

DOI: 10.19783/j.cnki.pspc.241061

# 基于改进贝叶斯最大熵的乡村旅游电动汽车 多时间尺度充电负荷预测

顾睿<sup>1</sup>, 于艾清<sup>1</sup>, 潘含芝<sup>2</sup>, 杨斐翔<sup>1</sup>, 王育飞<sup>1</sup>, 薛花<sup>1</sup>

(1. 上海电力大学电气工程学院, 上海 200090; 2. 华东电力设计院有限公司, 上海 200063)

**摘要:** 当前乡镇电动汽车(electric vehicle, EV)充电负荷样本集的获取受限于充电网络覆盖率低, 给乡村旅游 EV 充电负荷预测带来极大挑战。且目前研究大多局限于短期预测范畴, 鲜有涉及对多时间尺度的深入探讨。基于此, 提出一种基于改进贝叶斯最大熵(Bayesian maximum entropy, BME)的乡村旅游 EV 多时间尺度充电负荷预测模型。首先, 考虑 EV 的出行特性受温度与交通因素的影响建立 EV 单位能耗模型, 在此基础上建立基于改进 BME 的乡村旅游 EV 短期负荷预测模型。其次, 结合最优灰色模型与旅游客流量预测模型预测未来乡村旅游 EV 保有量, 从而推演出乡村旅游 EV 中长期负荷预测结果。最后, 基于江苏省某乡村旅游景区温度与行车数据进行仿真分析, 验证所提方法的有效性并预测乡村旅游 EV 充电负荷的未来发展趋势。

**关键词:** 电动汽车; 多时间尺度负荷预测; 贝叶斯最大熵; 季节性特征

## Multi-timescale charging load forecasting for rural tourism electric vehicles based on improved Bayesian maximum entropy

GU Rui<sup>1</sup>, YU Aiqing<sup>1</sup>, PAN Hanzhi<sup>2</sup>, YANG Feixiang<sup>1</sup>, WANG Yufei<sup>1</sup>, XUE Hua<sup>1</sup>

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. East China Electric Power Design Institute Co., Ltd., Shanghai 200063, China)

**Abstract:** The limited availability of electric vehicle (EV) charging load data in rural areas, due to low charging network coverage, poses a significant challenge for forecasting EV charging loads in rural tourism settings. Furthermore, existing studies mainly focus on short-term forecasting, with limited exploration of multi-timescale predictions. To address these issues, an enhanced multi-timescale charging load forecasting model for rural tourism EVs is proposed based on an improved Bayesian maximum entropy (BME) framework. First, an EV unit energy consumption model is established considering temperature and traffic impacts on EV travel behavior. Based on this, a short-term load forecasting model using the improved BME is developed. Next, by integrating an optimal grey model with tourist flow prediction, future stock of rural tourism EVs is forecasted, thereby deriving medium- and long-term charging load forecasts. Finally, simulation analysis using temperature and traffic data from a rural tourism area in Jiangsu Province is conducted to validate the effectiveness of the proposed method and predict the future development trend of rural tourism EV charging loads.

This work is supported by the Natural Science Foundation of Shanghai (No. 23ZR1425000).

**Key words:** electric vehicles; multi-timescale load forecasting; Bayesian maximum entropy; seasonal characteristics

## 0 引言

近年来, 我国电动汽车(electric vehicle, EV)产业蓬勃发展, 2023年末其保有量迅速增加至2041万

辆<sup>[1-2]</sup>。但 EV 的发展主要集中在发达城市, 乡镇地区因充电设施滞后、供需矛盾等问题<sup>[3]</sup>, EV 普及度相对较低。随着乡村旅游业的兴起, 乡镇充电设施建设迎来了新的机遇。鉴于乡村旅游 EV 负荷是乡镇 EV 充电负荷的重要组成部分, 且其数据特性复杂<sup>[4]</sup>, 充电需求的预测显得尤为重要。因此, 深入研究并精准预测乡村旅游 EV 充电负荷需求, 对于合理规

**基金项目:** 上海市自然科学基金项目资助(23ZR1425000);  
上海市科技创新行动计划项目资助(22010501400)

划乡镇充电设施及配电网设备以促进乡镇电动汽车产业的健康发展具有至关重要的意义。

当前电动汽车充电负荷预测方法主要集中在利用统计模型、优化算法、人工智能技术等多种手段,并不断探索新的预测模型和策略,以提高预测精度和效率。文献[5]基于蒙特卡洛负荷预测模型,对不同类型的EV根据其充电时间、初始电量等因素进行建模,进而得到负荷时空分布。文献[6]针对基于活动的模型依赖于描述所考虑区域内交通流量的数据,提出了一种克服空间限制且不需要交通流数据作为输入参数的基于活动的模型的新方法。文献[7]提出了一种基于改进麻雀搜索算法-卷积神经网络-门控循环神经网络模型的方法,实现了对电动汽车充电短期需求预测。文献[8]基于历史充电负荷数据,提出一种基于动态自适应图神经网络的电动汽车充电负荷预测算法。上述研究方法在运用过程中均对丰富的历史数据提出了较高要求,但当前乡镇EV充电负荷的数据样本呈现出显著的稀缺性,增加了预测结果偏离实际状况的风险,导致误差范围的扩大。文献[9]提出了一种基于贝叶斯最大熵(Bayesian maximum entropy, BME)的负荷预测方法,并通过实例分析验证了该方法在修正预测结果方面的有效性。然而,该方法在构建预测模型时,所考虑的待估量的样本信息来源相对单一,未能充分纳入温度与交通、客流量等关键变量对EV充电负荷的影响。且上述文献预测负荷的时间尺度较为单一,无法全面地反映和预测EV的长时间尺度下充电负荷特性来为未来EV充电设施的建设提供参考。

鉴于EV市场受多重复杂因素驱动,预测EV保有量的传统方法面临挑战。灰色预测模型(grey model, GM)因能处理小样本数据的不确定性问题而备受关注。然而,其全局搜索能力受限,易陷入局部最优,文献[10]通过萤火虫算法优化灰色模型,借助其随机性和全局搜索能力提升了预测精度。此外,乡村旅游客流量具有显著的非线性和季节性特征,传统的预测模型难以全面捕捉这些复杂变化。支持向量回归机(support vector regression, SVR)虽适合此类任务,但参数选择至关重要。粒子群优化(particle swarm optimization, PSO)算法能够在复杂搜索空间中高效寻找最优参数,然而,仅仅依赖PSO算法优化的SVR模型可能仍难以充分应对乡村旅游客流量的季节性波动。文献[11]采用季节性指数调整(seasonal exponential adjustment, SEA)方法,对原始数据进行预处理,以消除季节性因素的影响。

鉴于此,本文旨在构建一种基于改进BME的乡镇级电动汽车中长期充电负荷预测模型。针对乡

村旅游EV,首先建立车载空调耗电量与电池容量随温度变化的关联性模型,并构建考虑交通因素影响的EV能耗模型。随后,以改进BME理论为基础纳入季节性等因素的影响,构建短期乡村旅游EV充电负荷预测模型。接着,利用最优灰色模型对未来不同年份的电动汽车保有量进行预测,并采用季节性调整的粒子群优化支持向量机模型(seasonal exponential adjustment-support vector regression-particle swarm optimization, SEA-SVR-PSO)对乡村旅游客流量进行预测,进而推出乡村旅游EV的保有量。通过整合这些预测结果,实现多时间尺度的EV充电负荷预测。最后,通过算例仿真验证基于改进BME的乡村旅游EV充电负荷预测模型的有效性,并预测未来中长期EV充电需求负荷。

### 1 乡村旅游EV多时间尺度负荷预测架构

本文提出的电动汽车多时间尺度负荷预测方法主要由EV单位能耗模型、乡村旅游EV短期负荷预测模型、乡村旅游EV保有量3个部分组成,如图1所示。

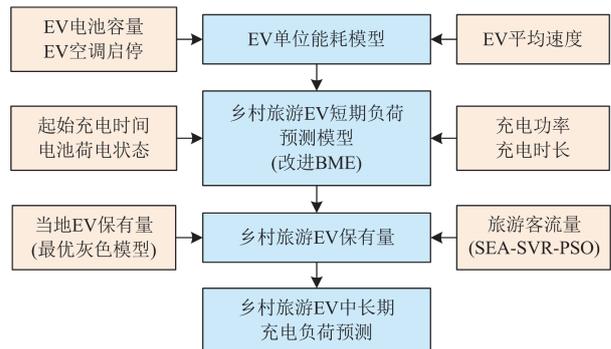


图1 乡村旅游EV中长期负荷预测架构

Fig. 1 Framework for medium-and long-term load forecasting of electric vehicles in rural tourism

1) 通过考虑温度对EV电池容量衰减、车载空调启停状态的影响,以及交通状况对EV平均速度的作用,构建EV能耗模型,以此作为负荷预测的基础。

2) 结合乡村旅游出行特征,考虑季节性等因素,通过EV起始充电时间、电池荷电状态、充电功率以及充电时长以改进BME为基础构建乡村旅游EV短期负荷预测模型。

3) 利用最优灰色模型实现当地未来EV保有量预测,并通过SEA-SVR-PSO方法构建旅游客流量预测模型,结合其关联性得到旅游EV的保有量,最终推演出乡村旅游EV中长期负荷需求。

## 2 基于 BME 的乡村旅游 EV 短期负荷预测

### 2.1 EV 单位能耗模型

EV 用户乡村旅游出行车辆的充电负荷会受到温度和交通因素的影响<sup>[12-13]</sup>, 考虑到用户的能动性, 旅游一般会选择晴朗舒适的天气出行, 因此本文默认天气为晴天。温度与交通因素对电动汽车的充电需求影响如图 2 所示。

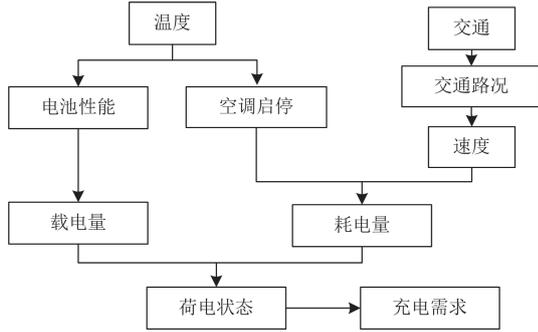


图 2 温度与交通因素对充电需求的影响

Fig. 2 Impact of temperature and traffic factors on charging demand

#### 2.1.1 温度因素对 EV 能耗的影响

EV 的电池性能受环境温度影响, 其相对容量会随着环境温度的下降而非线性衰减<sup>[14-15]</sup>。本文以磷酸铁锂电池为例, 设定 25 °C 为基准温度, 此时电池相对容量为 100%。

从图 3 中可以观察到在高温区间内(大于 30 °C), 电池的实际最大载电量呈现出一种相对稳定的态势。而在低温条件下, 电池的最大载电量随着环境温度的持续下降会出现明显的缩减现象。特别是在 -20 °C~20 °C 的温度区间内, 电池容量的衰减率随着温度的降低而急剧上升。

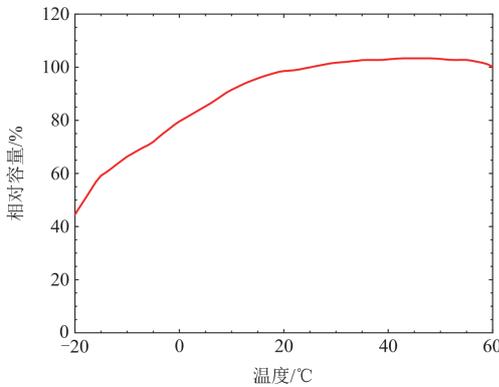


图 3 电池相对容量变化曲线

Fig. 3 Relative capacity change curve of battery

另外环境温度变化会影响空调的启停。参考文献[16]对不同温度  $T$  下的空调使用率进行调研, 将相关数据拟合得到空调启动概率正态分布函数为

$$f_i(T) = \frac{1}{\sqrt{2\pi}\delta_T T} e^{-\frac{(T-u_T)^2}{2\delta_T^2}} \quad (1)$$

式中:  $u_T$  和  $\delta_T$  分别为正态分布的均值和标准差, 制热启动  $u_T = 10.85$ ,  $\delta_T = 2.14$ ; 制冷启动  $u_T = 29.4$ ,  $\delta_T = 1.75$ 。

为了获得温度影响下的单位耗电量, 本文参考文献[16]的单位耗电量计算模型, 如式(2)所示。

$$K_T = \begin{cases} W_L \frac{S}{v_T} & T > T_{p \max} \\ W_R \frac{S}{v_T} & T > T_{p \min} \end{cases} \quad (2)$$

式中:  $K_T$  为环境温度为  $T$  时空调启动的耗电量;  $W_L$  和  $W_R$  分别为 EV 空调的制冷和制热功率, 对应的值分别为 1.2 kW 和 1.5 kW;  $v_T$  为 EV 实际行驶速度;  $S$  为 EV 行驶里程;  $T_{p \max}$  和  $T_{p \min}$  分别为空调制热温度上限和制冷温度下限。

#### 2.1.2 交通因素对 EV 能耗的影响

道路等级的差异会直接影响 EV 行驶速度, 从而影响 EV 的电能消耗量, 本文仅以平均速度作为参考。道路类型可分为 4 个等级: 一级、二级、三级、四级<sup>[17]</sup>。EV 在各级道路上行驶的概率及平均速度见表 1。

表 1 各级道路上行驶的概率和平均速度

Table 1 Probability and average speed of travel on roads at various levels

| 道路等级        | 一级   | 二级    | 三级    | 四级    |
|-------------|------|-------|-------|-------|
| 概率/%        | 7.14 | 14.29 | 21.43 | 57.14 |
| 平均速度/(km/h) | 80   | 60    | 40    | 30    |

不同道路等级下, EV 的单位里程能耗也不同, 可根据文献[18]中 EV 能耗因子模型求出单位里程耗电量  $E$ , 如式(3)所示。

$$E = \begin{cases} 0.247 + \frac{1.52}{v_T} - 0.004v_T + 2.992 \times 10^{-5}v_T & k = 1 \\ -0.179 + 0.004 \times v_T + \frac{5.492}{v_T} & k = 2 \\ 0.21 - 0.001 \times v_T + \frac{1.534}{v_T} & k = 3 \\ 0.208 - 0.002 \times v_T + \frac{1.553}{v_T} & k = 4 \end{cases} \quad (3)$$

式中： $E$ 为电动汽车在道路等级为 $k$ 级行驶时的单位里程耗电量； $k$ 为道路等级。

### 2.2 乡村旅游 EV 用户出行特征

目前中国乡村旅游的客流量整体呈现上升趋势，对于乡村旅游的客流动态，研究发现游客的出行高峰主要集中在上午 08:00—10:00，且这一出行模式呈现出正态分布特征<sup>[19]</sup>，其概率密度函数为

$$f_s(T) = \frac{1}{\sqrt{2\pi}\sigma_s} e^{-\frac{(T-\mu_s)^2}{2\sigma_s^2}} \quad (4)$$

式中： $\mu_s$ 为起始出行时刻均值， $\mu_s = 8.56$ ； $\sigma_s$ 为初始出行时刻方差， $\sigma_s = 1.57$ 。

在时间和路线允许的情况下，多数游客倾向于在一次出行中访问多个旅游景点。基于此背景，本研究所述的出行链定义为：在特定的时间节点，游客从其住所驾驶电动汽车出发，依据一定的时间顺序，完成对一个或多个乡村旅游景点的访问，最终返回住所的完整出行过程。该乡村旅游的出行链如图 4 所示。

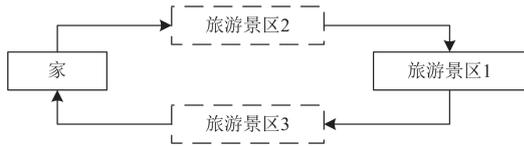


图 4 乡村旅游出行链示意图

Fig. 4 Schematic diagram of rural tourism travel chain

### 2.3 起始充电时间与电池荷电状态

由于车主充电行为具有较强的灵活性和主观性<sup>[20-21]</sup>，多数车主倾向于选择灵活充电模式，以确保行驶途中电量充裕。因此，游客到达目的地的时间即为电动汽车起始充电时间。鉴于乡村旅游出行时间与城市中常规的上下班时间存在差异，其起始充电时间的概率密度函数也相应有所不同<sup>[16]</sup>，如式(5)所示。

$$f_a(t') = \begin{cases} \frac{1}{\sigma_a \sqrt{2\pi}} e^{-\frac{(t'+24-u_a)^2}{2\sigma_a^2}} & 0 < t' \leq u_a - 12 \\ \frac{1}{\sigma_a \sqrt{2\pi}} e^{-\frac{(t'-u_a)^2}{2\sigma_a^2}} & u_a - 12 < t' \leq 24 \end{cases} \quad (5)$$

式中： $t'$ 为到达目的地的时刻； $u_a$ 和 $\sigma_a$ 为拟合参数。乡村旅游具有季节性特征，而各季节的拟合参数随季节的变化而不同，如表 2 所示。

表 2 各季节拟合参数

Table 2 Fitting parameters for each season

| 参数           | 春季    | 夏季    | 秋季    | 冬季    |
|--------------|-------|-------|-------|-------|
| $u_a/h$      | 13.60 | 12.97 | 13.38 | 14.00 |
| $\sigma_a/h$ | 3.60  | 3.59  | 3.62  | 3.61  |

在电动汽车乡村旅游中，电池荷电状态(state of charge, SOC)受多种因素的影响，包括温度、交通情况以及行驶里程等<sup>[22]</sup>。通过 2.1 节温度与交通因素对电动汽车能耗影响的分析，可得到受环境温度 $T$ 影响时，电动汽车开始充电时刻的 SOC 为

$$S_1 = \frac{C_T - K_T - ES}{C_T} \times 100\% \quad (6)$$

式中： $S_1$ 为电动汽车充电开始时的电池电量； $C_T$ 为温度为 $T$ 时电池的相对容量。

### 2.4 充电功率与充电时长

在考量乡村旅游活动的时间安排时，车主们通常更倾向于选择能快速完成充电、减少停留时间的快速充电方式。因此，本文假设所有充电桩均为快速充电桩。旅客到达目的地后，会持续为电动汽车充电直至达到理想电量。结合电池容量大小可得到

$$T_{ch} = \frac{(S_2 - S_1)C_T}{\eta P_{ch}} \quad (7)$$

式中： $T_{ch}$ 为电动汽车充电时长； $S_2$ 为电动汽车充电结束时的理想电池电量，本文取电池容量的 90%； $\eta$ 为充电效率，本文取 0.9； $P_{ch}$ 为充电功率。

### 2.5 基于改进 BME 的 EV 负荷预测

在乡村旅游 EV 负荷预测中，选用 BME 模型主要归因于其在处理小样本数据、融合多元信息源以及应对不确定性因素方面的优势。然而，乡村旅游 EV 负荷的变化受到多种复杂因素的综合影响，BME 模型在实际应用中仍面临难以全面适应动态变化环境的挑战。为提升预测准确性、增强模型的稳定性与适应性，必须对 BME 模型进行针对性的改进与优化。

#### 2.5.1 BME 方法

BME 方法是现代时空地统计学的重要组成部分。该方法采用统计学中的贝叶斯理论和信息论中熵的概念来认识和处理时空变量，将所研究时空要素的软数据和硬数据系统地综合到对该要素的空间估计和分析制图过程中<sup>[23]</sup>。BME 理论框架如图 5 所示。

BME 方法在乡村旅游电动汽车充电负荷预测中的流程分为 3 个阶段<sup>[24]</sup>。

1) 先验阶段。收集历史乡村旅游景点的充电负荷数据以及与之相关的各种特征数据，如温度、充电功率、充电时长、SOC 等，利用收集到的数据通过最大熵原理建立先验分布。

$$f_G(Z) = \frac{1}{A} e^{\sum_{\alpha=1}^{N_G} \mu_{\alpha} g_{\alpha} Z} \quad (8)$$

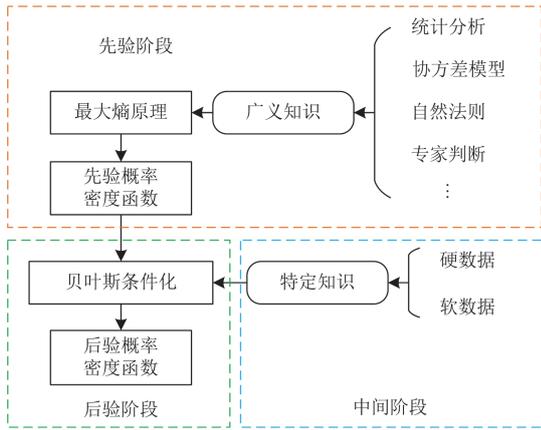


图 5 BME 理论框架

Fig. 5 Theoretical framework of BME

$$A = \int e^{\sum_{\alpha=1}^{N_c} \mu_{\alpha} g_{\alpha} Z} dZ \quad (9)$$

$$Z = (Z_y, Z_r, Z_g) \quad (10)$$

式中： $f_G(Z)$  为先验概率密度函数； $A$  为归一化约束； $\alpha$  为约束条件的编号； $N_c$  为约束条件总数； $\mu_{\alpha}$  为拉格朗日乘数； $g_{\alpha}$  为  $Z$  的已知函数； $Z_y$ 、 $Z_r$ 、 $Z_g$  分别为硬数据点、软数据点、估计点。

2) 中间阶段。持续收集新的乡村旅游景点的充电负荷数据以及相关特征数据，利用新数据和贝叶斯方法更新先验分布，得到后验分布。

$$f_k(Z_g) = f_G(Z_g | Z_y, Z_r) = \frac{\int_{\phi}^u f_G(Z_g, Z_y, Z_r) dZ_r}{\int_{\phi}^u f_G(Z_y, Z_r) dZ_r} \quad (11)$$

式中： $f_k(Z_g)$  为后验概率密度函数； $f_G(Z_g | Z_y, Z_r)$  为已知  $Z_y$ 、 $Z_r$  时  $Z_g$  的先验概率密度函数； $\phi$  和  $u$  分别为置信区间的上、下界。

3) 后验阶段。利用更新后的后验分布，结合未来的乡村旅游景点的特征数据，进行充电负荷的预测，预测均值  $\hat{f}_{BME}(Z_g)$ ，如式(12)所示。

$$\hat{f}_{BME}(Z_g) = \int Z_g f_k(Z_g) dZ_g \quad (12)$$

### 2.5.2 改进 BME

#### 1) 硬数据优化

考虑到乡村旅游电动汽车充电负荷受季节性、节假日等因素影响，利用自回归移动平均模型 (autoregressive integrated moving average model, ARIMA) 对历史数据建模，根据时间序列数据的散点图、自相关函数和偏自相关函数图识别序列的平稳性，对非平稳序列进行差分处理，使其变为平稳序列，提取周期性和趋势性特征，并将其作为新的

输入特征与原始数据引入 BME 模型，实现 BME 硬数据的优化，使 BME 在预测时能够更全面地考虑影响目标变量的各种因素，进而提高预测的准确性和可靠性。

#### 2) 贝叶斯优化

贝叶斯优化的核心理念在于，基于已知的先验分布及数据，通过不断更新后验分布来探寻最优解。为实现这一目标，采用高斯过程回归来构建采样函数，其预测公式为

$$\mu(a^*) = c^{*T} (C + \sigma_n^2 I)^{-1} b \quad (13)$$

$$c_{ov}(a^*) = c - c^{*T} (C + \sigma_n^2 I)^{-1} c^* \quad (14)$$

式中： $a^*$  表示目标函数预测值对应的输入点； $\mu(a^*)$  表示函数在  $a^*$  处的均值； $c_{ov}(a^*)$  表示函数在  $a^*$  处的协方差； $c$  为测试点自身的协方差； $c^*$  为测试点与训练数据点的协方差向量； $C$  为训练数据点之间的协方差矩阵； $\sigma_n^2$  为高斯噪声的方差； $I$  为单位矩阵； $b$  为训练数据点的目标值向量。

借助这一回归模型预测当前最可能的函数值，并计算每个采样点的概率密度函数。随后依据这一概率密度函数进行采样，从而获得一个新的点，作为下一次优化过程的输入。采样函数为

$$a_{t+1} = \arg \max E_1(a), a \in A' \quad (15)$$

$$E_1(a) = \int_{-\infty}^{q_{\min}} (q(a) - q_{\min}) p(q|D) dq \quad (16)$$

式中： $a$  为采样点； $a_{t+1}$  表示下一个新的采样点； $A'$  为搜索空间； $E_1(a)$  为期望提升函数； $q_{\min}$  为当前最优解的取值； $p(q|D)$  表示在已知数据  $D$  的情况下函数  $q$  的概率分布。

## 3 乡村旅游 EV 中长期负荷预测

在构建中长期负荷预测模型的过程中，为了准确预估负荷变化，需要精确量化不同年份的旅游 EV 保有量规模。鉴于旅游 EV 保有量与乡村旅游客流量以及当地 EV 保有量之间存在显著的关联性，首先需要构建预测框架以预测未来乡村旅游客流量以及当地 EV 保有量，用于进一步推算旅游 EV 保有量的规模，从而精确构建中长期负荷预测模型。

### 3.1 基于 SEA-SVR-PSO 模型旅游客流量预测

乡村旅游客流量数据呈现数据量小、节假日效应显著以及季节性波动明显等特征<sup>[11]</sup>，鉴于乡村旅游客流量随时间变化的特性与气候舒适度及公众闲暇时间之间存在着紧密而复杂的相互作用关系<sup>[4]</sup>，在进行客流量预测时，必须充分考虑这些关键变量，以提升预测的准确性和可靠性。

针对乡村旅游客流量的特征，本文构建了一个

结合 PSO 优化的 SVR 算法与季节性调整方法的乡村旅游客流量预测模型。SEA 通过对原始数据进行调整,使其更精确地反映实际数据的变化规律,从而显著提升了预测的准确性<sup>[25]</sup>,具体步骤如下。

首先,假设数据集共有  $m$  个周期,每个周期内有  $l$  个数值,并计算每个周期的均值,如式(17)所示。

$$\bar{X}_h = (X_{h1} + X_{h2} + \dots + X_{hl}) / l, h = 1, 2, \dots, m \quad (17)$$

式中:  $\bar{X}_h$  为均值;  $X_{hl}$  为每个周期内的值。

其次,将数据  $X_{hl}$  标准化,如式(18)所示。

$$I_{hl} = X_{hl} / \bar{X}_h, h = 1, 2, \dots, m; l = 1, 2, \dots, n \quad (18)$$

接着,计算季节指数  $I_j$ ,如式(19)所示。

$$I_j = (I_{1j} + I_{2j} + \dots + I_{mj}) / m, j = 1, 2, \dots, n \quad (19)$$

最后,利用季节指数对原始数据进行调整,得到新数据  $X'_{hl}$ ,如式(20)所示。

$$X'_{hl} = X_{hl} / I_j, h = 1, 2, \dots, m; j = 1, 2, \dots, n \quad (20)$$

此外,在进行乡村旅游 EV 中长期充电需求预测时,需要考虑到一个重要因素,即并非所有游客都选择驾驶 EV 前往目的地,因此不可将乡村旅游客流量直接等同于旅游 EV 保有量。在预测出旅游客流量的基础上,还需进一步确定旅游 EV 的保有量。旅游 EV 保有量所占市场的比例与旅游客流量所占总人口的比例存在一定的关联,如式(21)所示。

$$\frac{N_{LEV}}{S_{LP}} = \alpha' \frac{N_{EV}}{S_p} \quad (21)$$

式中:  $N_{LEV}$  为旅游 EV 保有量;  $N_{EV}$  为当地 EV 总保有量;  $S_{LP}$  为旅游客流量;  $S_p$  为当地总人口;  $\alpha'$  为比例系数,取值为 0.1。

由式(21)可知,在预测出乡村旅游客流量的基础上,预测出当地 EV 保有量即可得到乡村旅游 EV 保有量。

### 3.2 基于最优灰色模型的 EV 保有量预测

EV 行业目前发展势态迅猛,全国 EV 保有量不断攀升。然而,在预测 EV 保有量时,基础灰色模型存在若干局限性,包括模型精度可能受限、参数选择具有主观性、缺乏自适应机制以及对数据噪声较为敏感等问题<sup>[26-27]</sup>。

通过萤火虫算法(firefly algorithm, FA)来优化 GM 模型,可以在一定程度上改善基础模型的不足之处。其基本原理是通过模拟萤火虫在群体中相互吸引的行为,帮助搜索问题的最优解。算法的核心在于萤火虫的两个关键特性:吸引度和亮度。萤火虫之间的吸引度与它们的亮度成正比,亮度越高,吸引力越强。在搜索过程中,每个萤火虫会移动向那些比自己亮度更高的萤火虫的方向,以期望找到

更优的解。基于萤火虫算法的灰色模型流程如图 6 所示<sup>[10]</sup>。

萤火虫算法通过对空间矢量的考量,构建了适应度函数来优化灰色预测模型。它利用多次迭代搜索,旨在找到最优的发展系数,使预测模型达到最佳拟合效果,进而提高灰色模型预测结果的精度。

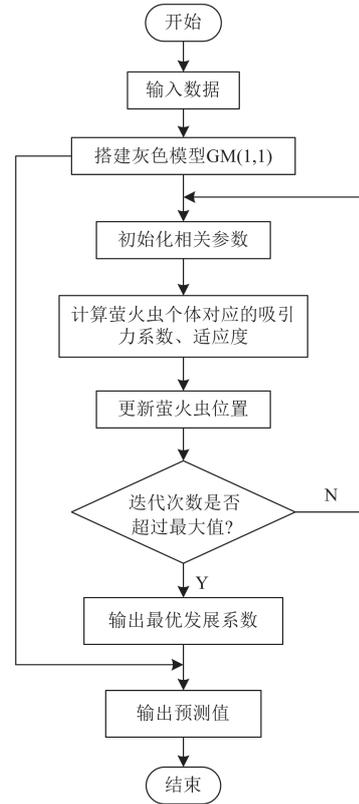


图 6 基于萤火虫算法的灰色模型流程

Fig. 6 Process of gray model based on firefly algorithm

### 3.3 乡村旅游 EV 中长期负荷预测流程

由改进 BME 方法完成短期负荷的预测,得到乡村景区的负荷曲线,再通过 SEA-SVR-PSO 模型、最优灰色模型分别预测 2024—2034 年的旅游客流量以及当地 EV 保有量,从而得到乡村旅游 EV 的保有量,更新旅游 EV 保有量可计算出未来不同年份的负荷曲线,预测流程图如图 7 所示。

以乡村景区旅游 EV 保有量数据为基础,用优化后的 BME 模型对旅游 EV 行为进行模拟。首先,设定 EV 用户以住所为出发点,抽取车辆  $i$  的出行时刻,考虑到用户旅游前倾向于将车辆充满电,设定 EV 出发时的电量为电池容量的 100%。然后,抽取旅游目的地,得到出发与目的地之间的路程,为了计算电动汽车电池荷电状态,需要确定电动汽车在温度  $T$  下的电池容量、行程的耗电量以及空调耗电

量。电动汽车*i*完成既定行程后, 计算其起始充电时间、充电时长以及充电功率, 得到各景区的充电负荷, 当模拟所有EV充电行为后, 可绘制出乡村景区总的日充电负荷曲线。最后, 由乡村旅游客流量预测与当地EV保有量预测推算出不同年份的旅游EV保有量, 从而更新该旅游景区不同年份的充电负荷曲线, 实现旅游EV中长期负荷预测。

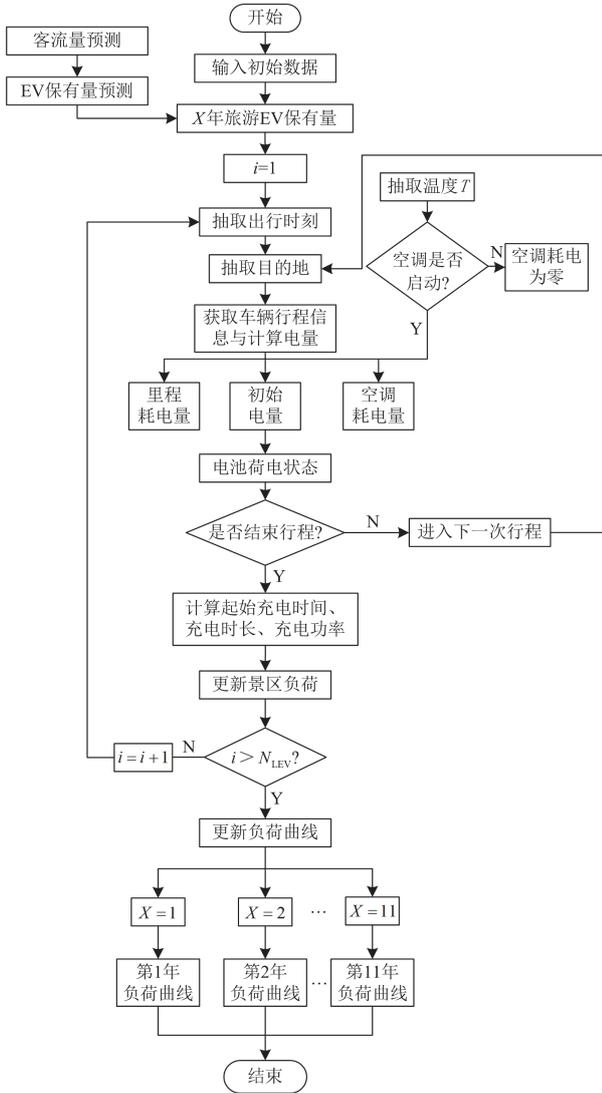


图7 乡村旅游EV中长期负荷预测流程

Fig. 7 Flow chart of medium-and long-term load forecasting for rural tourism EV

## 4 算例分析

### 4.1 参数设置

本文以江苏某乡镇的乡村景区为例进行仿真分析, 选取了其某年某月电动汽车历史充电数据作为样本。首先, 将常规预测方法与本文所提的改进BME方法进行预测对比; 其次, 基于改进BME方法预

测未来不同季节温度下的充电负荷; 最后, 结合乡村旅游的EV保有量预测未来多年的不同季节典型日充电负荷。电动汽车相关参数为: 续航里程为350 km, 理想电池容量为70 kWh, 快速充电功率为40 kW, 百公里耗电16 kWh。参考江苏省气象统计局统计的2023年全年温度, 春秋季节典型气温取20℃, 夏季和冬季典型气温分别取35℃和0℃。电池相对容量百分数分别为<sup>[22]</sup>:  $C_{20℃} = 98.8\%$ ,  $C_{35℃} = 103\%$ ,  $C_{0℃} = 79.3\%$ 。

### 4.2 结果分析

仿真结果分析主要包含乡村旅游EV短期负荷预测分析以及中长期负荷预测分析两个方面。

#### 4.2.1 乡村旅游EV短期负荷预测分析

选取江苏某乡村景区2024年某月两周电动汽车充电数据作为样本, 以这两周前十三日的充电负荷作为构建模型的基准数据集, 分别用蒙特卡洛(Monte Carlo, MC)方法、随机森林(random forest, RF)、BME以及改进BME对最后一日的充电负荷进行预测, 并将预测结果与实际值进行对比, 结果如图8所示。

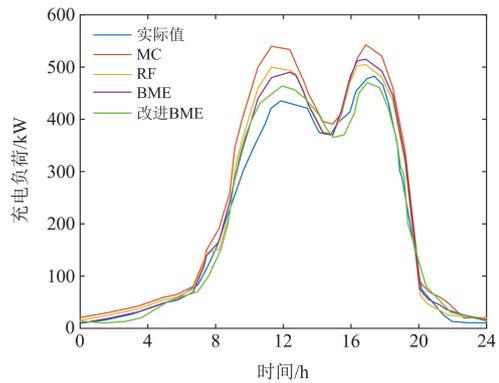


图8 不同方法预测结果对比

Fig. 8 Comparison of prediction results using different methods

从图8可以观察到各种负荷预测方法的预测值与实际值相比均存在一定程度的偏差。然而, 鉴于乡镇EV充电负荷样本的稀缺性, MC在某些时间点的预测值与实际值之间出现了较大的偏差。相比之下, RF与BME的预测结果偏移范围略有缩小, 可见其在乡村旅游情况下的EV负荷预测均有一定优势。而经改进后的BME方法的预测结果整体上与实际值轨迹高度吻合, 展现出了出色的预测精度。

为了进一步量化各种预测方法在误差指标上的具体差异以及本文所提方法的有效性, 引入最大误差率(maximum error rate, MER)、平均绝对误差(mean absolute error, MAE)和均方根误差(root mean

squared error, RMSE)作为评估指标, 结果如表 3 所示。

表 3 不同方法的误差对比

Table 3 Comparison of errors among different methods

| 预测方法   | MER   | MAE   | RMSE  |
|--------|-------|-------|-------|
| MC     | 28.17 | 39.30 | 55.08 |
| RF     | 18.45 | 25.38 | 35.73 |
| BME    | 13.70 | 24.74 | 32.61 |
| 改进 BME | 6.82  | 18.19 | 23.05 |

表 3 的数据直观地展示了不同模型的预测误差。从表中可以看出, 改进 BME 方法的 MER、MAE、RMSE 值都为最小, 预测精度最高。MC 误差最大主要受限于样本容量, BME 与 MC、RF 相比, 各个误差指标均有降低, 是因为其在处理小样本问题时具有更高的准确性。相较于 MC、RF、BME, 改进 BME 的 MER 分别减少了 75.79%、63.04%、50.22%, MAE 分别减少了 53.72%、28.33%、26.48%, RMSE 分别减少了 58.15%、35.49%、29.32%, 体现了本文对 BME 改进的有效性, 更直观地验证了其在乡村旅游 EV 负荷预测中的高度适用性与显著优势。

#### 4.2.2 乡村旅游 EV 中长期负荷预测分析

##### 1) 乡村旅游客流量预测分析

2020—2022 年间, 我国旅游业受疫情影响, 旅游客流量呈现异常波动特征, 相关数据在分析中被作为异常样本予以剔除, 因此选取此乡村景区 2015—2019、2023 年客流量数据作为样本, 预测 2025 年客流量。在 PSO 规模为 20、最大迭代次数设为 100、交叉验证采用 5 折时, SVR 中惩罚系数和宽度系数分别为 0.1 和 1.2299, 最终预测结果如图 9 所示。

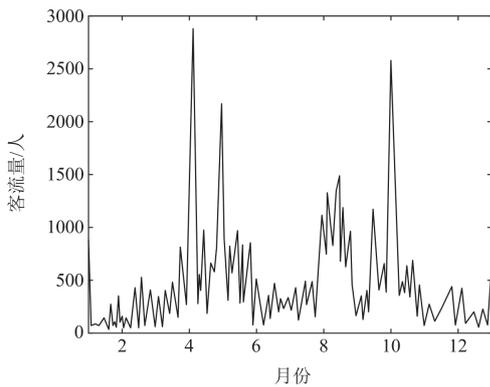


图 9 2025 年乡村旅游客流量预测值

Fig. 9 Forecast value of rural tourism visitor flow in 2025

图 9 中乡村旅游客流量呈现出 M 型波动特征, 揭示了节假日效应突出、季节性差异明显的特点。其中旅游峰值的时间点与国家法定节假日高度吻

合, 突显了节假日作为推动旅游出行高峰的关键因素。此外, 客流量在春秋两季呈现多峰值, 夏季则保持中等水平, 而冬季则明显陷入低谷。这表明季节性作为旅游活动的重要外部环境因素, 是分析旅游需求变化时不可或缺的考量维度。

##### 2) 乡村旅游 EV 保有量预测分析

在针对乡村旅游 EV 保有量进行预测时, 鉴于该乡村景区的主要游客群体多源自江苏省, 本研究特地选取江苏省 2019—2023 年的 EV 保有量数据作为核心分析依据。并通过运用最优灰色模型对 2024—2034 年的 EV 保有量进行预测。萤火虫算法相关参数设置为: 萤火虫的个体数量为 50, 最大迭代次数为 100 次, 最大吸引力系数为 1, 光吸收系数为 0.5。2024—2034 年当地 EV 保有量、乡村旅游客流量及乡村旅游 EV 保有量预测值如图 10 所示。

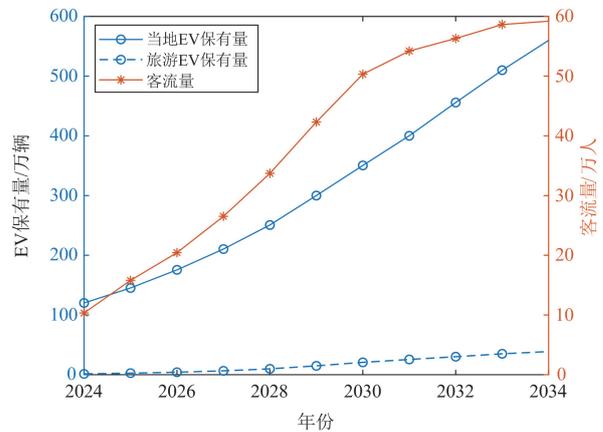


图 10 2024—2034 年当地 EV 保有量、旅游客流量及旅游 EV 保有量预测值

Fig. 10 Forecast of local EV ownership, tourist flow, and EV ownership for tourism from 2024 to 2034

由图 10 可知, 2024—2034 年江苏省 EV 保有量及当地旅游客流量均呈现出持续增长态势, 前期增长趋势近似呈指数级, 充分反映了我国电动汽车产业与乡村旅游业的蓬勃发展。这一增长态势与全面推进乡村振兴的发展战略及“双碳”目标紧密相连, 同时也彰显了国民生活水平的不断提升。然而, 在后期, 增长速度相较于前中期有所放缓, 这可能源于电动汽车市场的逐渐饱和以及乡村旅游业发展进入稳定阶段。在此背景下选择 EV 作为旅游出行方式的游客数量也在逐步上升。

##### 3) 中长期 EV 负荷预测分析

在旅游 EV 保有量预测的基础上, 对乡村旅游 EV 充电负荷进行中长期预测, 分析不同季节温度对 EV 充电需求负荷的影响, 以及 EV 保有量增长

对 EV 充电负荷的潜在作用。

图 11 展示了 2034 年该乡村景区在不同季节典型温度条件下的 EV 充电负荷曲线对比情况。观察发现, EV 充电需求在不同季节间存在显著差异。春秋季节与夏季、冬季之间的充电需求差异较大, 而夏季与冬季之间的充电需求差异则相对较小。进一步分析发现, 冬季的充电需求最大, 夏季次之, 而春秋季节的充电需求相对最小。

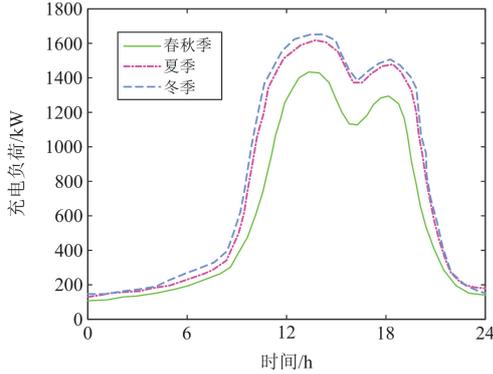


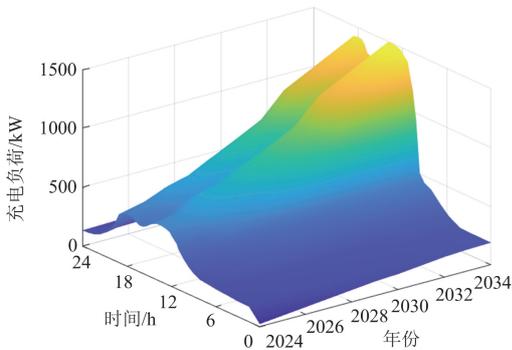
图 11 2034 年不同季节典型温度下充电负荷预测

Fig. 11 Prediction of charging load under typical temperatures in different seasons in 2034

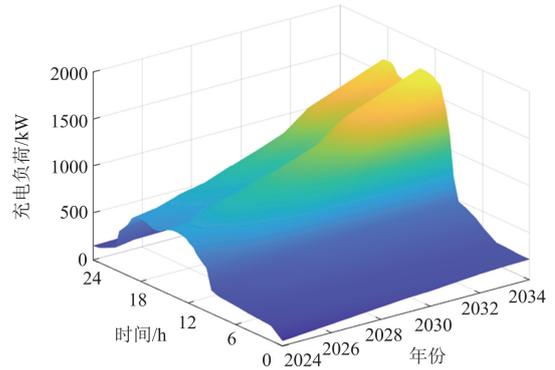
这种差异的产生主要源于温度对车载空调使用率和电池容量的影响。在夏季高温和冬季低温环境下, 车载空调的使用率会显著上升, 从而导致充电需求的增加。而春秋季节温度适宜, 车载空调的使用率较低, 因此充电需求相应减少。此外, 低温环境下电池容量的衰减进一步加剧了冬季充电需求的增长。因此, 温度对车载空调使用和电池容量的综合影响, 使得冬季充电需求负荷达到最大。

图 12 展示了该乡村景区 2024—2034 年不同季节典型日的电动汽车充电负荷预测情况。

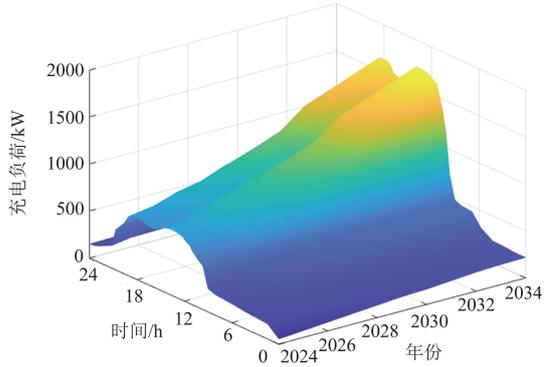
通过观察可以发现, 冬季和夏季的充电负荷比春秋季节高, 不同年份的充电负荷高峰期大致相同。此外, 各个季节典型日每年的充电需求均呈现出不断



(a) 2024—2034 年春季典型日充电负荷预测



(b) 2024—2034 年夏季典型日充电负荷预测



(c) 2024—2034 年冬季典型日充电负荷预测

图 12 2024—2034 年不同季节典型日充电负荷预测

Fig. 12 Prediction of charging load for a typical day from 2024 to 2034

断上涨的趋势, 主要归因于乡村旅游 EV 保有量的持续增加。因此, 对于乡村景区而言, 不断增长的充电需求使得合理规划和建设充电设施成为了当前亟待解决的问题。

## 5 结论

本文提出了一种基于改进 BME 方法的乡村旅游 EV 短期充电负荷预测模型, 在此基础上结合最优灰色模型和客流量预测模型得到乡村旅游 EV 未来的保有量, 从而实现乡村旅游 EV 的中长期负荷预测, 通过算例分析得到以下结论。

1) 本研究提出的基于改进 BME 的预测模型在乡村旅游这一特定场景中, 充分考虑了季节性因素等多源小样本情况, 相较于传统的负荷预测方法, 该模型在预测精度上展现出显著优势, 这一特点使其在乡村旅游等复杂且数据稀缺的乡镇中具有广泛的应用前景。

2) 本文针对乡村旅游的特殊性, 构建了旅游 EV 保有量与 EV 保有量及旅游客流量之间的关系

模型。基于旅游 EV 保有量预测结果,进一步分析了不同温度条件下 EV 充电负荷的动态演变规律并探讨了长时间尺度下 EV 充电需求的发展趋势。

### 参考文献

- [1] 邓衍辉, 李剑, 卢国强, 等. 考虑分区域动态电价机制引导的电动汽车充电优化策略[J]. 电力系统保护与控制, 2024, 52(7): 33-44.  
DENG Yanhui, LI Jian, LU Guoqiang, et al. Charging optimization strategy of electric vehicles guided by the dynamic tariff mechanism of a subregion[J]. Power System Protection and Control, 2024, 52(7): 33-44.
- [2] 周原冰, 龚乃玮, 王皓界, 等. 中国电动汽车发展及车网互动对新型储能配置的影响[J]. 中国电力, 2024, 57(10): 1-11.  
ZHOU Yuanbing, GONG Naiwei, WANG Haojie, et al. Study on the influence of electric vehicle development and the vehicle-grid interaction on new energy storage configuration in China[J]. Electric Power, 2024, 57(10): 1-11.
- [3] 国家发展改革委国家能源局关于加快推进充电基础设施建设更好支持新能源汽车下乡和乡村振兴的实施意见[J]. 财会学习, 2023(19): 1.
- [4] 陈艳波, 张宁, 李嘉祺, 等. 零碳园区研究综述及展望[J]. 中国电机工程学报, 2024, 44(14): 5496-5517.  
CHEN Yanbo, ZHANG Ning, LI Jiaqi, et al. Review and prospect of zero carbon park research[J]. Proceedings of the CSEE, 2024, 44(14): 5496-5517.
- [5] 周衍涛, 戴军, 苑惠丽, 等. 城市电动汽车充电设施需求预测与规划布局研究[J]. 电力系统保护与控制, 2021, 49(24): 177-187.  
ZHOU Yantao, DAI Jun, YUAN Huili, et al. Demand forecasting and planning layout of urban electric vehicle charging facilities[J]. Power System Protection and Control, 2021, 49(24): 177-187.
- [6] FLORIAN S, OTTO M, DIETMAR G, et al. Forecasting the spatial and temporal charging demand of fully electrified urban private car transportation based on large-scale traffic simulation[J]. Green Energy and Intelligent Transportation, 2023, 2(1).
- [7] 姚芳, 汤俊豪, 陈盛华, 等. 基于 ISSA-CNN-GRU 模型的电动汽车充电负荷预测方法[J]. 电力系统保护与控制, 2023, 51(16): 158-167.  
YAO Fang, TANG Junhao, CHEN Shenghua, et al. Charging load prediction method for electric vehicles based on an ISSA-CNN-GRU model[J]. Power System Protection and Control, 2023, 51(16): 158-167.
- [8] 张延宇, 张智铭, 刘春阳, 等. 基于动态自适应图神经网络的电动汽车充电负荷预测[J]. 电力系统自动化, 2024, 48(7): 86-93.  
ZHANG Yanyu, ZHANG Zhiming, LIU Chunyang, et al. Electric vehicle charging load prediction based on dynamic adaptive graph neural network[J]. Automation of Electric Power Systems, 2024, 48(7): 86-93.
- [9] 张晋豪, 武小梅, 潘景晖, 等. 基于贝叶斯最大熵的电动汽车充电需求预测[J]. 吉林电力, 2022, 50(2): 12-15, 31.  
ZHANG Jinhao, WU Xiaomei, PAN Jinghui, et al. Electric vehicle charging demand forecasting based on Bayesian maximum entropy[J]. Jilin Electric Power, 2022, 50(2): 12-15, 31.
- [10] 于梦桐, 高辉, 杨凤坤. 计及电动汽车保有量增长需求的充电负荷预测[J]. 现代电子技术, 2024, 47(6): 55-62.  
YU Mengtong, GAO Hui, YANG Fengkun. Charging load forecasting considering growth demand for electric vehicle ownership[J]. Modern Electronic Technique, 2024, 47(6): 55-62.
- [11] 古圣钰, 吴英伟. 节假日乡村旅游客流量预测——基于季节性调整的支持向量机模型研究[J]. 林业经济, 2021, 43(9): 86-96.  
GU Shengyu, WU Yingwei. Prediction of rural tourist flow during holidays——study on support vector machine model based on seasonal adjustment[J]. Forestry Economics, 2021, 43(9): 86-96.
- [12] 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.
- [13] 周喆, 黄婧杰, 周任军, 等. 考虑关键气象因素的时间卷积网络充电桩负荷预测[J]. 电力系统及其自动化学报, 2023, 35(5): 28-36.  
ZHOU Zhe, HUANG Jingjie, ZHOU Renjun, et al. Charging pile load prediction using temporal convolutional network with consideration of key meteorological factors[J]. Proceedings of the CSU-EPSA, 2023, 35(5): 28-36.
- [14] 朱永胜, 常稳, 武东亚, 等. 考虑充放储一体站与电动汽车互动的主从博弈优化调度策略[J]. 电力系统保护与控制, 2024, 52(7): 157-167.  
ZHU Yongsheng, CHANG Wen, WU Dongya, et al. A Stackelberg game optimization scheduling strategy considering the interaction between a charging-discharging-storage integrated station and an electric vehicle[J]. Power System Protection and Control, 2024, 52(7): 157-167.
- [15] 张志行, 韩雪冰, 冯旭宁, 等. 面向不同电流工况的锂

- 离子电池改进 EECM 研究[J]. 电力工程技术, 2023, 42(4): 2-12.  
ZHANG Zhihang, HAN Xuebing, FENG Xuning, et al. Improved EECM for lithium-ion batteries under different current conditions[J]. Electric Power Engineering Technology, 2023, 42(4): 2-12.
- [16] 王海玲, 张美霞, 杨秀. 基于气温影响的电动汽车充电需求预测[J]. 电测与仪表, 2017, 54(23): 123-128.  
WANG Hailing, ZHANG Meixia, YANG Xiu. Electric vehicle charging demand forecasting based on influence of weather and temperature[J]. Electrical Measurement & Instrumentation, 2017, 54(23): 123-128.
- [17] 刘志坚, 戴景, 杨灵睿. 考虑电力-交通耦合网动态协调的 EV 集群灵活性挖掘与优化调度[J]. 电力系统自动化, 2024, 48(7): 127-137.  
LIU Zhijian, DAI Jing, YANG Lingrui. Flexibility mining and optimal scheduling for electric vehicle clusters considering dynamic coordination of power-transportation coupling network[J]. Automation of Electric Power Systems, 2024, 48(7): 127-137.
- [18] 欧阳福莲, 王俊, 周杭霞. 基于改进迁移学习和多尺度 CNN-BiLSTM-Attention 的短期电力负荷预测方法[J]. 电力系统保护与控制, 2023, 51(2): 132-140.  
OUYANG Fulian, WANG Jun, ZHOU Hangxia. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2023, 51(2): 132-140.
- [19] 方恩泽. 考虑乡村旅游出行特征的电动汽车充电桩选址问题研究[D]. 南京: 南京农业大学, 2020.  
FANG Enze. Study on location problem of electric vehicles charging stations considering the characteristics of rural tourism travel[D]. Nanjing: Nanjing Agricultural University, 2020.
- [20] 游磊, 金小明, 刘云. 电动汽车集群充电负荷计算方法研究[J]. 南方能源建设, 2024, 11(5): 159-167.  
YOU Lei, JIN Xiaoming, LIU Yun. Research on the charging load calculation method for electric vehicle cluster[J]. Southern Energy Construction, 2024, 11(5): 159-167.
- [21] 庞松岭, 赵雨楠, 张瑞恩, 等. 市场环境计及用户响应的电动汽车充电站优化运行策略[J]. 电力建设, 2024, 45(10): 59-68.  
PANG Songling, ZHAO Yunan, ZHANG Ruiren, et al. The optimal operation strategy of electric vehicle charging stations considering user response in market environment[J]. Electric Power Construction, 2024, 45(10): 59-68.
- [22] 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.
- [23] GAO Zekun, JIANG Yutong, HE Junyu, et al. Comparing eight remotely sensed sea surface temperature products and Bayesian maximum entropy-based data fusion products[J]. Spatial Statistics, 2023, 54.
- [24] SARA R, MARC S, VIVIEN D, et al. Spatialization of saturated hydraulic conductivity using the Bayesian maximum entropy method: application to wastewater infiltration areas[J]. Water Research, 2021, 204: 117607-117609.
- [25] 陈荣, 梁昌勇, 陆文星, 等. 基于季节 SVR-PSO 的旅游客流量预测模型研究[J]. 系统工程理论与实践, 2014, 34(5): 1290-1296.  
CHEN Rong, LIANG Changyong, LU Wenxing, et al. Forecasting tourism flow based on seasonal PSO-SVR model[J]. Systems Engineering-Theory & Practice, 2014, 34(5): 1290-1296.
- [26] ZHANG Xian, CHAN Kawing, YANG Xuesen, et al. A comparison study on electric vehicle growth forecasting based on grey system theory and NAR neural network[C] // 2016 IEEE International Conference on Smart Grid Communications, November 6-9, 2016, Sydney, Australia: 711-715.
- [27] 于霄宇, 纪正森, 嵇灵, 等. 双碳目标下我国电动汽车碳减排贡献潜力分析[J]. 智慧电力, 2024, 52(2): 25-31, 39.  
YU Xiaoyu, JI Zhengsen, JI Ling, et al. Analysis on carbon emission reduction potential of electric vehicles in China under goal of carbon neutrality and carbon peaking[J]. Smart Power, 2024, 52(2): 25-31, 39.

收稿日期: 2024-08-08; 修回日期: 2024-11-22

作者简介:

顾睿(1999—), 男, 硕士研究生, 研究方向为电动汽车充换电站规划; E-mail: 17715338191@163.com

于艾清(1981—), 女, 通信作者, 博士, 副教授, 硕士生导师, 研究方向为新型电力系统规划、智能算法。E-mail: yuaiqing@shiep.edu.com

(编辑 周金梅)