

基于MF-LSTM的城市电动汽车集中充电负荷 可调潜力评估

潘玲玲¹,庄卫金¹,赵奇²,田江²

(1. 中国电力科学研究院有限公司,江苏 南京 210000;
2. 国网江苏省电力有限公司 苏州供电分公司,江苏 苏州 215000)

摘要:在新型电力系统背景下,电网需求侧可调控资源对于系统稳定的重要性日益提升。电动汽车作为重要的可调度负荷资源,对其可调度潜力进行准确评估,能有效提升电网安全稳定运行能力。现有研究较少考虑电动汽车用户行为偏好对电网负荷调控的影响,因此,提出一种考虑用户充电偏好的电动汽车集中式电站可调潜力评估方法。考虑电动汽车充电时的外部条件与自身行为偏好因素,建立基于隶属度函数的用户充电行为模型,并结合长短期记忆神经网络算法对充电站的可调潜力进行评估。最后,通过实际充电站算例,分析了电动汽车用户与负荷可调度潜力之间的耦合关系,验证了所提方法对负荷可调控容量评估的有效性,为电动汽车可调负荷参与削峰填谷等需求响应服务提供了理论支撑。

关键词:电动汽车;调度潜力;用户行为;隶属度函数;长短期记忆神经网络

中图分类号:TM715 **文献标识码:**A **DOI:** 10.19457/j.1001-2095.dqcd24400

Evaluation of Adjustable Potential of Urban Electric Vehicle Centralized Charging Load Based on MF-LSTM

PAN Lingling¹, ZHUANG Weijin¹, ZHAO Qi², TIAN Jiang²

(1. China Electric Power Research Institute Co., Ltd., Nanjing 210000, Jiangsu, China;
2. Suzhou Power Supply Branch, State Grid Jiangsu Electric Power Co., Ltd.,
Suzhou 215000, Jiangsu, China)

Abstract: In the background of the new power system, the importance of demand-side dispatchable resources of the grid for system stability is increasing. As an important dispatchable load resource, an accurate assessment of electric vehicle (EV) dispatchable potential can effectively improve the safety and stability of the grid. Existing research has rarely considered the impact of EV user behavior preferences on grid load regulation. Therefore, a method for evaluating the adjustable potential of EV centralized power stations considering user charging preferences was proposed. The user charging behavior model based on the membership function (MF) was established considering external conditions and their own behavioral preferences when charging EVs. And the long short-term memory (LSTM) neural network algorithm was combined with MF to evaluate the adjustable potential of charging stations. Finally, the coupling relationship between EV users and load dispatchable potential was analyzed through actual charging station calculations, which verifies the effectiveness of the proposed method for load dispatchable capacity assessment and provides theoretical support for EV adjustable load participation in demand response services such as peak shaving and valley filling.

Key words: electric vehicle (EV); scheduling potential; user behavior; membership function (MF); long short-term memory (LSTM) neural network

随着新能源在新型电力系统中的比例持续提升^[1],新能源机组具有的波动性大、随机性强的

特性,使其成为重要的可调度资源^[2]。国家电网公司负荷调控三年行动计划提出,需要充分发挥

基金项目:国家电网公司科技项目(5108-202118041A-0-0-00)

作者简介:潘玲玲(1985—),女,硕士,高级工程师,Email:panlingling@epri.sgcc.com.cn

通讯作者:庄卫金(1978—),男,本科,高级工程师,Email:zhuangweijin@epri.sgcc.com.cn

需求响应对于保障电力供需平衡、促进新能源消纳、提升电网运行效率等的作用。作为重要的可调度资源,电动汽车可调度容量大、可调度时间长,具有一般可调度资源不具备的灵活性和分散性。但是,对其调度潜力进行评估需要进一步结合其在特定充电设施下的充电行为。因此,考虑目前城市内集中式充电站作为主要的集群电动汽车充电场所,在集中式充电站这一充电载体下,亟需对电动汽车集群的可调控潜力进行准确评估,进一步分析集群电动汽车的调控潜力。

目前,电动汽车可调控潜力研究主要分为可调度容量评估及可调控时间分析^[3],两类研究均考虑可调控潜力的不确定性。在评估电动汽车调控潜力不确定性时,电动汽车用户作为响应聚合商调控需求的主体,由于其不确定性较强,且用户行为偏好与电网调控具有密切联系,因此需着重考虑用户自身的行为特性,分析不同用户群体的充电偏好,进而研究用户自身行为偏好对于系统调控的影响。但目前对用户出行及响应的不确定性因素研究较少,对于用户行为约束条件的考虑明显不足。文献[4]通过多种概率分布组合,分析了用户充电行为的不确定性,提出了电动汽车在分布式新能源高渗透条件下的配网系统规划方法。文献[5]基于后悔匹配理论建模分析了用户决策的不确定性,提出了考虑用户决策不确定性的停车场布局与激励联合优化算法。为了进一步验证用户自身行为会对充电负荷的时空分布产生影响,文献[6]提出了一种考虑多源信息实时交互和用户后悔心理的电动汽车充电负荷预测方法。在结合用户行为决策模型的基础上,相关文献分别采用模型驱动^[7]与数据驱动^[8]的算法预测电动汽车快速充电需求负荷,分析了城市快充站的充电需求负荷时空分布,提出了私家电动汽车参与电网调控的评估方法。以上研究在考虑用户充电偏好时均主观设置用户响应行为的参与度,没有考虑内、外部因素的耦合特性;或者定性考虑了用户的后悔心理及非理性选择,对于用户行为的影响因素研究仍显不足。

针对需求侧可调控灵活性资源,已有研究提出了多种优化调度策略:部分研究以提升经济效益为目标,提出的负荷综合优化调度策略能有效降低用户成本,提高发电系统收益及用户侧收益^[9-10];部分研究以提高能源用能效率、降低

能源损耗、提高电网调度水平为目标,提出了多种联合调控优化策略^[11-14]。以上优化调度策略为有效利用可调资源提供了多种思路。文献[15-16]提出了可调节负荷调控能力评估指标体系,建立了不同市场场景下可调节负荷调控能力评估标准与市场风险管控方法,实现可调节资源的有效管控。以上标准体系对实现可调节资源评估精确化、评价指标规范化奠定了一定的理论基础。

同时,为实现灵活资源可调容量预测,需对短期负荷进行预测。由于神经网络具有较强的自学习和非线性拟合能力,适合用来解决智能电网负荷预测问题。文献[17-18]分别考虑了实时电价与温度的影响,并引入隶属度函数进行模糊化处理,提出了基于长短期记忆循环神经网络的负荷预测模型。在长短期记忆神经网络的基础上,结合卷积神经网络^[19]的混合模型在短期负荷预测领域提高了预测精度,而结合K-means聚类算法^[20]的集群电动汽车实时自动优化调度策略提高了规模化电动汽车的实时调度效率。

针对以上问题,本文提出了一种考虑用户充电偏好的城市电动汽车集中式充电负荷可调潜力评估方法。首先考虑了电动汽车充电时的客观外部条件与用户自身的内部行为偏好因素,分析了各因素间的耦合关系,同时研究了单个因素对用户参与调控的影响程度;其次建立了基于隶属度函数(membership function, MF)及模糊化算法的用户行为数据库模型,用以仿真内、外部因素的动态耦合过程;然后在长短期记忆(long short-term memory, LSTM)神经网络输入侧引入用户行为隶属度函数,构建MF-LSTM预测模型对充电站的负荷可调潜力进行评估。最后,通过实际充电站算例,分析了电动汽车用户选择与负荷可调度潜力之间的耦合关系,验证了所提方法对负荷可调控容量评估的有效性,为电动汽车可调度负荷参与削峰填谷等需求响应服务提供了理论支撑。

1 基于MF-LSTM神经网络的充电负荷预测模型

1.1 长短期记忆神经网络

长短期记忆神经网络是一种循环神经网络(recurrent neural network, RNN)的结构变体,针对RNN存在的梯度消失而导致无法记忆长期数据

的问题,LSTM加入不同门的控制,将长时记忆数据和短时记忆数据进行结合。LSTM结构中一个LSTM单元如图1所示。




图1 LSTM单元

Fig.1 Long short-term memory unit

遗忘门能主动选取相关信息进行遗忘,相关公式为

$$f_t = \sigma(W_f[h_{t-1}, x_t + b_f]) \quad (1)$$

式中: f_t 为遗忘门输出; $\sigma(\cdot)$ 为sigmoid函数; W_f 为矩阵权重; h_{t-1} 为 $t-1$ 时刻的输出; x_t 为 t 时刻的输入; b_f 为偏置项。

输入门分为2个部分:先通过sigmoid层更新信息;再通过tanh层创建新的候选值向量。计算公式为

$$i_t = \sigma(W_i[h_{t-1}, x_t + b_i]) \quad (2)$$

$$C_t = \tanh(W_c[h_{t-1}, x_t + b_c]) \quad (3)$$

式中: i_t 为输入门状态; C_t 为新增状态; W_i, W_c 为矩阵权重; b_i, b_c 为偏置项。

t 时刻的隐藏层状态 c_t 通过添加遗忘门和输入门所控制的信息部分来确定:长时间信息由 f_t 控制;短时间信息由 i_t 和 C_t 控制。公式如下:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot C_t \quad (4)$$

输出门也分为2个部分:先通过sigmoid层对要输出的信息进行过滤,再将 c_t 通过tanh层,使状态范围为 $[-1, 1]$,最后将两者相乘得到期望输出。公式为

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh c_t \quad (6)$$

式中: o_t 为输出门状态; W_o 为矩阵权重; b_o 为偏置项; h_t 为最终期望输出结果。

1.2 MF-LSTM神经网络负荷预测模型

本文首先使用隶属度函数构建充电负荷时间序列特征作为网络输入信息,生成考虑用户偏好的充电负荷数据;其次将生成的新数据输入至LSTM神经网络实现负荷预测;最后得到充电负荷预测数据,得到未来一段时间内电站充电负荷

变化情况及波动曲线。MF-LSTM预测模型结构如图2所示。图中原始输入层为充电负荷历史数据,神经网络输入层为充电负荷生成数据,隐含层为双层隐藏层,输出层为考虑用户行为偏好后的负荷预测数据。

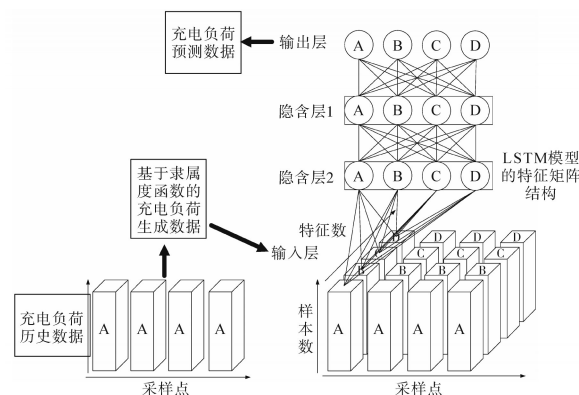


图2 MF-LSTM预测模型

Fig.2 MF-LSTM prediction model

2 电动汽车用户充电行为偏好模型

2.1 用户行为影响因素模糊化算法

电动汽车用户作为控制电动汽车接入电网的操作人,其对外部激励的响应程度随用户自身行为偏好产生差异,影响用户参与需求响应的可能性,从而改变电动汽车的调控潜力。由于实际情况中用户行为存在不确定性,用户存在多样化抉择,其考虑多方因素后做出的决策是模糊化的,无法得到具体的选择概率,因此本文使用模糊推理系统隶属度函数对用户选择过程中的决策行为进行仿真模拟。

电动汽车用户在考虑是否参与调控时,主要考虑内、外两类因素。针对自身内部因素,本文考虑了用户对电价的敏感程度及电量焦虑;针对环境外部因素,本文考虑了电动汽车充电起始荷电状态及补偿电价。

首先,分别对以上4个因素进行模糊化建模,得到各自的隶属度函数作为输入。由于现有文献针对用户行为影响因素的模糊推理过程内容较少,因此参考了文献[18]中的温度模糊化过程进行用户行为影响因素的类比;各参数按照影响因素的程度进行等比例划分,将影响因素划分为区间 $[1, 10]$ 内的隶属函数。由于采用模糊推理系统,无法给出确切的阈值区间,尤其是两种评价结果的交界处,因此针对以上4个因素仅提供大致的区间范围:

1)电价补偿:

$$m_1 = \begin{cases} 1 & P_r < A_1 \\ \frac{C_1 - P_r}{C_1 - A_1} & A_1 \leq P_r \leq C_1 \\ 0 & C_1 < P_r \end{cases} \quad (7)$$

$$m_2 = \begin{cases} \frac{P_r - A_1}{B_1 - A_1} & A_1 < P_r < B_1 \\ 1 & B_1 \leq P_r < D_1 \\ \frac{E_1 - P_r}{E_1 - D_1} & D_1 \leq P_r < E_1 \\ 0 & P_r < A_1 \text{ or } E_1 < P_r \end{cases} \quad (8)$$

$$m_3 = \begin{cases} 0 & P_r < C_1 \\ \frac{P_r - C_1}{E_1 - C_1} & C_1 \leq P_r \leq E_1 \\ 1 & E_1 < P_r \end{cases} \quad (9)$$

式中: m_1, m_2, m_3 分别为低电价补偿、中等电价补偿及高电价补偿的隶属度函数,阈值区间分别为 $[0, 3.33], [3.33, 6.67], [6.67, 10]$; P_r 为电价; $A_1 \sim E_1$ 为电价参数,取 $A_1=2.5, B_1=3.75, C_1=5, D_1=6.25, E_1=7.5$ 。

2)起始荷电状态:

$$m_{4i} = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(S - \mu_i)^2}{2\sigma^2}\right] \quad (10)$$

式中: m_{4i} 为起始荷电状态的隶属度函数, $i=1, 2, 3, 4$,分别对应低电量、较低电量、较高电量和高电量,阈值区间分别为 $[0, 2.5], [2.5, 5], [5, 7.5], [7.5, 10]$; S 为起始荷电状态; σ 取2.5; μ_i 分别取0, 3.33, 6.67, 10。

3)电量焦虑:

$$m_{5i} = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(N - \mu_i)^2}{2\sigma^2}\right] \quad (11)$$

式中: m_{5i} 为电量焦虑的隶属度函数, $i=1, 2, 3, 4$,分别对应无焦虑、低焦虑、中焦虑和高焦虑,阈值区间分别为 $[0, 2.5], [2.5, 5], [5, 7.5], [7.5, 10]$; N 为焦虑状态; σ 取2.5; μ_i 分别取0, 3.33, 6.67, 10。

4)电价敏感程度:

$$m_6 = \begin{cases} \frac{C_2 - Sen}{C_2 - A_2} & A_2 \leq Sen \leq C_2 \\ 0 & Sen \geq C_2 \end{cases} \quad (12)$$

$$m_7 = \begin{cases} 0 & Sen \leq B_2 \\ \frac{Sen - B_2}{C_2 - B_2} & B_2 \leq Sen \leq C_2 \\ \frac{D_2 - Sen}{D_2 - C_2} & C_2 \leq Sen \leq D_2 \\ 0 & Sen \geq D_2 \end{cases} \quad (13)$$

$$m_8 = \begin{cases} \frac{Sen - C_2}{E_2 - C_2} & C_2 \leq Sen \leq E_2 \\ 0 & Sen \leq C_2 \end{cases} \quad (14)$$

式中: m_6, m_7, m_8 为电价敏感程度的隶属度函数,分别为不敏感、较敏感和高敏感,阈值区间分别为 $[0, 3.33], [3.33, 6.67], [6.67, 10]$; Sen 为电价敏感度; $A_2 \sim E_2$ 为敏感参数, $A_2=0, B_2=2.5, C_2=5, D_2=7.5, E_2=10$ 。

其次,将用户是否参与电网调控设置为输出结果,如下式:

$$\begin{cases} Re = 1 & output \geq 0.5 \\ Re = 0 & output < 0.5 \end{cases} \quad (15)$$

输出结果为1表示用户参与电网调控,0表示用户不参与电网调控。

最后,制定隶属度函数输出规则,其中包含6条规则,规则矩阵如下:

$$R = \begin{bmatrix} 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ -4 & 3 & 3 & 2 & 2 & 1 & 1 \\ -3 & -1 & -1 & 3 & 2 & 1 & 1 \\ -3 & 3 & 3 & 3 & 2 & 1 & 1 \\ 1 & -1 & -1 & 4 & 2 & 1 & 1 \\ -4 & -1 & -1 & 3 & 2 & 1 & 1 \end{bmatrix} \quad (16)$$

综上所述,得到计及用户行为影响因素的模糊化推理算法,该算法对用户行为决策进行模拟,实现用户参与电网调控的模糊推理,为后续构建MF-LSTM模型提供前端支撑。

2.2 计及用户行为偏好充电行为数据生成算法

由于缺少耦合用户行为的充电负荷历史数据,因此,需要基于所建立的用户行为影响因素模糊化算法,在原始充电行为数据库基础上考虑用户行为偏好,构建数据生成算法得到新的充电行为数据库作为仿真输入。算法具体规则如下:

1)充电时长限制。充电时长 T_c 低于1h的充电段由于充电时间较短,其调控意义不强,不参与调控。

2)车辆停靠时长限制。电动汽车在停车时段内才参与电网调控。日间06:00—16:00时预期停靠时长 T 为

$$T = \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left[-\frac{(x - u_1)^2}{2\sigma_1^2}\right] \quad \sigma_1 = 1, u_1 = 4 \quad (17)$$

式中: x 为电动汽车停靠开始时刻。夜间00:00—6:00时及16:00—24:00时预期停靠时长 T 为

$$T = \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left[-\frac{(x-u_2)^2}{2\sigma_2^2}\right] \quad \sigma_2 = 4, u_2 = 20 \quad (18)$$

若某电桩的两段邻接充电数据相隔的时间 T_i 大于预期停靠时长,则真实停靠时长 T_p 为预期停靠时长 T , 否则停靠时长 T_p 为 T_i , 公式描述为

$$T_p = \begin{cases} T_i & T_i \leq T \\ T & T_i > T \end{cases} \quad (19)$$

若该充电时段为当日内该电桩最后一次充电,则其参与调控后充电调控时段为此充电开始时刻至第二日 06:00 时。

3) 荷电状态限制及充电功率限制。对真实充电数据进行计算,得到车辆原始充电量 C , 用户参与电网调控后其在离开电桩前所充电量 C_n 需大于等于原始充电量 C , 且充电功率 P_o 小于等于电桩最大充电功率 P_{max} , 公式描述为

$$\begin{cases} P_o \leq P_{max} \\ C_n \geq C \end{cases} \quad (20)$$

4) 当电动汽车用户充电紧迫性不高时, 用户倾向于在低价时段充电, 此时聚合商进行电价补偿, 用户一方面充电迫切性不强, 另一方面能获得额外收益, 能有效激励用户参与调控^[21]。因此在使用用户行为影响因素模糊化算法输出结果后需计算影响系数: 低电价区影响系数为 1.2, 高电价区影响系数为 0.8。

根据以上设定的规则, 仿真流程为: 首先载入原始充电数据库, 进行充电时长约束, 选取充电时长大于 1 h 的数据; 其次引入用户行为隶属度函数, 计算用户参与需求响应的可能性; 然后针对参与调控的部分车辆, 设置停靠时长约束、荷电状态约束及充电功率约束; 最后引入电价影响因素, 通过蒙特卡洛模拟, 输出计及用户行为偏好后的充电行为数据库。仿真流程如图 3 所示。

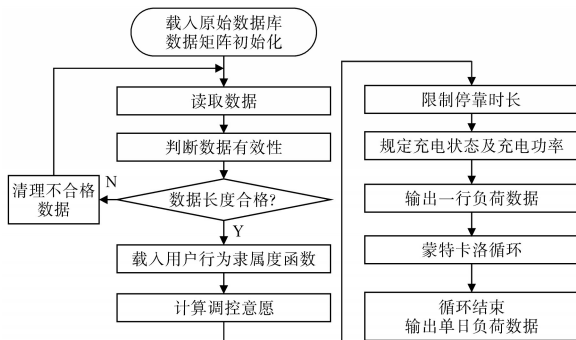


图3 计及用户行为偏好的充电行为数据库生成算法流程图
Fig.3 Flowchart of algorithm for generating a charging behavior database considering user behavior preferences

3 仿真实验

3.1 充电行为数据预处理及 MF-LSTM 参数设置

为提升 MF-LSTM 训练速度并有效拟合负荷曲线, 首先, 对某城市电网 2021 年充电负荷数据进行预处理:

1) 异常数据处理。针对数据库中充电功率低于 1 kW·h 数据、大于 60 kW·h 数据、时长为 1 采样点数据及空数据, 默认其为无效异常数据进行删除。

2) 扩充数据样本集。由于电动汽车充电功率存在上升—平稳—下降的变化趋势, 针对充电起始结束时刻的大功率充电数据, 对其进行插值计算填补扩充数据两端。

3) 数据标准化。为了获得较好的拟合并防止训练发散, 将训练数据标准化为具有零均值和单位方差的函数, 即

$$\mu = \frac{1}{N_{EV}} \sum_{i=1}^{N_{EV}} DataTrain_i \quad (21)$$

$$\sigma = \sqrt{\frac{1}{N_{EV} - 1} \sum_{i=1}^{N_{EV}} |DataTrain_i - \mu|^2} \quad (22)$$

归一化函数如下:

$$data_i = \frac{DataTrain_i - \mu}{\sigma} \quad (23)$$

式中: N_{EV} 为车辆总数; $DataTrain_i$ 为第 i 辆车的充电数据; $data_i$ 为标准化后第 i 辆车的充电数据。

4) 训练集和测试集划分。选取某城市某居民区集中式充电站 2021 年 1 月—2021 年 2 月的真实充电负荷数据, 将其按周一至周日 7 d 为一个周期进行划分, 从 1 月 11 日开始至 2 月 7 日结束, 共 4 个周期, 充电负荷曲线如图 4 所示。由于 MF-LSTM 网络更适用于时间序列数据处理, 因此将 4 个周期的负荷数据转化为一维时间序列矩阵。选取的负荷数据以 15 min 为一个采样点, 一周共 672 个采样点, 选取其中一周负荷数据绘制负荷波动图如图 5 所示。




图4 4个负荷周期波动

Fig.4 Four groups of load cycle fluctuations




图5 一周期内充电负荷曲线
Fig.5 Load curve in one week

由图4可见,各周负荷曲线波动大致趋势相同,这体现出负荷曲线具有周周期性的特征;由图5可见,一周期内负荷曲线具有7个波峰和7个波谷,体现了电动汽车充电负荷曲线具有日周期性的特征。

根据文献[18],将序列的前80%用于训练,后20%用于测试。

完成数据预处理后,对MF-LSTM参数进行设置,对网络进行优化。设置不同隐藏层层数及隐藏层神经元个数,对其训练速度及预测误差进行多次计算,取平均值,统计结果如表1所示。

根据表1,当隐藏层层数为2、神经元个数为100时,其均方根误差RMSE最小,决定系数R2最大,且训练速度较低,因此设置隐藏层层数为2,隐藏层神经元个数为100。

表1 不同隐藏层层数及神经元个数MF-LSTM训练结果统计表

隐藏层层数	隐藏层神经元个数	RMSE	R2	训练速度
1	100	35.298 4	0.939 6	81
1	200	45.152 5	0.901 4	208
2	100	29.777 1	0.957 1	195
2	200	45.032 3	0.902 4	514
3	100	39.463 5	0.925 0	307

不同设置下训练结果使用均方根误差RMSE指标和决定系数R2指标进行对比分析,公式为

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{pred} - Y_{test})^2}{n}} \quad (24)$$

$$R2 = 1 - \frac{\sum_{i=1}^n (Y_{pred} - Y_{test})^2}{\sum_{i=1}^n (Y_{test} - \frac{1}{n} \sum_{i=1}^n Y_{pred})^2} \quad (25)$$

式中:Y_{pred}为预测值;Y_{test}为验证值;n为数据总数。

3.2 不同深度学习模型负荷预测结果对比分析

基于原始数据库,使用4种深度学习模型:反向传播(back propagation, BP)、RNN、门循环单元(gate recurrent unit, GRU)与MF-LSTM分别对负荷进行预测,对其准确度、拟合效果、训练速度进行对比分析,对比结果如表2所示。由于本文着重考虑的是基于历史数据对未来短期内负荷变化进行预测,以此进行日前调度安排,因此需要较高的预测精确度,而对训练时间要求相对不高。4种模型中,MF-LSTM预测精确度最高,虽然其训练时间较长,但整体训练效果最符合本文所设场景;同时MF-LSTM所包含的3种阀门节点能为每个区域进行针对性调整,提升远期记忆的连接能力,在具有固定特征成分的不稳定时间序列预测上具有更好的预测效果,因此MF-LSTM神经网络对于本文应用场景适配性最佳。

表2 4种深度学习模型验证效果对比结果

Tab.2 Comparison results of verification effects of four deep learning models

神经网络	RMSE	R2	训练速度
BP	35.342 2	0.942 3	123
RNN	57.029 2	0.834 6	118
GRU	59.163 5	0.824 4	106
MF-LSTM	29.777 1	0.957 1	195

3.3 计及用户偏好的充电负荷调控潜力

基于3.1节适当扩充后的充电数据库和2.2节考虑用户行为偏好生成的新数据库,分别作为综合考虑用户行为偏好前、后的充电负荷数据,并利用训练完成的MF-LSTM网络对充电负荷进行时序预测,预测结果对比如图6所示。根据图6,发现考虑用户行为偏好后电动汽车充电负荷峰值明显下降,负荷高峰数减少,负荷高峰期延后,日间负荷高峰转移至夜间,夜间负荷均值升高,一定程度实现了系统削峰填谷的目标。




图6 本文算法负荷对比

Fig.6 Comparison of algorithm load in this paper

对比分析两种情况下的充电负荷差异,综合考虑用户行为偏好的负荷曲线波动性趋于平稳,

负荷极值降低,负荷峰谷差明显减小。从图6中看出,负荷可调时间主要集中于用户最后一次出行完成后接入电桩时刻至用户第二天出行时刻,日间参与调控时段短、调控潜力小,这与集中式充电站所处区域为居民区相关。

若设置用户自身参与需求响应的可能性为50%,生成用户参与需求响应后的负荷数据,利用LSTM网络对充电负荷进行时序预测,此时考虑用户行为偏好前、后的负荷曲线对比如图7所示。




图7 设置用户参与度算法负荷对比

Fig.7 Set user engagement algorithm load comparison

根据图7,直接设置用户心理参与可能性后的负荷曲线相较于不考虑用户选择的负荷曲线,负荷高峰值有所下降,夜间低谷期负荷有所上升,说明部分用户会参与需求响应,起到一定的削峰填谷效果;但同时,受外界分时电价影响,用户在电价高峰期或用电急迫期实际参与需求响应的比例远低于50%,设置用户心理参与度无法有效体现多种因素影响下用户参与调控的实际情况;同时,本文在计算用户参与需求响应可能性时,引入用户隶属函数,取代了常规的“低中高”参与度设置方法,计算结果具有更强的应用性。因此,本文所提出的综合考虑用户行为偏好的模糊控制方法将具有更好的应用效果。

抽取2月6日某居民区计及用户行为偏好后的负荷预测曲线作为对照组,通过分别改变用户行为偏好因素,得到不同用户行为偏好下的负荷曲线对比图,如图8所示。

图8中,对照组负荷曲线设定参数为初始荷电状态0.5,用户电价敏感程度中等,电价补偿价格中等,所处季节为冬季,所处日期为节假日;其余曲线为仅改变其中一个参数下的负荷变化情况。

根据图8可得:当仅改变一个参数时,改变初始荷电状态及补偿电价会对用户参与调控产生较大影响;而在中等补偿电价情况下,用户自身

电价敏感程度对其参与调控影响不大,说明中等补偿电价对用户吸引力不强,若想吸引用户参与调控,需进一步提升补偿电价。




图8 单日内负荷曲线变化

Fig.8 Change of load curves in one day

为了量化用户行为偏好对负荷调控的影响程度,提出了电站负荷平均变化值。计算对照组日间06:00—20:00与夜间20:00—次日06:00电站负荷平均变化值,计算公式为

$$P_c = \frac{\sum(P - P_u)}{4h} \quad (26)$$

式中: P_c 为负荷平均变化值; P 为每个时间节点不考虑用户偏好的负荷; P_u 为每个时间节点考虑用户偏好后的负荷; h 为时间段的小时数。

计算可得:日间06:00—20:00负荷平均变化值为-62.117 kW,夜间20:00—次日06:00负荷平均变化值为88.952 kW。以上数据表明,居民区集中式充电站在夜间负荷均值上升,日间负荷均值下降,且夜间变化大,证明夜间可调潜力大,且计及用户偏好后能有效减小电网波动性,提高电网运行的稳定性。

进一步计算各情况下的负荷变化平均偏移百分比、极值与标准差,计算结果如表3所示。

表3 各种情况下单日负荷变化对比

Tab.3 Comparison of daily load changes under various conditions

	平均偏移/ %	极大/ (kW·h)	极小/ (kW·h)	标准差
不考虑用户行为偏好	/	618.5	0	177.4
对照组	62.6	523.5	15.4	114.1
荷电状态0.7	74.6	528.1	13.9	115.2
荷电状态0.3	31.6	557.0	8.4	146.8
电价敏感高	65.6	523.5	12.8	114.4
电价敏感低	55.5	535.9	15.7	117.1
电价补偿高	65.6	527.1	12.0	114.5
电价补偿低	24.8	576.6	2.6	161.7

根据表3可得:在荷电状态高、电价敏感程度高、电价补偿高的情况下,负荷平均偏移百分比大,证明这三种情况下用户选择参与调控可能性强;同时,这三种情况下单日内负荷标准差小,负荷极大值降低,证明负荷波动小,用户在参与调控后可实现负荷削峰填谷,达到减小峰谷差的效果。在不同荷电状态及电价补偿情况下,负荷平均偏移多,标准差变化大,说明电动汽车荷电状态及电价补偿对调度潜力影响较大。

3.4 用户行为偏好影响度分析

进一步对不同日期、不同季节、不同功能区区域的集中式充电站负荷进行统计整理,分析各情况下用户行为偏好差异的影响程度。

1)不同日期。主要针对居民区集中式电站的工作日与节假日差异,将1月11日至2月7日的真实充电负荷数据与2.2节计及用户行为偏好生成的充电负荷数据划分为工作日和节假日,分为4组工作日共20d和4组节假日共8d分别进行负荷预测,依次通过控制用户行为偏好,分析不同日期下用户行为偏好对调控容量的影响,分析结果如表4所示。

表4 各情况下工作日负荷变化对比

Tab.4 Comparison of workday load changes under various conditions

	平均偏移/ %	极大/ (kW·h)	极小/ (kW·h)	标准差
不考虑用户行为偏好	/	360.2	0	111.2
对照组	73.1	300.3	13.3	69.9
荷电状态0.7	83.5	317.5	10.2	72.8
荷电状态0.3	37.1	330.2	23.0	80.4
电价敏感高	76.9	303.4	10.3	69.1
电价敏感低	63.4	301.2	16.2	68.1
电价补偿高	74.1	298.8	13.0	69.8
电价补偿低	25.5	347.1	5.6	96.9

结合表3和表4,首先可得工作日负荷极大

值相较节假日明显下降,可能是节假日用户外出多,回家后所需充电电量提升导致;其次工作日各情况下平均偏移较节假日也有所提升,且荷电状态及电价补偿对其影响最大,改变其参数会对负荷曲线产生较大影响;同时,工作日用户参与调控后,负荷标准差更小,说明工作日用户参与调控后,负荷波动性更低,负荷曲线更为平缓,证明工作日用户参与调控可能性更高,负荷调控潜力更大。

2)不同季节。主要针对居民区集中式电站的夏季与冬季差异,利用夏季6月与冬季2月的真实负荷数据与2.2节计及用户行为偏好生成的充电负荷数据分别进行负荷预测,依次通过控制用户行为偏好,分析不同季节下用户行为偏好对调控容量的影响,分析结果如表5所示。

表5 各情况下夏季单日负荷变化对比

Tab.5 Comparison of daily load changes in summer under various conditions

	平均偏移/ %	极大/ (kW·h)	极小/ (kW·h)	标准差
不考虑用户行为偏好	/	814.0	0	178.6
对照组	43.3	623.9	27.8	137.3
荷电状态0.7	47.0	617.2	29.4	136.3
荷电状态0.3	23.3	691.4	23.5	158.6
电价敏感高	44.5	622.4	30.0	136.2
电价敏感低	39.9	629.7	22.5	139.6
电价补偿高	43.9	613.3	29.3	136.4
电价补偿低	17.5	764.3	9.6	168.0

对比表3与表5,夏季负荷高峰值有明显提升,原因是夏季温度升高,电动汽车除行驶消耗外其余电量消耗较多,充电所需电量提升,且随着时间推移电动汽车保有量不断提升,充电负荷高峰也随之提升,相较于1月负荷最高峰值提升了19.24%。经过调控后,夏季负荷高峰的下降比例大于冬季,说明夏季响应调控的用户更多,电动汽车调控潜力更大。夏季负荷曲线标准差相较冬季更大,说明夏季负荷波动更明显,对电网安全稳定运行造成不利影响,急需对充电行为进行调控。

3)不同功能区。主要针对居民区与商业区的集中式电站差异,利用1月11日至2月7日两者的真实负荷数据与2.2节计及用户行为偏好生成的充电负荷数据进行负荷预测,依次通过控制用户行为偏好,分析不同功能区用户行为偏好对调控容量的影响,分析结果如表6所示。

表6 商业区各情况下单日负荷变化对比
Tab.6 Comparison of daily load changes under different conditions in commercial district

	平均偏移/ %	极大/ (kW·h)	极小/ (kW·h)	标准差
不考虑用户行为偏好	/	599.3	37.1	138.9
对照组	39.1	506.4	93.0	106.5
荷电状态0.7	42.4	515.0	96.9	110.4
荷电状态0.3	19.7	492.0	103.8	108.3
电价敏感高	39.1	507.5	108.4	105.5
电价敏感低	34.6	500.1	97.6	102.1
电价补偿高	38.4	511.3	97.3	106.8
电价补偿低	8.7	555.4	71.4	124.8

对比表3与表6,首先由于商业区停车场充电桩更多,车流量较大,充电车辆数稳定,因此商业区充电负荷峰谷差较小,负荷波动小;其次,商业区充电负荷偏移相较居民区较小,说明商业区

充电车主参与调控可能性小,由于停靠时间短,参与调控过程复杂,车主更倾向于直接充电;最后,商业区车主在荷电状态不同、电价敏感程度不同、电价补偿价格不同的情况下,充电负荷标准差变化不明显,证明商业区负荷调控潜力不大。

计算各情况下电站的可调持续性指标及可调时段,得到表7。由于部分可调时段持续性较差,选取持续时长大于1h的时段列入表格。

根据表7,居民区可调潜力明显大于商业区,可调容量及可调持续时长都优于商业区。居民区可调时间段主要在傍晚及夜间,可调持续时间长、可调时间聚集、可调容量大;商业区可调持续时间长、调控时间段分散、可调容量小。因此,后续应进一步对居民区集中电站进行负荷调控。

对以上各情况下电站的充电负荷单日可调容量进行分析,绘制可调容量指标变化如图9所示。

表7 各情况下电站可调指标

Tab.7 Adjustable indicators of charging stations under various circumstances

	标准差	50 kW·h 可调时段	50 kW·h 可调时长/h	100 kW·h 可调时段	100 kW·h 可调时长/h	150 kW·h 可调时段	150 kW·h 可调时长/h
居民区冬季节假日	118.2	23:00—05:00 12:30—13:30 14:45—21:45	14	23:00—00:30 01:15—04:45 15:00—21:00	11	02:45—04:00 15:00—17:45	4
居民区冬季工作日	103.4	21:00—04:45 15:30—20:30	13	21:30—02:45 15:45—20:00	9	16:00—18:00	2
居民区夏季节假日	114.8	21:15—04:45 13:45—15:00 15:30—18:45 19:30—20:30	13	01:00—02:45 15:30—18:30 21:45—23:45	7	无	无
商业区冬季节假日	84.4	00:30—03:15 08:45—10:00 12:00—13:30 16:15—17:15 18:30—19:30 22:00—23:45	9	16:15—17:15 18:45—19:15	1.5	无	无

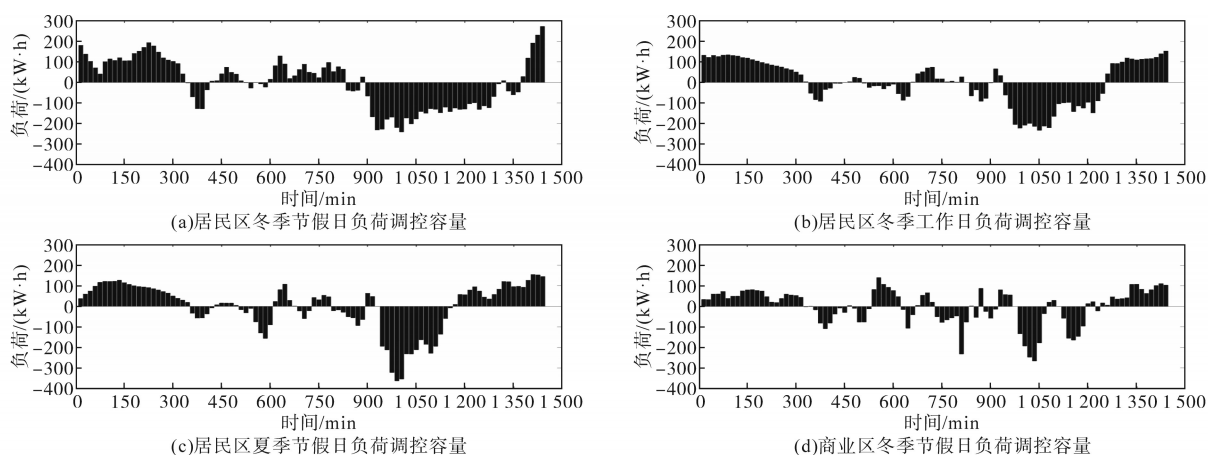


图9 各情况下电站可调负荷容量变化图

Fig.9 Variation diagram of adjustable load capacity of power station under different conditions

根据对以上几种场景进行分析,初始荷电状态及电价补偿因素对用户参与调控的影响程度最大,在其他条件相同时,电价补偿价格越高,初始荷电状态越高,用户选择参与调控可能性越大,越容易接受电网调控。集中式电站调控潜力在不同情况下具有差异:居民区调控潜力普遍大于商业区,居民区可调时段集中,商业区可调时段分散。在考虑用户选择偏好因素后,电站充电负荷峰值都产生一定的下降,证明该方法可以实现充电负荷的削峰填谷,以缓解短小时内高负荷压力,对电网安全稳定运行提供支撑。

4 结论

本文针对目前评估电动汽车调度潜力过程中,用户参与度设置理想化、参数设置主观化的问题,提出一种基于用户行为隶属度函数的模糊推理算法,并将其输入LSTM神经网络对考虑用户行为偏好前、后的充电负荷进行对比,可以得出以下结论:

1)基于隶属度函数与LSTM构建的MF-LSTM模型将用户行为偏好模糊化处理到 $[0, 10]$ 区间作为神经网络特征向量输入,实现了多输入条件下推理单输出的预测,且预测效果较好。

2)计及用户充电偏好因素后,电网负荷产生明显变化,通过调控并网电动汽车的充电行为,能够防止规模化电动汽车接入电网造成过大峰谷差,较好地实现削峰填谷目标。

3)不同场景下电动汽车用户参与电网调控受不同因素影响程度存在差异,居民区电动汽车调控潜力较大,荷电状态与补偿电价因素对用户行为影响程度高,对时间、地点进行划分能为电网精细化调控并网车辆提供参考价值。

4)研究了用户行为、充电负荷的不确定性,量化了用户行为对可调负荷的影响,分析了多种场景下、多种时间参数下的可调负荷容量。

后续将在以下方面进行深入研究:1)研究负荷特性分类,聚类分析多种类电动汽车参与调控时用户行为偏好差异;2)挖掘个人电桩负荷数据特性,针对分布式电桩评估其调控潜力;3)进一步增加其余充电负荷相关因素的不确定性分析,提升所提算法的应用性。

参考文献

[1] 徐潇源,王晗,严正,等. 能源转型背景下电力系统不确定性

及应对方法综述[J]. 电力系统自动化, 2021, 45(16): 2-13.

- XU Xiaoyuan, WANG Han, YAN Zheng, et al. Overview of power system uncertainty and its solutions under energy transition [J]. Automation of Electric Power Systems, 2021, 45(16): 2-13.
- [2] 陈忠华,高振宇,陈嘉敏,等. 考虑不确定性因素的综合能源系统协同规划研究[J]. 电力系统保护与控制, 2021, 49(8): 32-40.
- CHEN Zhonghua, GAO Zhenyu, CHEN Jiamin, et al. Research on cooperative planning of an integrated energy system considering uncertainty[J]. Power System Protection and Control, 2021, 49(8): 32-40.
- [3] 邓艺璇,黄玉萍,黄周春. 基于随机森林算法的电动汽车充电容量预测[J]. 电力系统自动化, 2021, 45(21): 181-188.
- DENG Yixuan, HUANG Yuping, HUANG Zhouchun. Charging and discharging capacity forecasting of electric vehicles based on random forest algorithm[J]. Automation of Electric Power Systems, 2021, 45(21): 181-188.
- [4] SHAABAN M F, EL-SAADANY E F. Accommodating high penetrations of PEVs and renewable DG considering uncertainties in distribution systems[J]. IEEE Transactions on Power Systems, 2014, 29(1): 259-270.
- [5] ZENG B, FENG J, LIU N, et al. Cooptimized parking lot placement and incentive design for promoting PEV integration considering decision-dependent uncertainties[J]. IEEE Transactions on Industrial Informatics, 2021, 17(3): 1863-1872.
- [6] 张美霞,孙铨杰,杨秀. 考虑多源信息实时交互和用户后悔心理的电动汽车充电负荷预测[J]. 电网技术, 2022, 46(2): 632-645.
- ZHANG Meixia, SUN Quanjie, YANG Xiu. Electric vehicle charging load prediction considering multi-source information real-time interaction and user regret psychology[J]. Power System Technology, 2022, 46(2): 632-645.
- [7] 李瑶虹,陈良亮,刘卫东,等. 基于用户出行链和调控意愿的城市级私家电动汽车调控能力评估[J]. 电力建设, 2021, 42(5): 100-112.
- LI Yaohong, CHEN Liangliang, LIU Weidong, et al. Regulation ability estimation of private EVs at city level considering users' trip chain and regulation willingness[J]. Electric Power Construction, 2021, 42(5): 100-112.
- [8] 周椿奇,向月,童话,等. 轨迹数据驱动的电动汽车充电需求及V2G可调控容量估计[J]. 电力系统自动化, 2022, 46(12): 46-55.
- ZHOU Chunqi, XIANG Yue, TONG Hua, et al. Trajectory-data-driven estimation of electric vehicle charging demand and vehicle-to-grid regulable capacity[J]. Automation of Electric Power Systems, 2022, 46(12): 46-55.
- [9] 李滨,黎智能,陈碧云. 基于DFT的智能园区中央空调负荷调控策略[J]. 电网技术, 2020, 44(7): 2549-2557.
- LI Bin, LI Zhineng, CHEN Biyun. DFT-based intelligent park central air-conditioning regulation strategy[J]. Power System Technology, 2020, 44(7): 2549-2557.
- [10] 侯慧,徐焘,肖振锋,等. 计及可调控负荷的发用电一体化综

- 合优化调度[J]. 电网技术, 2020, 44(11): 4294-4301.
HOU Hui, XU Tao, XIAO Zhenfeng, et al. Generation and load integrated optimal scheduling considering adjustable load[J]. Power System Technology, 2020, 44(11): 4294-4301.
- [11] 孙毅, 黄绍模, 李泽坤, 等. 考虑时域特性的异构温控负荷联合调控策略[J]. 电网技术, 2020, 44(12): 4722-4733.
SUN Yi, HUANG Shaomo, LI Zekun, et al. Joint control strategy of heterogeneous temperature control load considering time domain characteristics[J]. Power System Technology, 2020, 44(12): 4722-4733.
- [12] 赵星宇, 胡俊杰. 集群电动汽车充电行为的深度强化学习优化方法[J]. 电网技术, 2021, 45(6): 2319-2327.
ZHAO Xingyu, HU Junjie. Deep reinforcement learning based optimization for charging of aggregated electric vehicles[J]. Power System Technology, 2021, 45(6): 2319-2327.
- [13] 杨羊, 马玉秋. 电动汽车智能充电系统控制策略研究[J]. 电气传动, 2019, 49(12): 64-70.
YANG Yang, MA Yuqiu. Research on control strategy of electricvehicle intelligent charging system[J]. Electric Drive, 2019, 49(12): 64-70.
- [14] 陈璐, 王璨, 胡昊, 等. 三相不平衡配网下电动汽车有序充电控制策略[J]. 电气传动, 2022, 52(11): 42-50.
CHEN Lu, WANG Can, HU Hao, et al. Orderly charging control strategy for electric vehicles in three-phase unbalanced distribution network[J]. Electric Drive, 2022, 52(11): 42-50.
- [15] 文旭, 杨可, 毛锐, 等. 可调节负荷调控能力评估行业标准研究及应用[J]. 电网技术, 2021, 45(11): 4585-4593.
WEN Xu, YANG Ke, MAO Rui, et al. Research and application of industry standards for evaluation of adjustable load control capacity[J]. Power System Technology, 2021, 45(11): 4585-4593.
- [16] 文旭, 陈鑫, 张爱枫, 等. 含可调节负荷的风光互补微电网随机调度市场风险管控方法[J]. 电网技术, 2021, 45(11): 4308-4318.
WEN Xu, CHEN Xin, ZHANG Aifeng, et al. Stochastic dispatching market risk control for wind and photovoltaic microgrid integrated with adjustable load[J]. Power System Technology, 2021, 45(11): 4308-4318.
- [17] 李鹏, 何帅, 韩鹏飞, 等. 基于长短期记忆的实时电价条件下智能电网短期负荷预测[J]. 电网技术, 2018, 42(12): 4045-4052.
LI Peng, HE Shuai, HAN Pengfei, et al. Short-term load forecasting of smart grid based on long-short-term memory recurrent neural networks in condition of real-time electricity price[J]. Power System Technology, 2018, 42(12): 4045-4052.
- [18] 郑瑞骁, 张姝, 肖先勇, 等. 考虑温度模糊化的多层长短期记忆神经网络短期负荷预测[J]. 电力自动化设备, 2020, 40(10): 181-186.
ZHENG Ruixiao, ZHANG Shu, XIAO Xianyong, et al. Short-term load forecasting of multi-layer long short-term memory neural network considering temperature fuzziness[J]. Electric Power Automation Equipment, 2020, 40(10): 181-186.
- [19] 陆继翔, 张琪培, 杨志宏, 等. 基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8): 131-137.
LU Jixiang, ZHANG Qipei, YANG Zhihong. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8): 131-137.
- [20] 周华嫣然, 周羿宏, 胡俊杰, 等. 人工智能技术支撑的集群电动汽车实时优化调度策略[J]. 电网技术, 2021, 45(4): 1446-1459.
ZHOU Huayanran, ZHOU Yihong, HU Junjie, et al. Real-time optimization scheduling strategy for aggregated electric vehicles supported by artificial intelligence technology[J]. Power System Technology, 2021, 45(4): 1446-1459.
- [21] 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合商调度策略[J]. 电网技术, 2022, 46(4): 1259-1269.
HOU Hui, WANG Yifan, ZHAO Bo, et al. Electric vehicle aggregator dispatching strategy under price and incentive demand response[J]. Power System Technology, 2022, 46(4): 1259-1269.

收稿日期: 2022-05-28
修改稿日期: 2022-06-29