

基于高斯过程回归的电动汽车集群灵活性的概率预测

刘子腾¹, 孙 焱², 张沛超², 徐博强², 赵建立¹

(1. 国网上海市电力公司, 上海 200030; 2. 上海交通大学, 上海 200240)

摘要:电动汽车(electric vehicle, EV)是重要的新型可调节负荷资源, 预测其灵活性是实施优化调控的重要前提。首先, 提出基于EV正常充电会话数据推断集群充电可行域的方法, 形成关于EV集群调节灵活性的历史数据集。随后, 针对充电负荷的高随机性特点, 提出基于高斯过程回归的EV集群灵活性的概率预测方法。所得到的概率预测结果可用于建立EV集群运行优化问题的机会约束, 并转换为特定置信度下的确定性约束。最后, 利用实际充电数据进行仿真验证, 结果表明, 所提方法能从电量和功率两个方面比较准确的预测EV集群的充电灵活性; 通过调整置信度, 能够在对EV集群优化调度时权衡经济性和优化结果的可实施性。

关键词:电动汽车; 充电灵活性; 累积电量包络线; 高斯过程回归; 机会约束

Flexibility probabilistic prediction of electric vehicle fleet based on Gaussian process regression

LIU Ziteng¹, SUN Ye², ZHANG Peichao², XU Boqiang², ZHAO Jianli¹

(1. State Grid Shanghai Municipal Electric Power Company, Shanghai 200030, China; 2. Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: Electric vehicles (EVs) are important new adjustable load resources, and predicting their flexibility is an essential prerequisite for implementing optimized dispatch. A method to infer the fleet charging feasibility domain based on normal charging session data of EVs is proposed, forming a historical dataset on the flexibility of EV fleets. Subsequently, considering the high stochasticity of charging load, a probability prediction method for the flexibility of EV fleets based on Gaussian process regression is proposed. The obtained probability prediction results can be used to establish chance constraints for the optimization problem of EV fleet and convert them into deterministic constraints under specific confidence levels. Lastly, simulation verification is conducted using actual charging data. The results show that the proposed method can accurately predict the charging flexibility of EV fleets from both energy and power aspects. By adjusting the confidence level, it is possible to balance the economy and the implementability when optimizing the EV fleets.

Key words: electric vehicle; charging flexibility; cumulative energy envelope; Gaussian process regression; chance constraint

0 引言

电动汽车(electric vehicle, EV)能够显著减少交通领域对于化石能源的依赖^[1]。同时, 大规模EV的聚合可使其成为具有良好调节能力的新型需求侧灵活性资源^[2-3]。因此, 各国政府均通过经济扶持、政策激励和法规强制等诸多方式积极推动其快速发展^[4]。

为了对EV集群实施优化调控和需求侧管理^[5-6], 需要对充电行为做出准确、可靠的预测。充电行为预测包括负荷预测以及本文研究的EV灵活性预测。目前针对前者已有较多研究^[7-8], 而针对后者的研究仍相当有限。在本文中, EV集群灵活性是指EV集群根据电网条件调整内部充电模式能

力。常规的负荷预测可以直接利用历史用电数据作为样本。但对于EV灵活性预测, 由于目前需求响应远未常态化实施, 且每次响应中EV所表现的灵活性受互动类型、时段、等诸多因素影响, 使得实践中很难得到足够的训练样本, 这导致EV灵活性预测远较负荷曲线预测更为困难。

为降低EV灵活性预测难度, 很多文献需要用户提前上报充电计划等信息^[9]。但实际情况表明, 由于缺乏有效激励, 用户提供的信息普遍不准确^[10]。另一种常用方法是假设EV入网时刻、离网时刻、充电电量等特征均满足典型概率分布且相互独立^[11-12], 然后结合蒙特卡洛模拟法推断EV的灵活性。但实际充电数据表明^[10, 13], 上述特征的概率分布不能通过单一的典型分布来简单描述, 且特征之间存在显著相关性。

在预测结果方面, 现有研究大多仅给出点预测值^[7-9, 11, 14-15], 而不能提供置信区间和置信水平。考

收稿日期: 2024-01-05; 修回日期: 2024-03-21

基金项目: 国家重点研发计划项目(2021YFB2401200);
国网上海市电力公司科技项目(52090D230004)

虑到EV充电行为的强随机性,点预测结果不能给出分布信息,电网调度或者EV聚合商难以判断决策的风险与不确定性。

为了解决上述问题,本文提出了基于高斯过程回归(Gaussian process regression, GPR)的EV集群充电灵活性的概率预测方法,主要贡献包括:(1)提出基于正常充电会话数据推断集群充电可行域的方法,形成EV灵活性的历史样本。本方法不要求用户提供充电计划,也无需EV实际参与电网互动;(2)基于上述样本,提出利用GPR预测EV集群灵活性的方法,能同时提供充电灵活性的期望值和置信区间;(3)利用概率预测结果,建立了含置信度的确定性约束,便于构建EV集群的优化调度问题。

1 EV集群灵活性预测的总体流程

本文利用充电桩自动记录的如下充电会话字段: $[t_{in}, t_{out}, E_{exp}, P_N]$, 其中, t_{in} 和 t_{out} 分别为EV的入、离网时间,由车主出行规律决定; E_{exp} 为充电电量; P_N 为额定充电功率,由充电桩和车载充电机共同决定。

在数学上, EV集群灵活性可用充电可行域表示。需要首先预测充电可行域,然后就可以估计集群的削峰填谷能力,或者实施能量优化。根据上述思路,形成图1所示的EV集群灵活性预测的总体过

程,该过程采用数据驱动与动物模型相结合的方法^[16]。包含如下步骤:

第1步,利用每次充电会话信息,推断EV在本次会话期间在充电电量和功率上的灵活性;第2步,利用电量和功率满足可加性的特点,由聚合商聚合形成整个集群的电量可行域与功率可行域。

经过上述两步,可获得反映EV集群灵活性的大量样本。上述过程所依赖的数据无需用户输入,也不受EV是否参与电网互动影响。

第3步,利用上述历史数据,基于GPR预测EV集群关于电量和功率的调节灵活性;第4步,由于预测结果包含高斯分布信息,故可以方便的结合具体应用构建EV集群的随机优化调控问题。为突出重点,本文并不讨论控制问题,相关方法可参考文献[9,12,17]。

2 EV集群灵活性样本集构建方法

2.1 单辆EV的充电可行域

设一天中考察的时间区间为 $H=[t_{start}, t_{end}]$ 。EV的一条充电会话信息为 $[t_{in}, t_{out}, E_{exp}, P_N]$, $[t_{in}, t_{out}] \subseteq H$ 。

EV充电可行域可用公式表示为

$$\begin{cases} E_k = E_{k-1} + \eta P_k \Delta t \\ E_{\min, t_{in}} = E_{\max, t_{in}} = 0 \\ E_{\min, t_{out}} = E_{\max, t_{out}} = E_{exp} \\ E_{\min, k} \leq E_k \leq E_{\max, k} \\ 0 \leq P_k \leq P_N \end{cases} \quad (1)$$

式中: $k \in [t_{in}, t_{out}]$; P_k 为 k 时段的充电功率; η 为充电效率; E_k 为截止到 k 时段的累积充电量; Δt 为优化间隔; $E_{\max, k}$ 、 $E_{\min, k}$ 分别为 k 时段累积充电量的上、下界。

2.2 EV集群的充电可行域

将一天中在网时间满足 $[t_{in}, t_{out}] \subseteq H$ 的所有EV的电量与功率相加,可建立整个EV集群的可行域模型

$$\begin{cases} E_{agg, k} = E_{agg, k-1} + \eta P_{agg, k} \Delta t \\ E_{\min, agg, k} \leq E_{agg, k} \leq E_{\max, agg, k} \\ P_{\min, agg, k} \leq P_{agg, k} \leq P_{\max, agg, k} \end{cases} \quad (2)$$

式中: $k \in [t_{start}, t_{end}]$; 下标 agg 代表集群聚合值。

式(2)中第1个公式为整个EV集群的状态方程,其中 $P_{agg, k}$ 为聚合充电功率,按下式计算

$$P_{agg, k} = \sum_{j=1}^{N_k} P_{j, k} \quad (3)$$

式中: j 为EV编号; N_k 为 k 时段在网的EV数量。

式(2)中第2个公式为集群的累积电量约束,其




图1 总体流程

Fig. 1 Overall flow

中, $E_{\max, \text{agg}, k}$ 、 $E_{\min, \text{agg}, k}$ 分别为整个集群累积电量的上、下包络线, 由各 EV 的累积电量包络线相加得到

$$\begin{cases} E_{\min, \text{agg}, k} = \sum_{j=1}^{N_k} E_{\min, j, k} \\ E_{\max, \text{agg}, k} = \sum_{j=1}^{N_k} E_{\max, j, k} \end{cases} \quad (4)$$

以上两条包络线定义了 EV 集群一天中的电量可行域, 为封闭区域, 如图 2(a) 所示。

式(2)中第3个公式为集群充电功率约束, 集群充电功率上限 $P_{\max, \text{agg}, k}$ 和下限 $P_{\min, \text{agg}, k}$ 分别按下式估计

$$\begin{cases} P_{\max, \text{agg}, k} = \sum_{j=1}^{N_k} P_{N, j} \\ P_{\min, \text{agg}, k} = \min \left(\frac{E_{\max, \text{agg}, k} - E_{\max, \text{agg}, k-1}}{\Delta t}, \frac{E_{\min, \text{agg}, k} - E_{\min, \text{agg}, k-1}}{\Delta t} \right) \end{cases} \quad (5)$$

式中: $P_{\max, \text{agg}, k}$ 取 k 时段所有在网 EV 的额定充电功率之和; $P_{\min, \text{agg}, k}$ 取 k 时段上、下电量包络线斜率(代表充电功率)的较小值。若 $P_{\min, \text{agg}, k}$ 不为 0, 则表明在 k 时段存在必需充电、没有灵活调控能力的 EV。

由上述充电功率上下限构成了 EV 集群一天中的功率可行域, 如图 2(b) 所示。需强调的是, 集群灵活性需由图 2(a) 和图 2(b) 共同刻画, 即同时满足电量和功率可行域的集群调度方案才是可行的。




图 2 EV 集群一天中的充电可行域

Fig. 2 Cumulative energy envelope of EV fleet in a day

至此, 本文利用一天中集群中全部 EV 的充电会话数据, 推断出该集群一天的运行可行域, 获得了关于 EV 集群灵活性的大量历史样本。

3 基于 GPR 的 EV 集群灵活性概率预测方法

记 EV 集群累积电量包络线的预测结果为随机变量 $\tilde{E}_{\min, \text{agg}, k}$ 和 $\tilde{E}_{\max, \text{agg}, k}$, 充电功率包络线的预测结果为随机变量 $\tilde{P}_{\max, \text{agg}, k}$ 和 $\tilde{P}_{\min, \text{agg}, k}$ 。不失一般性, 下面仅推导 $\tilde{E}_{\max, \text{agg}, k}$ 的概率预测方法。

将 EV 集群累积电量上包络线时间序列视为高斯过程 (Gaussian process, GP)^[18], 即

$$\{E_{\max, \text{agg}, k}\} \sim \text{GP}(m(k), K(k, k')) \quad (6)$$

式中: $m(k)$ 为均值函数; $K(k, k')$ 为协方差函数。

由于充电行为具有周期性, 本文采用如下形式的平滑周期核函数作为协方差函数^[18]

$$K(k, k') = \sigma_f^2 \exp \left[-\frac{2}{\ell^2} \sin^2 \left(\frac{\pi}{p} (k - k') \right) \right] \quad (7)$$

式中: σ_f 和 ℓ 为待辨识的超参数; p 为包络线的周期。

简记 $\mathbf{E} = \{E_{\max, \text{agg}, k}\}$ 为集群累积电量包络线的历史样本, 由上节提出的方法获得, 样本数为 N ; $E^* = E_{\max, \text{agg}, k^*}$ 为未来 k^* 时刻的待预测值。记 σ 为均方根测量误差, $\mathbf{I}_N$ 为 N 阶单位矩阵, 则历史样本 $\mathbf{E}$ 和待预测值 E^* 服从如下的联合高斯分布

$$\begin{bmatrix} \mathbf{E} \\ E^* \end{bmatrix} \sim N \left(\mathbf{0}, \begin{bmatrix} \mathbf{K} + \sigma^2 \mathbf{I}_N & \mathbf{K}^{*T} \\ \mathbf{K}^* & K^{**} \end{bmatrix} \right) \quad (8)$$

式中

$$\begin{cases} \mathbf{K} = [K(k_i, k_j)]_{i=1, N, j=1, N} \in \mathbf{R}^{N \times N} \\ \mathbf{K}^* = [K(k^*, k_i)]_{i=1, N} \in \mathbf{R}^{1 \times N} \\ \mathbf{K}^{**} = K(k^*, k^*) \in \mathbf{R}^{1 \times 1} \end{cases} \quad (9)$$

高斯过程的重要性质是其条件概率仍满足高斯分布^[18], 据此可以推断出未来 k^* 时刻 E^* 的分布为

$$E^* | \mathbf{E} \sim N(\mathbf{K}^* (\mathbf{K} + \sigma^2 \mathbf{I}_N)^{-1} \mathbf{E}, \mathbf{K}^{**} - \mathbf{K}^* (\mathbf{K} + \sigma^2 \mathbf{I}_N)^{-1} \mathbf{K}^{*T}) \quad (10)$$

则 k^* 时刻集群累积电量上包络线的期望值为

$$\bar{E}_{\max, \text{agg}, k^*} = \mathbf{K}^* (\mathbf{K} + \sigma^2 \mathbf{I}_N)^{-1} \mathbf{E} \quad (11)$$

该时刻的方差为

$$\text{var}(\bar{E}_{\max, \text{agg}, k^*}) = \mathbf{K}^{**} - \mathbf{K}^* (\mathbf{K} + \sigma^2 \mathbf{I}_N)^{-1} \mathbf{K}^{*T} \quad (12)$$

可见, GPR 不但能给出点预测值(期望值), 还能根据预测方差给出置信区间。

由上可见, 本文使用的 GPR 方法无需对回归曲线的形状做出假设, 且模型的超参数很少, 易于使用。此外, 与文献[11—12]不同, 本文的预测方法无需对入/离网时间、充电时间和电量等特征分布及其相关性做出假设或限定, 因而可适应包含多充电场所(如居民区、商业区、工作场所等)的 EV 集群。

4 EV 集群灵活性的机会约束模型

EV 集群灵活性的预测结果, 可应用于一类优化问题, 该问题旨在从预测的 EV 集群可行域中找到一条最优的可行轨迹, 本文建立了关于 EV 集群的电量和功率可行轨迹的机会约束模型

$$\begin{cases} P_r(E_{\text{agg}, k} \leq \tilde{E}_{\max, \text{agg}, k}) \geq \alpha \\ P_r(\tilde{E}_{\min, \text{agg}, k} \leq E_{\text{agg}, k}) \geq \alpha \\ P_r(P_{\text{agg}, k} \leq \tilde{P}_{\max, \text{agg}, k}) \geq \alpha \\ P_r(\tilde{P}_{\min, \text{agg}, k} \leq P_{\text{agg}, k}) \geq \alpha \end{cases} \quad (13)$$

式中: P_r 为概率, $\alpha \in [0, 1]$ 为置信度, $k \in [t_{\text{start}}, t_{\text{end}}]$ 。

上式的含义是,在整个优化区间 $[t_{\text{start}}, t_{\text{end}}]$ 内,集群累积电量 $E_{\text{agg},k}$ 和功率 $P_{\text{agg},k}$ 位于可行域内的概率应大于给定置信度。

由于GPR的预测结果满足高斯分布,故易于得到 $\tilde{E}_{\text{min,agg},k}$ 、 $\tilde{E}_{\text{max,agg},k}$ 、 $\tilde{P}_{\text{min,agg},k}$ 、 $\tilde{P}_{\text{max,agg},k}$ 的累积分布函数,分别记为 $F_{E_{\text{min},k}}$ 、 $F_{E_{\text{max},k}}$ 、 $F_{P_{\text{min},k}}$ 、 $F_{P_{\text{max},k}}$,则式(13)可以转化为如下的确定性约束

$$\begin{cases} F_{E_{\text{min},k}}^{-1}(\alpha) \leq E_{\text{agg},k} \leq F_{E_{\text{max},k}}^{-1}(1-\alpha) \\ F_{P_{\text{min},k}}^{-1}(\alpha) \leq P_{\text{agg},k} \leq F_{P_{\text{max},k}}^{-1}(1-\alpha) \end{cases} \quad (14)$$

综上,含置信度的EV集群充电可行域可写为

$$\begin{cases} E_{\text{agg},k} = E_{\text{agg},k-1} + \eta P_{\text{agg},k} \Delta t \\ F_{E_{\text{min},k}}^{-1}(\alpha) \leq E_{\text{agg},k} \leq F_{E_{\text{max},k}}^{-1}(1-\alpha) \\ F_{P_{\text{min},k}}^{-1}(\alpha) \leq P_{\text{agg},k} \leq F_{P_{\text{max},k}}^{-1}(1-\alpha) \end{cases} \quad (15)$$

式(15)只包含线性和仿射约束,方便结合具体应用构造易于求解的优化问题。本文将在下一节给出应用算例。

5 算例分析

5.1 数据集选择与优化参数设置

本文参考美国加州理工学院提供的充电公共数据集^[10]。该数据集包含跨度为3年的约3万条现场充电数据。为方便构造累积电量包络线,本文将优化周期 H 设为07:00至次日07:00,这样,各类充电场所在上述起止时刻的在充车辆数均较小。EV集群优化间隔为0.5 h。

5.2 集群灵活性的概率预测结果

以2018年4月25日作为待预测日,以前7 d充电数据构建训练集。预测间隔为0.5 h。

作为对比,选择现有研究中常用的基于概率统计的蒙特卡洛(Monte Carol, MC)随机模拟法^[11-13]。首先根据历史充电会话数据统计EV入网时刻、离网时刻、充电电量等特征的概率分布。然后,假定特征间相互独立,由MC模拟法随机生成和待预测日同数量的充电会话数据,并聚合成EV集群的累积电量包络线和功率包络线。

图3直观比较了本文提出的GPR方法与MC方法的预测结果,可见在大部分时段,由本文方法得到的EV集群灵活性预测区间更好的覆盖了真实值。而MC方法只提取了EV各个充电特征的边缘概率分布,忽略了彼此间的相关性,使得在很多时段预测出的集群灵活性明显超出真实值。

为定量评价预测效果,采用均方根误差(root mean square error, RMSE)评价其点预测的精度,采




图3 GPR方法和MC方法的对比

Fig. 3 Comparison of GPR and Monte Carlo methods

用预测区间归一化平均宽度(prediction interval normalized average width, PINAW)和覆盖比例(prediction interval coverage proportion, PICP)分别评价预测区间的精确度和覆盖性,具体计算公式如下

$$\begin{cases} R_{\text{MSE}} = \sqrt{\frac{1}{M} \sum_{k=1}^M (\bar{X}_k - X_k)^2} \\ P_{\text{INAW}} = \frac{1}{MR} \sum_{i=1}^M (U_k - L_k) \\ P_{\text{ICP}} = \frac{1}{M} \sum_{k=1}^M c_i \end{cases} \quad (16)$$

式中: M 为预测时段数; $\bar{X}_k$ 为点预测值; X_k 为真值; U_k 和 L_k 分别为预测区间的上下界,当时段 i 真值落在区间 $[L_k, U_k]$ 内时 c_i 取1,否则取0; R 为区间边界的全距。

评价结果见表1。从RMSE指标看,点预测误差较小,能有效反映包络线的变化趋势。从PICP和PINAW这两项指标看,在大多数时段预测区间都能覆盖真值,且预测区间相对于包络线的宽度较小,精确度较高。需指出的是,覆盖性指标PICP和精确度指标PINAW之间存在一定的矛盾性,而本文预测结果较好的兼顾了这两项指标。

从表1中还能发现,功率可行域的预测指标比电量可行域略差一些。这是由于,前者反映的是EV集群短期的充电状态,因此更易受充电行为随机性

的影响。另外,本文使用的是校园级充电数据集^[10],EV数量有限,这也增大了预测的难度。

表1同时给出了MC方法的预测指标。可见,除了充电功率下限的覆盖性指标,本文提出的GPR方法的预测效果皆明显优于MC方法。

表1 灵活性预测指标对比

Table 1 Comparison of flexibility prediction indices

精度指标	预测方法	RMSE	PINAW	PICP
累积电量	GPR	1.9	5.8	87.5
上包络线	MC	4.9	7.0	65.3
累积电量	GPR	1.7	5.6	91.7
下包络线	MC	7.1	6.8	61.2
充电功率	GPR	10.1	17.6	68.8
上限	MC	38.1	26.8	34.7
充电功率	GPR	8.1	19.5	77.1
下限	MC	13.2	29.2	85.7

5.4 考虑置信度的集群运行优化示例

作为示例,构建如下的EV集群充电优化问题

$$\begin{cases} \min \left[\sum_{k=1}^T (p_{e,k} P_{agg,k}) + a \sqrt{\sum_{k=1}^T P_{agg,k}^2} + b \sqrt{\sum_{k=1}^T (P_{agg,k} - P_{agg,k-1})^2} \right] \Delta t \\ \text{s.t. 式(15)} \end{cases} \quad (17)$$

式中: T 为一天中的优化时段数;目标函数第1项为集群充电费用; $p_{e,k}$ 为充电电价,采用峰谷平3段式分时电价^[6];第2项用于减少一天中集群充电功率的峰谷差;第3项用于抑制充电功率波动; a 、 b 为相应的惩罚系数,本文皆取1元/kWh。约束条件为第4节建立的含置信度约束。上述问题为二次规划问题。

分别选取98.5%、90%、50%等3种置信度完成优化,结果如图4所示,可见随着置信度增加,优化问题的可行域也随之减小。值得说明的是,当置信度取50%时,由高斯分布性质不难得出此时的充电可行域等价于基于点预测结果的确定性约束。





图4 不同置信度下的优化结果

Fig. 4 Optimization results with different confidence levels

为分析置信度的影响,本文统计了最近7天最优充电轨迹突破了实际充电包络线的时段数,将其与总时段数的比值定义为该置信度下的突破率。

表2比较了不同置信度下优化结果的经济性与突破率。可见,置信度的大小与最优充电成本呈正相关,而与突破率呈负相关。在以点预测值(对应置信度50%)作为约束条件时,集群可行域最大,最优充电轨迹取得了最低的充电成本,但其突破实际包络线的风险也最高,会使得优化结果不可实施。本文提出的概率预测方法,为实现EV集群运行优化结果的经济性与可实施性两者间提供了调节手段。

表2 不同置信度下的优化结果

Table 2 Optimization results with different confidence levels

置信度/%	最优充电成本/元	突破率/%
98.5	1 831.59	17.26
90.0	1 772.61	22.92
50.0	1 704.09	40.18

6 结束语

为满足EV集群参与电网互动的迫切要求,本文提出EV集群灵活性的概率预测方法,并以实际充电数据进行了仿真验证,结论如下:

(1) 基于充电会话数据推断集群充电可行域,能够利用正常充电数据形成用于灵活性预测的样本,可以解决历史需求响应事件不足的问题,且无需用户提前上报充电计划,改善了用户体验。

(2) 利用GPR方法预测EV集群灵活性,能够同时提供点预测值和预测区间,形成带有置信度的集群充电可行域,从而适应充电负荷高度随机的特点。

(3) 利用高斯分布的特点,把基于概率的机会

约束转换为给定置信度下的确定性约束,易于将随机优化问题转换为确定性优化,从而方便求解。D

参考文献:

- [1] EHSANI M, SINGH K V, BANSAL H O, et al. State of the art and trends in electric and hybrid electric vehicles[J]. Proceedings of the IEEE, 2021, 109(6):967-984.
- [2] 史倩芸,吴传申,高山.考虑电动汽车需求响应的微电网预测控制研究[J].电力需求侧管理,2022,24(2):1-6,13.
- SHI Qianyun, WU Chuanshen, GAO Shan, et al. Research on predictive control of microgrid considering electric vehicle demand response[J]. Power Demand Side Management, 2022, 24(2):1-6, 13.
- [3] 程熹,洪雅迪,邱辛泰.计及电动汽车负荷特性的虚拟电厂优化调度[J].电力需求侧管理,2022,24(4):28-35.
- CHENG Xi, HONG Yadi, QIU Xintai. Optimal dispatch of virtual power plant considering electric vehicle load characteristics[J]. Power Demand Side Management, 2022, 24(4):28-35.
- [4] 陈杰军,奚巍民,朱婵霞,等.电动汽车发展态势评价体系及方法研究[J].电力需求侧管理,2023,25(1):74-79.
- CHEN Jiejun, XI Weimin, ZHU Chanxia, et al. Evaluation system and method of electric vehicle development trend[J]. Power Demand Side Management, 2023, 25(1):74-79.
- [5] 叶婷,邓星,黄堃,等.电动汽车充换储一体化电站的优化调度策略及应用[J].电力需求侧管理,2021,23(4):67-72.
- YE Ting, DENG Xing, HUANG Kun, et al. Optimal dispatching strategy and application of electric vehicle charge-exchange-storage integrated power plant[J]. Power Demand Side Management, 2021, 23(4):67-72.
- [6] 徐博强,赵建立,张沛超,等.基于负荷准线和纳什谈判的高比例新能源消纳方法[J].电力系统自动化,2023,47(15):36-45.
- XU Boqiang, ZHAO Jianli, ZHANG Peichao, et al. High-proportion renewable energy accommodation method based on customer directrix load and nash bargaining[J]. Automation of Electric Power Systems, 2023, 47(15):36-45.
- [7] 牛牧童,廖凯,杨健维,等.考虑季节特性的多时间尺度电动汽车负荷预测模型[J].电力系统保护与控制,2022,50(5):74-85.
- NIU Mutong, LIAO Kai, YANG Jianwei, et al. Multi-time-scale electric vehicle load forecasting model considering seasonal characteristics[J]. Power System Protection and Control, 2022, 50(5):74-85.
- [8] 陈勇,江颖达,徐刚,等.规模化电动汽车充电负荷预测[J].电力需求侧管理,2022,24(5):71-77.
- CHEN Yong, JIANG Yingda, XU Gang, et al. Charging load forecasting for large-scale electric vehicle[J]. Power Demand Side Management, 2022, 24(5):71-77.
- [9] VANDAEL S, CLAESSENS B, HOMMELBERG M, et al. A scalable three-step approach for demand side management of plug-in hybrid vehicles[J]. IEEE Transactions on Smart Grid, 2013, 4(2):720-728.
- [10] LEE Z J, LI T, LOW S. ACN-Data: analysis and applications of an open EV charging dataset[C]// Proceedings of the Tenth ACM International Conference on Future Energy Systems, Phoenix, AZ, USA, June 25-28, 2019: 139-149.
- [11] 侯慧,王逸凡,赵波,等.价格与激励需求响应下电动汽车负荷聚集商调度策略[J].电网技术,2022,46(4):1259-1269.
- HOU Hui, WANG Yifan, ZHAO Bo, et al. Dispatching strategy of electric vehicle aggregator under price and incentive demand response[J]. Power System Technology, 2022, 46(4):1259-1269.
- [12] XU Z, SU W, HU Z, et al. A hierarchical framework for coordinated charging of plug-In electric vehicles in China[J]. IEEE Transactions on Smart Grid, 2016, 7(1):428-438.
- [13] 陈丽丹,张尧,FIGUEIREDO A.电动汽车充放电负荷预测研究综述[J].电力系统自动化,2019,43(10):177-191.
- CHEN Lidian, ZHANG Yao, FIGUEIREDO A. Overview of charging and discharging load forecasting for electric vehicles[J]. Automation of Electric Power Systems, 2019, 43(10):177-191.
- [14] 叶林,宫婷,宋旭日,等.基于波动类型精细划分与聚类的短期负荷预测[J].电网技术,2023,47(3):998-1013.
- YE Lin, GONG Ting, SONG Xuri, et al. Short term load forecasting based on fine division and clustering of fluctuation types[J]. Power System Technology, 2023, 47(3):998-1013.
- [15] 任建吉,位慧慧,邹卓霖.基于CNN-BiLSTM-Attention的超短期电力负荷预测[J].电力系统保护与控制,2022,50(8):108-116.
- REN Jianji, WEI Huihui, ZOU Zhuolin, et al. Ultra-short-term power load forecasting based on CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2022, 50(8):108-116.
- [16] 王玉彬,董伟,陈源奕.基于数据驱动的家庭能量实时经济调控方法[J].电力系统自动化,2022,46(13):21-29.
- WANG Yubin, DONG Wei, CHEN Yuanyi, et al. Data-driven real-time economic regulation method for household energy[J]. Automation of Electric Power Systems, 2022, 46(13):21-29.
- [17] 张丙旭,许刚,张琥华.考虑EV集群时序灵活性的分布式能源协同优化[J].电网技术,2021,45(3):987-998.
- ZHANG Bingxu, XU Gang, ZHANG Xiaohua. Distributed energy collaborative optimization considering temporal flexibility of EV cluster[J]. Power System Technology, 2021, 45(3):987-998.
- [18] WILLIAMS C K, RASMUSSEN C E. Gaussian processes for machine learning[M]. Cambridge, MA: MIT press, 2006.

作者简介:

刘子腾(1996),女,安徽亳州人,硕士,初级工程师,研究方向为智能用电新技术、需求侧管理;

孙烨(2000),男,江苏南通人,硕士研究生,研究方向为新能源预测、综合能源系统运行优化等;

张沛超(1970),男,通信作者,江苏连云港人,博士,副教授,研究方向为电力系统保护与控制、可再生能源接入、能源互联网。

(责任编辑 郝 逊)