

·电动汽车与智能电网互动(V2G)优化控制技术专题·

基于供需两侧协同优化的电动汽车V2G充放电 负荷时空分布预测研究*

彭伟伦¹ 马力¹ 刘琦颖¹ 于洋²

(1.广东电网有限责任公司广州供电局,广州 510630;2.烟台海颐软件股份有限公司,烟台 264000)

【摘要】为准确预测电动汽车的V2G充放电负荷,以调节电网负荷峰谷差,保证供电稳定性,提出了一种基于供需两侧协同优化的电动汽车V2G充放电负荷时空分布预测方法。构建供需两侧协同优化目标模型,利用鲸鱼优化算法迭代求解,得出最优充放电负荷曲线,据此明确最优充放电时段。采集不同空间区域最优充放电时段内的充放电负荷影响指标,并以此为输入,构建基于多元线性回归的预测模型,实现电动汽车V2G充放电负荷时空分布预测。试验结果表明,采用所提出的方法得到的负荷预测模型具有较大的决定系数,表明该方法的预测结果更接近实际负荷,具有较高的预测准确性。

关键词:协同优化 电动汽车 V2G充放电负荷 时空分布预测

中图分类号:TP225.66 **文献标志码:**A **DOI:** 10.19620/j.cnki.1000-3703.20230832

Research on Prediction of Time and Space Distribution of V2G Charge and Discharge Load of Electric Vehicle Based on Collaborative Optimization of Supply and Demand Side

Peng Weilun¹, Ma Li¹, Liu Qiying¹, Yu Yang²

(1. Guangzhou Power Supply Bureau, Guangdong Power Grid Co., Ltd., Guangzhou 510630; 2. Yantai Haiyi Software Co., Ltd., Yantai 264000)

【Abstract】In order to accurately predict the V2G charging and discharging load of electric vehicles, so as to regulate the peak to valley difference of power grid load and ensure power supply stability, this paper proposed a spatiotemporal distribution prediction method for V2G charging and discharging loads of electric vehicles based on collaborative optimization of supply and demand sides. A collaborative optimization objective model for both supply and demand sides was built, the Whale Optimization Algorithm was used for iterative solution to obtain the optimal charging and discharging load curve, and the optimal charging and discharging period was determined. The influencing indicators of charging and discharging loads within the optimal time periods in different spatial regions were collected, serving as inputs for constructing a prediction model based on multiple linear regression, thus achieving the prediction of spatial-temporal distribution of electric vehicle V2G charging and discharging loads. The experimental results show that the load prediction model obtained with the proposed method has a relatively large coefficient of determination, indicating that the prediction results of this research method are closer to the actual load, and have high prediction accuracy.

Key words: Collaborative optimization, Electric vehicle, V2G charging and discharging load, Time-space distribution prediction

【引用格式】彭伟伦, 马力, 刘琦颖, 等. 基于供需两侧协同优化的电动汽车V2G充放电负荷时空分布预测研究[J]. 汽车技术, 2024(6): 17-23.

PENG W L, MA L, LIU Q Y, et al. Research on Prediction of Time and Space Distribution of V2G Charge and Discharge Load of Electric Vehicle Based on Collaborative Optimization of Supply and Demand Side[J]. Automobile Technology, 2024(6): 17-23.

1 前言

在车辆与电网互动(Vehicle to Grid, V2G)场景中,

电动汽车的充、放电过程分别从电网获取电能和向电网释放电能,将给电网调度带来巨大压力。因此,需要准确预测电动汽车的V2G充放电负荷,据此制定合理有

*基金项目:中国南方电网有限责任公司科技项目(GZHKJXM20210055)。

序的充电策略,从而有效调节充放电功率和负荷峰谷差,实现电网供电与电动汽车负荷之间的供需互补,优化电网调度管理^[1]。

在上述背景下,很多学者进行了相关研究。张琳娟等^[2]首先分析了电动汽车充放电行为的影响因素,建立了城市路网拓扑结构,利用蒙特卡洛方法实现了充电负荷时空分布预测。该方法可准确预测充电负荷的连续变化,但需要大量的数据作为支撑,因此预测精度并不稳定。袁小溪等^[3]将研究区域进行网格划分,统计每个网格的充电负荷,并从中选取预测指标,构建了电动汽车充电负荷预测模型。这种方法简单、高效,但是拟合估计一旦不准确,易造成充电负荷的累积误差。李恒杰等^[4]采集了预测所需基础数据并进行清洗处理,然后从中总结出了充电负荷的影响因素。这种方法所需计算资源少、泛化能力强,但收敛速度慢,因此易陷入局部最优,导致预测结果存在误差。Dabbaghjamesh等^[5]提出将Q学习(Q-Learning)方法用于电动汽车充电站的负荷预测,以改进传统人工智能方法的预测精度,该方法对训练数据的要求较为严格,难以保证全局收敛性。Feng等^[6]针对电动汽车(Electric Vehicle, EV)数量、环境温度和电价等系列因素对EV充电站负荷预测精度的影响问题,提出了基于多变量余项校正灰色模型和长短时记忆网络相结合的负荷预测方法。所述方法结构复杂,同时,误差的累积效果评估存在一定困难。石立国等^[7]基于电动汽车充电站的非线性时序负荷数据,运用卷积神经网络和门控循环单元相结合提取具有时序特性的重要特征,以区分不同时间序列的重要度。但是,该方法收敛速度较慢,影响预测准确性。

针对上述问题,为实现供需两侧的平衡,本文研究基于供需两侧协同优化的电动汽车V2G充放电负荷时空分布预测方法,以期提高负荷预测准确性,为电网合理调度提供可靠的参考依据。

2 供需两侧协同优化方案设计

为解决电动汽车接入电网造成负荷峰谷差过大、线路过载的问题,本文对供需两侧进行协同优化^[8]。使用鲸鱼优化算法计算种群个体的适应度函数值,并进行降序排序,获取目标函数值作为最优个体,在迭代中持续优化,有效提高算法的收敛速度,获取最优放电计划。然后,结合历史数据分析最优充放电负荷曲线,明确最优充放电时段,采集该时间段的数据,将最优充放电负荷曲线和该时段的数据作为负荷预测的主要参数,为负荷预测提供基础^[9]。

2.1 供需两侧协同优化目标函数

2.1.1 需求侧(用户)目标函数

使用成本低是用户选择电动汽车的重要原因,因此用户用电成本最小化是需求侧的主要目标, T 时段需求侧(用户)目标函数模型^[10]为:

$$Q_1 = \sum_{i=1}^n \sum_{t=1}^T \Delta t A_i^t F_i^t C^t + D_i^t - \sum_{i=1}^n \sum_{t=1}^T \Delta t \hat{A}_i^t \hat{F}_i^t \hat{C}^t \quad (1)$$

式中: Q_1 为用户用电成本,该目标函数的最小值表示用户在能源消耗和成本方面达到最佳平衡时的用电情况; Δt 为时长; A_i^t 、 \hat{A}_i^t 分别为 t 时段第 i 辆电动汽车的充、放电状态; D_i^t 为 t 时段第 i 辆电动汽车放电损耗成本; F_i^t 、 \hat{F}_i^t 分别为 t 时段第 i 辆电动汽车的充电功率和放电功率; C^t 、 \hat{C}^t 分别为 t 时段充电电价和放电电价; n 为电动汽车数量。

2.1.2 供电侧(电网)目标函数

供电侧最核心的需求是在电动汽车接入后,不影响自身的稳定工作^[11]。针对该核心需求,建立如下目标函数,即电网负荷峰谷差最小^[12]:

$$Q_2 = E_{\max} - E_{\min} = \max_{1 \leq t \leq 24} \left(E^t + \sum_{i=1}^n F_i^t \right) - \min_{1 \leq t \leq 24} \left(E^t + \sum_{i=1}^n F_i^t \right) \quad (2)$$

式中: Q_2 为电网负荷峰谷差, E_{\max} 、 E_{\min} 分别为最大负荷、最小负荷, E^t 为 t 时段的基础负荷。

2.1.3 供需两侧协同优化目标函数

基于上述需求侧和供电侧目标模型的加权目标函数^[13]为:

$$\min Q = w_1 \left(\frac{Q_1}{\bar{Q}_1} \right) + w_2 \left(\frac{Q_2}{\bar{Q}_2} \right)$$

$$\text{s.t.} \begin{cases} \sum_{t=1}^{24} D_i^t \leq D_{i\max} \\ F_{i\min} \leq F_i^t \leq F_{i\max} \\ t_0 \leq t \leq t_1 \\ U_i^t \leq U_{i\max} \\ N_{i\min} \leq N_i^t \leq N_{i\max} \\ X_{i\min} \leq X_i^t \\ V_{i\min} \leq V_i^t \leq V_{i\max} \\ E^t \leq E_b^t \end{cases} \quad (3)$$

式中: \bar{Q}_1 为电动汽车无序充电时的充电费用; w_1 、 w_2 分别为需求侧、供电侧目标模型权重,取值范围为 $[0,1]$; $D_{i\max}$ 为第 i 辆电动汽车放电损耗成本的最大值; $F_{i\min}$ 、 $F_{i\max}$ 分别为第 i 辆电动汽车充放电功率的最小值、最大值; \bar{Q}_2 为未接入电网时的负荷峰谷差; t_0 、 t_1 分别为车辆到达和离开充电地点的时间^[14]; U_i^t 、 $U_{i\max}$ 分别为 t 时段第 i 辆电动汽车电池容量及其最大值; N_i^t 为 t 时段第 i 辆电动汽车的百公里电耗; $N_{i\min}$ 、 $N_{i\max}$ 分别为第 i 辆电

动汽车百公里电耗的最小值和最大值; $X_i^l, X_{i_{\min}}$ 分别为 i 时段第 i 辆电动汽车充电效率及其最小值; V_i^l 为 i 时段第 i 辆电动汽车平均行驶速度; $V_{i_{\min}}, V_{i_{\max}}$ 分别为第 i 辆电动汽车平均行驶速度的最小值和最大值; X_b^l 为充电负荷。

电力公司根据电力系统的负荷情况和市场需求设定峰时电价、平时电价和谷时电价等,为此,根据实际充电时间和电价档位得到电动汽车无序充电费用。为了更好地评估不同方案的优劣并作出更加有效的决策,需要考虑需求侧(用户)和供电侧(电网)不同目标模型的重要性,为每个目标设置权重,本文取 $w_1=w_2=0.5$,以同时对需求侧和供电侧进行优化。

2.2 目标模型优化求解

针对上述供需两侧协同优化目标模型,本文利用鲸鱼优化算法^[15]迭代求解,获得最优充电方案,明确充放电负荷分布情况。具体求解过程如下:

a. 设置算法的初始参数。包括鲸鱼数量 J 、收缩因子 a 、第 i 辆电动汽车 k 方位个体初始位置指标的向量 G_i^k 。

b. 初始化种群,即电动汽车充放电计划。

c. 计算种群中每个个体的适应度函数值,即计算式(3)所示每个电动汽车充放电计划的供需两侧协同优化目标函数值。

d. 对电动汽车充放电计划的目标函数值按照降序排列,选出其中最大值对应的充放电计划作为最优个体^[16],从而使算法更加聚焦于表现较好的解决方案,进而持续迭代优化,并最终接近全局最优解。

e. 记录最优个体及其位置。

f. 根据个体适应度值判断优劣,若优于上一代,对最优个体进行变异并保留变异后的位置,输出最终结果,否则进行下一步。变异公式如下:

$$R_i^{k+1} = G_i^k + g\Delta G_i^k \quad (4)$$

式中: R_i^{k+1} 为个体变异后的位置, g 为缩放比例常数, ΔG_i^k 为个体位置的差异向量。

g. 判断迭代次数是否小于最大迭代次数。若满足,进行下一步,否则输出最优充放电负荷。

h. 计算更新系数向量 χ 和随机向量 u :

$$\chi = 2u \quad (5)$$

i. 随机产生[0,1]范围内的行驶速度 V 。

j. 判断 V 是否小于 0.5。若满足,进行下一步;否则,进入步骤 1。

k. 判断 $|\chi|$ 是否小于等于 1。若满足,进入下一步;否则,随机搜索猎物。

1. 对个体进行差分变异操作并令 k 自加 1,然后重复步骤 c。

由上述过程可求出最优充电方案,明确充放电负荷分布^[17],计算流程如图 1 所示。

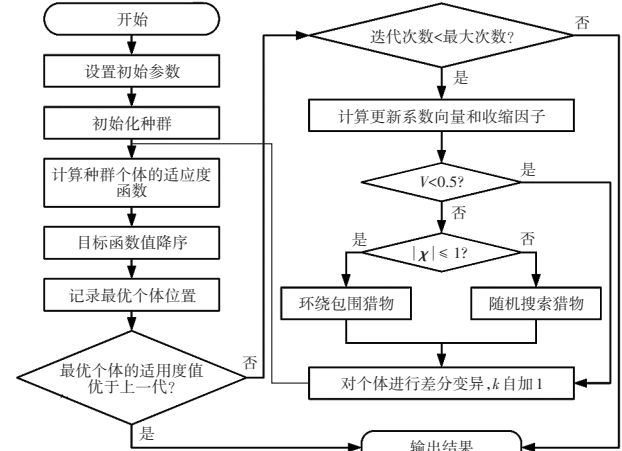


图 1 目标模型优化求解过程流程

3 基于协同优化的充放电负荷时空分布预测

利用得到的最优充放电负荷曲线可明确最优充放电时段^[18]。在以往的研究中,电动汽车 V2G 充放电负荷时空分布预测是集中进行的,没有考虑到不同时间段影响充放电负荷的因素不同,采用完全相同的影响因素作为预测基础,预测结果会存在较大的误差^[19]。针对这一问题,在确定最优充放电时间段后,采集该时间段空间区域内的数据:收集充电桩的使用情况、充电需求量、充电时长等,获取电网供电容量、发电量等信息以及充电桩位置、道路网络、交通流量等地理信息数据。以此为基础,分别进行充电时空分布预测和放电时空分布预测,为电网调整供电量提供依据。充电需求可能在不同地区和时间段之间存在差异。通过充电时空分布预测,平衡充电负载,避免过度集中充电,减少电网负荷峰值。预测分为两部分,即电动汽车 V2G 充放电负荷影响因素选取和时空分布预测模型构建。

首先选取建立预测模型所需要的输入指标。参考很多文献中选取的指标^[20],影响电动汽车充电的指标有区域功能、季节、节假日、温度、电池特性、充电模式、用户个人充电行为、充电桩建设,影响电动汽车放电的指标有区域功能、出行时间、节假日、温度、季节、人口分布、用户出行习惯、交通流量。

针对充放电负荷影响指标,采集最优充电时间段内对应充电影响指标的数据和最优放电时间段内对应放电影响指标的数据,然后进行归一化处理,统一各指标的纲^[21]。将处理好的充电影响指标记为 $P = \{p_0, p_1, \dots, p_8\}$,处

理好的放电影响指标记为 $L=\{l_0, l_1, \dots, l_8\}$ 。

协同优化目标模型求解需要考虑各种影响指标来制定最优的充放电策略,因此建立多元线性回归方程描述影响指标与实际充放电负荷之间的关系。以上述选出的影响指标为输入,以对应时空范围内的充放电负荷数据为输出,利用多元线性回归方程描述二者的关系^[22]:

$$H = g_0 + g_1 p_1 + g_2 p_2 + \dots + g_8 p_8 + \delta \quad (6)$$

$$Z = y_0 + y_1 l_1 + y_2 l_2 + \dots + y_8 l_8 + \gamma \quad (7)$$

式中: H 、 Z 分别为充、放电负荷, $g_0 \sim g_8$ 、 $y_0 \sim y_8$ 分别为充、放电负荷回归系数, d 、 γ 为充、放电随机误差项。

在上述基础模型中,回归系数 $g_0 \sim g_8$ 、 $y_1 \sim y_8$ 是未知的。针对其值的求解,首先需要利用历史观测样本建立多元线性回归方程组。通过历史观测样本能够验证供需两侧协同优化的有效性和合理性,建立多元线性回归方程组预测未来的充放电负荷情况,并与协同优化决策进行比较。以充电影响指标为例,假设有 n 组观测数据 $p_{i1}, p_{i2}, \dots, p_{i8} (i=1, 2, \dots, n)$, p_{ij} 为第 i 组第 j 个影响指标,有 n 组回归系数 $g_{i1}, g_{i2}, \dots, g_{i8} (i=1, 2, \dots, n)$, g_{ij} 为第 i 组第 j 个回归系数, n 个对应的历史充电负荷值为 $H_i (i=1, 2, \dots, n)$,由此建立多元线性回归方程组:

$$\begin{cases} H_1 = g_{10} + g_{11} p_{11} + g_{12} p_{12} + \dots + g_{18} p_{18} + \delta_1 \\ H_2 = g_{20} + g_{21} p_{21} + g_{22} p_{22} + \dots + g_{28} p_{28} + \delta_2 \\ \dots \\ H_n = g_{n0} + g_{n1} p_{n1} + g_{n2} p_{n2} + \dots + g_{n8} p_{n8} + \delta_n \end{cases} \quad (8)$$

为了便于模型的参数估计,进行确定性假设、零均值假设、同方差假定、正态性和独立性假定,然后利用最小二乘法求解上述多元线性回归方程组,估计回归系数 $g_0 \sim g_8$ 的取值,将其代入式(8),完成基于多元线性回归的电动汽车V2G充电负荷预测模型的初步构建。

预测模型构建完成后,进行参数检验,包括拟合优度检验、整体显著性以及回归系数显著性检验,分别验证样本观察值在样本回归线附近集合的紧密程度、模型中影响指标与充电负荷间线性关系的显著程度,以及影响指标对充电负荷的影响程度,从而确定影响指标能否保留在线性回归方程中^[23]。通过检验后,认为建立的充电预测模型合理,可用于实际充电预测。

重复上述步骤,建立放电预测的多元线性回归方程组,求取回归系数 $y_0 \sim y_8$ 并检验,通过检验后,认为建立的放电预测模型合理,可用于实际放电预测。

4 仿真分析

4.1 参数设置

为验证基于供需两侧协同优化的电动汽车V2G充

放电负荷时空分布预测的有效性,以某区域为研究对象,该区域包含4个功能区:居民区1含电动汽车1000辆、充电桩6台;居民区2含电动汽车600辆,设置4台充电桩;商业区含电动汽车400辆,设置6台充电桩;工业区含电动汽车412辆,设置4台充电桩。各区域同时充放电的EV概率分别设置为33.3%、18.75%、11.1%和25.8%,以反映各区域EV负荷的差异。

通过调查确定该区域内电动汽车的基础参数,如表1所示。

表1 电动汽车参数

参数	取值	参数	取值
电动汽车总数/辆	2 412	放电功率/kW	3.5
电池容量/kW·h	80	充电效率	0.9
充电功率/kW	8	平均行驶速度/km·h ⁻¹	80
百公里电耗/kW·h	18		

利用表1中的电动汽车相关参数建立更全面的协同优化目标函数约束,以实现电力供需平衡和充放电效率的优化。设置电动汽车的电池容量,可以限制充放电范围,保证电动汽车的电池容量在可接受的范围内。电池或储能设备在充放电过程中存在能量转换的损耗,通过限制百公里电耗,可以减少能量的损失,提高充放电效率。

4.2 最优充放电决策

采用鲸鱼优化算法对所设计的供需两侧协同优化目标函数进行求解,算法迭代终止后获取最优充电方案,进而明确充放电负荷分布情况,得到各区域的最优充放电决策和负荷分布曲线分别如图2和图3所示。

由图2和图3可知,当充放电负荷较高时,表示有更多的电动汽车需要充电,得出每个空间区域的最优充放电时段。此时能够更有效地利用充电设施,避免出现充电桩闲置或排队等待,电网需求量大,发电量增大,电动汽车充电平衡了增加的发电量。相反,当充放电负荷较低时,进行放电,通过将储存的电能释放到电网中,可以在需要时向电网提供额外的电力,帮助电网调节和维持稳定运行。最优充放电时段如表2所示。

4.3 充放电负荷预测

通过实地观察了解3个区域的功能划分、人流量、交通桩以及用户充电行为等信息,利用气象预报获得实时温度,由此采集表2中各时段4个功能区的充放电影响指标数据。结合最优充放电负荷曲线,对4个功能区的充电负荷进行预测。基于多元线性回归的电动汽车

V2G充、放电负荷预测模型分别为:

$$H = 2.5185 + 1.2352p_1 - 0.2633p_2 + 0.6255p_3 + 5.7884p_4 + 1.5256p_5 + 0.5268p_6 - 1.5873p_7 + (9) 24.2633p_8 + 0.2230$$

$$Z = 0.3256 + 4.8555l_1 + 0.7412l_2 + 7.5412l_3 + 2.2015l_4 - 1.3244l_5 + 2.5842l_6 + 3.3635l_7 + (10) 10.6683l_8 + 0.1472$$

利用上述模型对4个功能区某日的充放电负荷进行预测,结果如图4和图5所示。

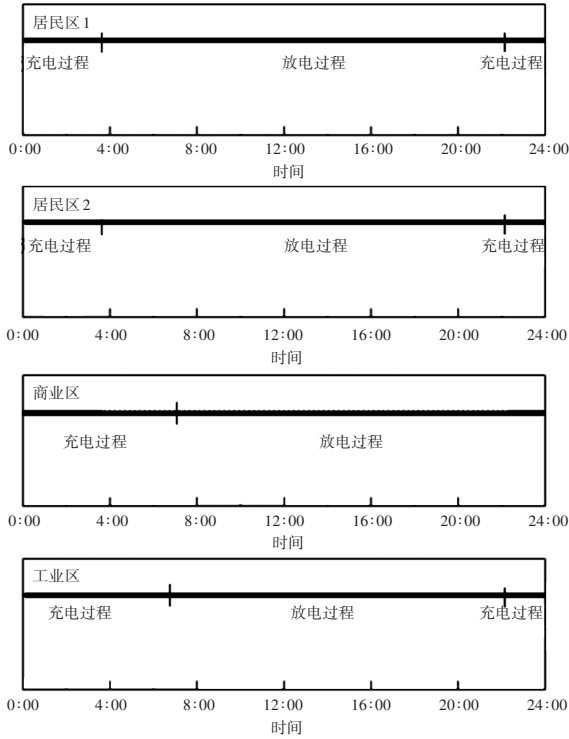


图2 最优充放电决策




图3 最优充放电负荷曲线

4.4 预测效果验证

相同测试条件下,利用基于出行起讫点(Origin-Destination, OD)矩阵的方法^[2]、基于网格划分的方法^[3]、基于集成学习的方法^[4]对同一日的充放电负荷进行

空分布预测,绘制负荷时空分布曲线,最后计算与实际负荷时空分布曲线间的决定系数,以评估预测模型拟合实际负荷的优度。决定系数为预测负荷与实际负荷相关系数的平方,取值范围为0~1,系数越大,预测结果越接近实际结果,证明预测结果越准确,结果如表3所示。

表2 最优充放电时段

功能区	类别	最优时段
居民区1	充电	22:30~次日3:40
	放电	3:40~22:30
居民区2	充电	22:30~次日3:40
	放电	3:40~22:30
商业区	充电	00:00~5:00
	放电	5:00~24:00
工业区	充电	21:50~次日5:00
	放电	5:00~21:50




图4 充电负荷预测结果




图5 放电负荷预测结果

从表3中可以看出,应用本文提出的方法,决定系数大于3种对比方法,表明所提出的方法预测结果更接近实际负荷,预测准确性更高。

表3 决定系数对比

方法	类别	决定系数			
		居民区1	居民区2	商业区	工业区
文献[2]	放电	0.825 6	0.824 8	0.823 6	0.874 5
	充电	0.869 2	0.796 6	0.722 3	0.892 3
文献[3]	放电	0.821 4	0.874 2	0.824 7	0.852 4
	充电	0.836 9	0.862 5	0.863 3	0.824 4
文献[4]	放电	0.785 5	0.796 9	0.824 5	0.805 2
	充电	0.825 1	0.822 2	0.802 5	0.845 2
文中方法	放电	0.952 3	0.923 6	0.936 6	0.933 2
	充电	0.921 4	0.954 7	0.925 8	0.948 2

5 结束语

为保证电力供需平衡,并为电网调度规划提供信息和依据,本文研究了基于供需两侧协同优化的电动汽车V2G充放电负荷时空分布预测方法。通过求取供需两侧协同优化方案,得到最优充电和放电时段,并分别进行负荷预测。验证结果表明,所提出方法的决定系数较对比方法大,证明了该方法的准确性。

参 考 文 献

- [1] 邓艺璇,黄玉萍,黄周春. 基于随机森林算法的电动汽车充放电容量预测[J]. 电力系统自动化, 2021, 45(21): 181-188.
DENG Y X, HUANG Y P, HUANG Z C. Charging and Discharging Capacity Forecasting of Electric Vehicles Based on Random Forest Algorithm[J]. Automation of Electric Power, 2021, 45(21): 181-188.
- [2] 张琳娟,许长清,王利利,等. 基于OD矩阵的电动汽车充电负荷时空分布预测[J]. 电力系统保护与控制, 2021, 49(20): 82-91.
ZHANG L J, XU C Q, WANG L L, et al. OD Matrix Based Spatiotemporal Distribution of EV Charging Load Prediction [J]. Power System Protection and Control, 2021, 49(20): 82-91.
- [3] 袁小溪,潘鸣宇,段大鹏,等. 基于网格划分的电动汽车充电负荷预测方法[J]. 电力科学与技术学报, 2021, 36(3): 19-26.
YUAN X X, PAN M Y, DUAN D P, et al. Prediction Method of Electric Vehicle Charging Load Based on Grid Division[J]. Journal of Electric Power Science and Technology, 2021, 36(3): 19-26.
- [4] 李恒杰,朱江皓,傅晓飞,等. 基于集成学习的电动汽车充电站超短期负荷预测[J]. 上海交通大学学报, 2022, 56(8): 1004-1013.
LI H J, ZHU J H, FU X F, et al. Ultra-Short-Term Load

- Forecasting of Electric Vehicle Charging Stations Based on Ensemble Learning[J]. Journal of Shanghai Jiaotong University, 2022, 56(8): 1004-1013.
- [5] DABBAGHJAMANESH M, MOEINI A, KAVOUSHI-FARD A. Reinforcement Learning-Based Load Forecasting of Electric Vehicle Charging Station Using Q-Learning Technique[J]. IEEE Transactions on Industrial Informatics, 2020, 17(6): 4229-4237.
- [6] FENG J W, YANG J Y, LI Y L, et al. Load Forecasting of Electric Vehicle Charging Station Based on Grey Theory and Neural Network[J]. Energy Reports, 2021, 7: 487-492.
- [7] 石立国,李延真,刘继彦,等. 电动汽车充电站超短期充电负荷预测的改进GRU方法[J]. 供用电, 2023, 40(6): 42-47.
SHI L G, LI Y Z, LIU J Y, et al. Improved GRU Method for Ultra-Short-Term Charging Load Forecasting at Electric Vehicle Charging Stations[J]. Distribution & Utilization, 2023, 40(6): 42-47.
- [8] 郑远硕,李峰,董九玲,等. “车-路-网”模式下电动汽车充放电时空灵活性优化调度策略[J]. 电力系统自动化, 2022, 46(12): 88-97.
ZHENG Y S, LI F, DONG J L, et al. Optimal Dispatch Strategy of Spatio-Temporal Flexibility for Electric Vehicle Charging and Discharging in Vehicle-Road-Grid Mode[J]. Automation of Electric Power, 2022, 46(12): 88-97.
- [9] 秦建华,潘崇超,张璇,等. 基于充电行为分析的电动汽车充电负荷预测[J]. 电测与仪表, 2023, 60(4): 19-26.
QIN J H, PAN C C, ZHANG X, et al. Charging Load Forecast of Electric Vehicle Based on Analysis of Charging Behavior[J]. Electrical Measurement & Instrumentation, 2023, 60(4): 19-26.
- [10] 王晓东,张一龙,刘颖明,等. 基于双时间尺度净负荷预测的储能调峰控制策略[J]. 太阳能学报, 2021, 42(7): 58-64.
WANG X D, ZHANG Y L, LIU Y M, et al. Double Time Scale Power Prediction Based Peaking Shaving Control Strategy of Energy Storage System[J]. Acta Energetica Sinica, 2021, 42(7): 58-64.
- [11] 邓慧琼,张晓飞,曾凡滢,等. 动态分时电价机制下的电动汽车充放电调度策略研究[J]. 智慧电力, 2023, 51(3): 59-66+78.
DENG H Q, ZHANG X F, ZENG F G, et al. Electric Vehicle Charging and Discharging Scheduling Strategy Under Dynamic Time-of-Use Electricity Price Mechanism [J]. Smart Power, 2023, 51(3): 59-66+78.
- [12] 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 Y J, YU A Q, DING L Q. 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.
- [13] 冯斌, 郭亦宗, 陈页, 等. 基于GRU多步预测技术的云储能充放电策略[J]. 电力系统自动化, 2021, 45(9): 46-54.
FENG B, GUO Y Z, CHEN Y, et al. Charging and Discharging Strategy of Cloud Energy Storage Based on GRU Multi-Step Prediction Technology[J]. Automation of Electric Power Systems, 2021, 45(9): 46-54.
- [14] 胡道栋, 邱俊宏, 王玉芳, 等. 综合能源充电站有序充电策略的研究与设计[J]. 电测与仪表, 2023, 60(2): 25-31.
HU D D, QIU J H, WANG Y F. Research and Design of Orderly Charging Strategy for Integrated Energy Charging Station[J]. Electrical Measurement & Instrumentation, 2023, 60(2): 25-31.
- [15] 郭振洲, 郝亚茹, 拱长青. 基于社交学习理论的鲸鱼优化算法[J]. 计算机仿真, 2021, 38(6): 219-225.
GUO Z Z, HAO Y R, GONG C Q. Social Learning Whale Optimization Algorithm[J]. Computer Simulation, 2021, 38(6): 219-225.
- [16] 刘志强, 张谦, 朱熠, 等. 计及车-路-站-网融合的电动汽车充电负荷时空分布预测[J]. 电力系统自动化, 2022, 46(12): 36-45.
LIU Z Q, ZHANG Q, ZHU Y, et al. Spatial-Temporal Distribution Prediction of Charging Loads for Electric Vehicles Considering Vehicle-Road-Station-Grid Integration[J]. Automation of Electric Power Systems, 2022, 46(12): 36-45.
- [17] 张美霞, 吴子敬, 杨秀. 基于动态能耗模型与用户心理的电动汽车充电负荷预测[J]. 现代电力, 2022, 39(6): 710-719.
ZHANG M X, WU Z J, YANG X. Electric Vehicle Charging Load Prediction Based on Dynamic Energy Consumption Model and User Psychology[J]. Modern Electric Power, 2022, 39(6): 710-719.
- [18] 刘敦楠, 张悦, 彭晓峰, 等. 计及相似日与气象因素的电动汽车充电负荷聚类预测[J]. 电力建设, 2021, 42(2): 43-49.
LIU D N, ZHANG Y, PENG X F, et al. Clustering Prediction of Electric Vehicle Charging Load Considering Similar Days and Meteorological Factors[J]. Electric Power Construction, 2021, 42(2): 43-49.
- [19] 胡博, 张鹏飞, 黄恩泽, 等. 基于图WaveNet的电动汽车充电负荷预测[J]. 电力系统自动化, 2022, 46(16): 207-213.
HU B, ZHANG P F, HUANG E Z, et al. Graph WaveNet Based Charging Load Forecasting of Electric Vehicle[J]. Automation of Electric Power Systems, 2022, 46(16): 207-213.
- [20] 范磊, 陈良亮, 罗雯茜, 等. 考虑城市不同功能区的电动汽车负荷时空分布建模方法[J]. 电力建设, 2021, 42(6): 67-75.
FAN L, CHEN L L, LUO W Q, et al. Spatial and Temporal Distribution Model of Electric Vehicle Load Considering Different Urban Functional Areas[J]. Electric Power Construction, 2021, 42(6): 67-75.
- [21] 华远鹏, 王圆圆, 韩丁, 等. 考虑有序充电的居民区电动汽车中长期充电负荷预测[J]. 电力系统及其自动化学报, 2022, 34(6): 142-150.
HUA Y P, WANG Y Y, HAN D, et al. Mid-and Long-Term Charging Load Forecasting for Electric Vehicles in Residential Areas Considering Orderly Charging[J]. Proceedings of the CSU-EPSA, 2022, 34(6): 142-150.
- [22] 卢姬, 常俊晓, 刘瑞, 等. 考虑电动汽车集群的互联电网负荷频率分散预测控制[J]. 电测与仪表, 2021, 58(9): 96-102.
LU J, CHANG J X, LIU R, et al. Decentralized Predictive Control of Load Frequency for Interconnected Power Grid Considering Electric Vehicle Clusters[J]. Electrical Measurement and Instrumentation, 2021, 58(9): 96-102.
- [23] 彭维湘. 时间序列中DF单位根检验存在的问题及方法改进[J]. 统计与决策, 2022, 38(21): 53-56.
PENG W X. Problems and Method Improvement of DF Unit Root Test in Time Series[J]. Statistics and Decision, 2022, 38(21): 53-56.

(责任编辑 斛 畔)

修改稿收到日期为2023年11月7日。