模型可同时兼顾逼近精度和计算效率,具有更好的聚合效果和实用性。

考虑用户出行信息及调频价格的不确定性后,各内逼近聚合方法的整体效果对比如图 8 所示。以方法 4 优化结果作为基准值,与方法 1、2 两种内逼近聚合方法相比,本文聚合方法具有最优的可行域近似精度及 EVA 净收益,因此在计及不确定性的整体层面,本文方法仍具有更好的聚合效果,可实现全局效果最优。

需要注意的是,对于车辆充电过程中突然离网的情况,若未能满足离网电量约束,将导致个体可行域无法准确刻画。但在绝大多数 EV 连接稳定、充电计划连续的典型情形下,本文所用重构聚合方法均可保证有效性与高效性。




图 8 不同内逼近聚合方法整体效果对比
Fig. 8 Comparison of overall effects of different inner approximation aggregation methods

4.3 鲁棒优化申报策略分析

为了分析用户出行信息及调频价格不确定性对 EVA 申报策略的影响,验证本文所提鲁棒决策方法在兼顾收益与风险方面的优势,本节设置以下 4 种场景进行对比分析。场景 1: 不考虑不确定性因素的影响,为确定性优化;场景 2: 只考虑用户出行信息的不确定性;场景 3: 只考虑调频价格的不确定性;场景 4: 同时考虑用户出行信息及调频价格的不确定性(本文所提模型)。其中,场景 1 和 4 初始电量不确定度(标准差/均值)取 0.06,入离网时间允许在前后两个充放电时段内波动,置信水平取 90%。

4.3.1 EVA 净收益与策略失效风险

为同时分析申报策略的失效风险,本文基于蒙特卡洛抽样方法随机生成 1000 个样本,以检验实际情况中申报策略的可行性。不同场景下 EVA 参与能量-调频市场的净收益及申报策略的失效率如表 2 所示。

表 2 EVA 净收益及策略失效率				
Table 2 EVA net revenue and strategy failure rate				
场景	购电成本/元	调频净收益/元	EVA 净收益/元	失效率/%
1	36.579	380.864	344.285	94.7
2	40.963	357.470	316.507	15.2
3	38.172	370.151	331.979	88.5
4	42.615	341.267	298.652	10.1

策略的失效率是指由于用户出行行为及调频价格的不确定性导致聚合结果无法覆盖申报功率的次数占样本总数的百分比。由表 2 可知,确定性优化下 EVA 的净收益最高,但此时申报策略的失效率高达 94.7%。若以确定性优化指导 EVA 申报策略的制定,次日用户行为及市场环境产生的较小变化即会导致日前申报策略失效,无法满足系统调频

及用户充电需求, 将给 EVA 带来较大损失。对比场景 2 与 3 可知, 仅考虑调频价格不确定性时 EVA 净收益更高, 但仅比场景二高 4.66%, 同时, 场景 3 策略失效率虽比确定性优化时有所降低, 但仍比场景 2 高 73.3%, 因此实际运行中用户行为不确定性带来的风险将远高于调频价格不确定性, 但其对 EVA 净收益的影响不大。对于场景 4 同时考虑两者不确定性的情况, EVA 净收益比场景 1 降低了 13.25%, 但此时失效率仅为 10.1%, 可知, EVA 在进行日前申报时, 同时计及用户行为及市场的不确定性可在很大程度上规避实际运行中不确定性环境带来的风险, 在尽可能减小 EVA 净收益损失的同时, 保证申报策略的有效性, 以实现 EVA 整体收益最大化。

4.3.2 鲁棒申报策略分析

场景 1 与 4 中, EVA 参与能量-调频辅助服务市场的申报策略如图 9 所示。图中蓝色虚线代表场景 1 确定性优化下 EVA 申报策略, 实色柱状图为场景 4 考虑不确定性因素后的 EVA 申报策略。为了显示方便, 本文所有图中上调频容量均显示为负。




图 9 EVA 申报策略对比

Fig. 9 Comparison of EVA declaration strategies

总体来看, 考虑不确定性前后 EVA 申报策略的变化趋势保持一致, 均在凌晨购电价格低时段充电, 在并网前后高电价时段放电, 以获取更大收益。对比两者图像, 考虑不确定性环境后, EVA 将采取更加保守的申报策略, 在日前功率申报时增大基线功率申报, 减小上下调频容量的申报, 以预留更大裕度, 确保实际运行中申报策略的有效性。如在凌晨至离网前, 考虑到用户提前取车出行及调频价格变化等不确定性因素的影响, EVA 充电功率申报量明显增大, 上调频容量的申报量明显减小, 且 03:00

基线功率由确定性优化情况下的放电功率变为充电功率, 以满足用户电量需求。19:00 左右为傍晚用户入网时段, 考虑到用户延后充电等不确定性情况, EVA 下调频容量明显减小, 以满足系统调频需求。

4.4 灵敏度分析

本节通过设置不同的置信水平, 分析其对申报策略及 EVA 净收益的影响。令初始电量的不确定度取 0.06, 入离网时间允许在前后两个充放电时段内波动。当违反概率取不同值时, 不同置信水平下的 EVA 申报策略如图 10 所示。由图 10 可知, 当置信水平较小时, EVA 倾向于采取更为激进的申报策略, 即在日前市场中申报较小的基线功率, 以降低购电成本, 同时在调频市场中申报更大的上下调频容量, 以获取更多调频收益。尽管潜在收益增加, 但调度不可行的风险也随之上升。随着置信水平的增大, EVA 将以降低其自身净收益为代价采取更为保守的申报策略, 适当增大基线功率申报、减少上下调频容量申报, 以优先保障调度方案的可行性, 从而更好应对用户行为随机性及调频价格不确定性的影响, 降低申报风险。




图 10 不同置信水平下的 EVA 申报策略

Fig. 10 EVA declaration strategies under different confidence levels

进一步分析不同置信水平下各时刻 EVA 的净收益, 结果如图 11 所示。在多数时段, 置信水平越低, EVA 净收益越大。但在部分时刻, 如 19:00、20:00, 置信水平为 97% 时, EVA 净收益最大, 与图 10 结合分析可知, 该时刻 EVA 申报基线功率为较大的放电功率, 置信水平越高, 申报放电功率越大, 收益更高。但总体来看, 置信水平越高, EVA 净收益越小, 策略失效率越低。




图 11 不同置信水平下各时刻 EVA 净收益

Fig. 11 EVA net revenue at each time point under different confidence levels

因此, EVA 进行日前功率申报时,可调整违反概率的取值,依据其风险偏好及期望净收益设置相应置信水平,从而指导自身申报策略的制定,实现收益与风险的平衡。

5 结论

本文提出计及用户出行信息不确定性的电动汽车可行域重构聚合与鲁棒决策方法,通过算例分析,得到结论如下:

1) 构建内逼近闵可夫斯基重构聚合方法,在仿射变换过程中引入重构过程,极大提高了聚合精度与效率。与传统方法相比,兼顾了计算效率与逼近精度,在理想化计算与通信条件下,可实现千辆级 EV 聚合求解时间降至秒级,在处理大规模 EV 集群聚合问题时效率更高,该方法也适用于其他具有储能特性的灵活性资源。

2) 对计及用户行为不确定性的聚合可行域鲁棒边界建模,同时考虑调频价格的不确定性,可平衡收益与风险,在尽可能减小 EVA 净收益损失的同时,保证申报策略的有效性。

3) 随着置信水平的增大, EVA 将以降低净收益为代价,采取更为保守的申报策略,增大基线功率申报,减少调频容量申报,以应对不确定性环境的影响,降低策略失效风险。EVA 可根据自身需要选择不同置信水平,指导其日前申报策略。

本文为 EVA 参与多元市场提供可行的申报策略,提高了策略的鲁棒性,降低了求解难度,对 EV 支撑电力系统稳定运行具有参考意义。后续研究将重点关注 EV 在网状态突变对可行域建模及聚合方法鲁棒性的影响,并进一步探讨能量-调频-调峰等多元市场耦合下的联合收益优化问题。

参考文献

- [1] 董玮,施志明,张晓琳,等. 计及新能源场站调频时延的电力系统频率响应模型及应用[J]. 中国电机工程学报, 2025, 45(12): 4657-4668.
DONG Wei, SHI Zhiming, ZHANG Xiaolin, et al. Frequency response model and application of power system considering the frequency regulation delay of renewable energy station[J]. Proceedings of the CSEE, 2025, 45(12): 4657-4668(in Chinese).
- [2] 董昱,孙大雁,许丹,等. 新型电力系统电力电量平衡的挑战、应对与展望[J]. 中国电机工程学报, 2025, 45(6): 2039-2056.
DONG Yu, SUN Dayan, XU Dan, et al. Challenges, response and prospects for power balance in new power systems[J]. Proceedings of the CSEE, 2025, 45(6): 2039-2056(in Chinese).
- [3] 胡泽春,宋永华,刘辉. 电动汽车与电网互动的调控策略[M]. 北京: 科学出版社, 2019: 195-237.
HU Zechun, SONG Yonghua, LIU Hui. Electric vehicle and power grid interaction: dispatch and control strategies [M]. Beijing: Science Press, 2019: 195-237(in Chinese).
- [4] ZHENG Yanchong, NIU Songyan, SHANG Yitong, et al. Integrating plug-in electric vehicles into power grids: a comprehensive review on power interaction mode, scheduling methodology and mathematical foundation[J]. Renewable and Sustainable Energy Reviews, 2019, 112: 424-439.
- [5] 王玲玲,刘恋,张镭,等. 电力系统灵活调节服务与市场机制研究综述[J]. 电网技术, 2022, 46(2): 442-452.
WANG Lingling, LIU Lian, ZHANG Ke, et al. A review of power system flexible ramping product and market mechanism[J]. Power System Technology, 2022, 46(2): 442-452(in Chinese).
- [6] 王明深,李毅强,王伟亮,等. 考虑充放电响应度的电动汽车聚合商与机组协同参与调频市场运营策略[J]. 电网技术, 2025, 49(7): 2809-2818.
WANG Mingshen, LI Yiqiang, WANG Weiliang, et al. Collaborative frequency market operation strategy of electric vehicle aggregator and units considering charging and discharging responsiveness[J]. Power System Technology, 2025, 49(7): 2809-2818(in Chinese).
- [7] 陈会来,张海波,王兆霖. 不同类型虚拟电厂市场及调度特性参数聚合算法研究综述[J]. 中国电机工程学报, 2023, 43(1): 15-27.
CHEN Huilai, ZHANG Haibo, WANG Zhaolin. A review of market and scheduling characteristic parameter aggregation algorithm of different types of virtual power plants[J]. Proceedings of the CSEE, 2023, 43(1): 15-27(in Chinese).

- [8] WANG Lusha, KWON J, SCHULZ N, et al. Evaluation of aggregated EV flexibility with TSO-DSO coordination [J]. IEEE Transactions on Sustainable Energy, 2022, 13(4): 2304-2315.
- [9] HAO He, WU Di, LIAN Jianming, et al. Optimal coordination of building loads and energy storage for power grid and end user services[J]. IEEE Transactions on Smart Grid, 2018, 9(5): 4335-4345.
- [10] 童宇轩, 胡俊杰, 杜昊明, 等. 基于虚拟电池模型的外逼近闵可夫斯基热泵负荷调节可行域聚合方法[J]. 电网技术, 2024, 48(8): 3340-3349.
- TONG Yuxuan, HU Junjie, DU Haoming, et al. Feasible region aggregation method for load regulation of minkowski heat pump based on external approximation of VB model[J]. Power System Technology, 2024, 48(8): 3340-3349(in Chinese).
- [11] BAROT S, TAYLOR J A. A concise, approximate representation of a collection of loads described by polytopes[J]. International Journal of Electrical Power & Energy Systems, 2017, 84: 55-63.
- [12] 龙禹, 张悦, 阮文骏, 等. 基于内盒近似模型的有序用电调度策略研究[J]. 电力需求侧管理, 2022, 24(5): 84-89.
- LONG Yu, ZHANG Yue, RUAN Wenjun, et al. Ordered electricity consumption dispatching strategy based on inner box approximation model[J]. Power Demand Side Management, 2022, 24(5): 84-89(in Chinese).
- [13] 张怀宇, 昌力, 曹路, 等. 基于改进奇诺多面体的需求侧资源可行域聚合研究[J]. 电力需求侧管理, 2024, 26(2): 1-7.
- ZHANG Huaiyu, CHANG Li, CAO Lu, et al. Research on demand side resource feasible region aggregation based on improved zonotope[J]. Power Demand Side Management, 2024, 26(2): 1-7(in Chinese).
- [14] AL TAHA F, VINCENT T L, BITAR E. An efficient method for quantifying the aggregate flexibility of plug-in electric vehicle populations[J]. IEEE Transactions on Smart Grid, 2025, 16(4): 3142-3154.
- [15] 徐湘楚, 米增强, 詹泽伟, 等. 考虑多重不确定性的电动汽车聚合商参与能量-调频市场的鲁棒优化模型[J]. 电工技术学报, 2023, 38(3): 793-805.
- XU Xiangchu, MI Zengqiang, ZHAN Zewei, et al. A robust optimization model for electric vehicle aggregator participation in energy and frequency regulation markets considering multiple uncertainties[J]. Transactions of China Electrotechnical Society, 2023, 38(3): 793-805(in Chinese).
- [16] WANG Yubo, SUN Weiqiang. A two-stage robust pricing strategy for electric vehicle aggregators considering dual uncertainty in electricity demand and real-time electricity prices[J]. Sustainability, 2024, 16(9): 3593.
- [17] ZHANG Mingyang, XU Yinliang, SHI Xiaoying, et al. A fast polytope-based approach for aggregating large-scale electric vehicles in the joint market under uncertainty[J]. IEEE Transactions on Smart Grid, 2024, 15(1): 701-713.
- [18] 朱旭, 孙元章, 杨博闻, 等. 考虑不确定性与非完全理性用能行为的电动汽车集群可调度潜力计算方法[J]. 电力自动化设备, 2022, 42(10): 245-254.
- ZHU Xu, SUN Yuanzhang, YANG Bowen, et al. Calculation method of EV cluster's schedulable potential capacity considering uncertainties and bounded rational energy consumption behaviors [J]. Electric Power Automation Equipment, 2022, 42(10): 245-254(in Chinese).
- [19] 鲍志远, 胡泽春. 大规模电动汽车充换电设施可调能力聚合评估与预测[J]. 中国电机工程学报, 2025, 45(11): 4103-4116.
- BAO Zhiyuan, HU Zechun. Aggregated assessment and prediction of adjustable capacity for large-scale electric vehicle charging and battery swapping facilities[J]. Proceedings of the CSEE, 2025, 45(11): 4103-4116(in Chinese).
- [20] CHEN Xin, DALL'ANESE E, ZHAO Changhong, et al. Aggregate power flexibility in unbalanced distribution systems[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 258-269.
- [21] ZHAO Lin, ZHANG Wei, HAO He, et al. A geometric approach to aggregate flexibility modeling of thermostatically controlled loads[J]. IEEE Transactions on Power Systems, 2017, 32(6): 4721-4731.
- [22] JIANG Ruiwei, GUAN Yongpei. Data-driven chance constrained stochastic program[J]. Mathematical Programming, 2016, 158(1): 291-327.
- [23] 李虹, 韩雨萌. 基于 LSTM-CGAN 的多微网数据驱动分布鲁棒协同优化运行策略[J]. 电力系统保护与控制, 2024, 52(18): 133-148.
- LI Hong, HAN Yumeng. Data-driven distributionally robust collaborative optimization operation strategy for a multi-microgrid based on LSTM-CGAN[J]. Power System Protection and Control, 2024, 52(18): 133-148(in Chinese).
- [24] HE Xinran, DING Tao, ZHANG Xiaosheng, et al. A robust reliability evaluation model with sequential acceleration method for power systems considering renewable energy temporal-spatial correlation[J]. Applied Energy, 2023, 340: 120996.
- [25] ZHANG Yipu, AI Xiaomeng, WEN Jinyu, et al.

Data-adaptive robust optimization method for the economic dispatch of active distribution networks[J]. IEEE Transactions on Smart Grid, 2019, 10(4): 3791-3800.

[26] LU Xiaoxing, LI Kangping, WANG Fei, et al. Optimal bidding strategy of DER aggregator considering dual uncertainty via information gap decision theory[J]. IEEE Transactions on Industry Applications, 2021, 57(1): 158-169.

[27] PJM electricity market data[EB/OL]. [2021-04-18]. [https:// dataminer2.pjm.com/list](https://dataminer2.pjm.com/list).

[28] 文艺林, 胡泽春, 宁剑, 等. 基于分布鲁棒机会约束的充电运营商参与调峰市场投标策略[J]. 电力系统自动化, 2022, 46(7): 23-32.

WEN Yilin, HU Zechun, NING Jian, et al. Bidding strategy of charging operator participating in peak regulation market based on distributionally robust chance constraint[J]. Automation of Electric Power Systems, 2022, 46(7): 23-32(in Chinese).

附录 A

为直观呈现不同聚合方法聚合效果的差异, 设置两辆 EV 的小规模算例。通过将充电时段压缩至 2 个时段(t_1, t_2), 实现可行域在二维平面的可视化表达。EV 具体参数设置如表 A1 所示。

表 A1 EV 仿真参数设置

Table A1 EV Simulation Parameter Settings		
参数	EV1	EV2
$P_{\max}^C$ / kW	22	23
E_{cap} /(kW h)	44	50
SOC_0	0.28	0.42
E_{exp} /(kW h)	33.2	40.1
η^C	0.96	0.94

不同聚合方法下 EV 初始可行域与近似聚合可行域如图 A1 所示。图中, 基于闵可夫斯基求和方法生成的红色可行域边界为精确聚合可行域, 可作为基准, 客观反映不同聚合方法的精度差异。





图 A1 不同聚合方法下的初始可行域与近似聚合可行域
Fig. A1 Initial feasible region and approximated aggregated feasible region under different aggregation methods

直接相加法由于忽略充放电行为的跨时段耦合特性, 仅对各时段功率可行域进行独立线性叠加, 聚合可行域边界显著扩大, 精度过低, 产生非可行点; 外逼近方法在外近似过程中增大了资源聚合可行域, 同样存在不可解问题; 传统内逼近方法可保证聚合结果严格位于真实可行域内, 但牺牲较多灵活性, 聚合结果过于保守; 本文所用重构聚合方法在仿射变换中引入基集可行域重构过程, 使其具有与每辆 EV 的可行域空间相同的结构, 以最小的灵活性损失最大程度地匹配 EV 真实可行域, 保证聚合结果真实可行的同时降低保守性, 具有更好的近似精度。



胡俊杰

在线出版日期: 2025-06-04。
收稿日期: 2024-12-31。
作者简介:
胡俊杰(1986), 男, 博士, 教授, 博士生导师, 主要研究方向为电动汽车与电网互动, junjiehu@ncepu.edu.cn;
马旭睿(2001), 女, 硕士研究生, 主要研究方向为电动汽车参与电网调频, mxr123321@163.com。

(责任编辑 邱丽萍)