

基于改进蒙特卡洛算法的电动汽车充电负荷预测

刘瑞霖^{1,2}, 余洋^{1,2}, 刘璠³, 李伟³

1. 新能源电力系统全国重点实验室(华北电力大学(保定)), 河北 保定 071003;
2. 河北省分布式储能与微网重点实验室(华北电力大学(保定)), 河北 保定 071003;
3. 内蒙古电力集团蒙电经济技术研究院有限责任公司, 呼和浩特 010020)

摘要: 针对传统蒙特卡洛模拟方法在电动汽车充电负荷预测中存在的概率分布拟合误差大及数据随机性强等问题, 提出基于GMM(高斯混合模型)与GRA(灰色关联度分析)的改进方法。首先, 利用GMM拟合充电行为特征的多峰分布特性, 并通过BIC(贝叶斯信息准则)优化高斯分量个数, 提升概率分布模型准确性。其次, 应用GRA分析蒙特卡洛随机生成的充电行为数据集与原始数据的关联度, 筛选最优数据集以降低极端值影响。最后, 引入电池容量伽马分布模型表征不同类型电动汽车的异质性充电需求, 进行电动汽车负荷预测。仿真结果表明: 采用改进方法拟合的起始充电时间与起始充电SOC(荷电状态)相关系数最高达0.999 5, 预测的总充电负荷预测峰值更贴合实际用电高峰时段, 显著提升了预测精度。该方法通过融合GMM多峰拟合能力与GRA数据筛选机制, 解决了传统方法中概率模型单一性和数据随机性问题, 为电网负荷规划与动态平衡提供了技术支持。

关键词: 电动汽车; 充电负荷预测; 蒙特卡洛模拟; 高斯混合模型; 灰色关联度分析

DOI: 10.19585/j.zjdl.202508002

开放科学(资源服务)标识码(OSID):



EV charging load forecasting using an enhanced Monte Carlo simulation methods

LIU Ruilin^{1,2}, YU Yang^{1,2}, LIU Jun³, LI Wei³

1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources (NCEPU), Baoding, Hebei 071003, China;
2. Key Laboratory of Distributed Energy Storage and Microgrid of Hebei Province, North China Electric Power University (Baoding), Baoding, Hebei 071003, China;
3. Inner Mongolia Electric Power Group Mengdian Economic and Technological Research Institute Co., Ltd., Hohhot 010020, China)

Abstract: To address the limitations of conventional Monte Carlo simulation methods in electric vehicle (EV) charging load forecasting—particularly their large probability distribution fitting errors and strong data randomness—this paper proposes an enhanced approach integrating Gaussian mixture model (GMM) and grey relational analysis (GRA). First, GMM is employed to fit the multimodal distribution characteristics of charging behaviors, with the Bayesian information criterion (BIC) optimizing the number of Gaussian components to enhance probability distribution model accuracy. Second, GRA evaluates the relational degree between Monte Carlo-generated charging behavior datasets and the original data, screening optimal datasets to mitigate extreme value impacts. Finally, a Gamma distribution model of battery capacity is introduced to characterize heterogeneous charging demands across EV types. Simulation results demonstrate that the enhanced method achieves a correlation coefficient of up to 0.999 5 for initial charging time and initial state of charge (SOC) fitting, while the forecasted peak total charging load aligns closely with actual peak demand periods, significantly improving forecasting precision. By combining GMM's multimodal fitting capability with GRA's data screening mechanism, this method resolves the oversimplified probability models and data randomness inherent in traditional approaches, offering robust technical support for grid load planning and dynamic balancing.

Keywords: EV; charging load forecasting; Monte Carlo simulation; GMM; GRA

0 引言

近年来,在国家“双碳”战略目标的政策推动下,新能源汽车数量实现了爆发式增长。截至2024年底,我国新能源汽车产销量已连续10年位居全球首位,保有量达3 140万辆,市场渗透率达47.6%^[1-4]。然而,电动汽车规模化接入电网的时空聚合性与随机性,可能引发电力系统多重风险。无序充电易加剧区域负荷峰谷差,导致变压器过载、电压越限及供电可靠性下降;若与晚高峰负荷叠加,可能使配电网局部峰值负荷激增40%以上。研究表明,当区域电动汽车渗透率超过15%时,配电网容量缺口可达10%~30%,危及电网安全运行^[5]。因此,准确的电动汽车充电负荷预测是提升电网韧性与实现低碳转型的技术基石。

在电动汽车充电负荷预测研究领域,基于概率统计方法的建模分析具有显著的理论优势,其中蒙特卡洛模拟因其广泛的适用性成为主流研究方法。现有研究在技术特征与局限性方面呈现以下共性规律:文献[6-8]通过构建日行驶里程与起始充电时间的概率分布模型实现蒙特卡洛模拟,但未将电池SOC(荷电状态)纳入建模体系。文献[9]在基础模型中引入起始充电SOC参数,但其SOC数值通过日行驶里程模型间接推导获得,可能导致误差传递现象。文献[10]建立了日行驶里程、SOC及最后一次返程时间的联合概率分布模型,采用多特征独立抽样策略提升模拟精度。值得注意的是,城市电动汽车充电负荷普遍呈现多峰非规则分布特征,传统单峰分布模型在概率密度函数拟合过程中存在系统性偏差。现有研究在概率分布建模与数据抽样方法上主要存在双重不足:首先,理想化概率分布假设易导致模型与实际充电行为特征失配;其次,单一概率模型难以有效表征多峰分布特性。此外,基于日行驶里程推算充电需求的建模框架隐含“每日一充”假设,与实际的充电行为多样性存在理论差异。文献[11]采用双段泊松分布改进电动汽车返回时间模型,受限于泊松分布均值与方差相等的固有特性,其在多峰场景下适应性仍有待提升。文献[12]应用有限混合模型改进起始充电时间建模,虽突破单峰限制,但在分量确定方法与过拟合控制方面仍存在改进空间。GMM(高斯混合模型)因其多峰

表征能力与计算效率优势,结合信息准则优化模型复杂度的方法,展现出潜在的应用价值。在蒙特卡洛模拟的数据抽样环节,现有研究普遍采用单次抽样策略进行负荷预测,导致预测结果易受异常值影响且统计稳定性不足。GRA(灰色关联度分析)通过构建多组抽样数据集的筛选机制,与原始数据集进行关联性对比,可有效增强预测结果的稳健性。总体而言,当前基于蒙特卡洛模拟的充电负荷预测方法在概率模型的多峰特征表征、过拟合抑制机制以及抽样稳定性优化等方面仍需深化研究,特别是在高维概率分布建模与自适应抽样算法领域具有进一步探索的必要性。

因此,本文提出一种基于GMM-GRA的蒙特卡洛模拟改进框架,以系统解决现有充电负荷预测方法的关键技术瓶颈。针对充电负荷多峰非规则分布特性,构建基于GMM的概率建模框架,通过BIC(贝叶斯信息准则)自适应确定模型分量数目,克服传统单峰分布导致的特征失配问题。在充电需求计算维度,建立以起始充电SOC为直接判定参数的充电需求计算模型,替代传统基于日行驶里程的间接推导方法,消除模型误差传递风险,突破“每日一充”假设的理论局限。在数据抽样环节设计优化筛选机制,运用GRA评估抽样数据集与原始数据的特征一致性,构建最优抽样集合,从而降低极端值干扰,提升预测结果的统计稳定性。本方法通过概率模型优化与抽样机制改进蒙特卡洛模拟,旨在实现充电负荷预测精度与鲁棒性的协同提升。

1 GMM构建与分量确定

1.1 GMM原理

GMM是一种基于多个高斯分布线性组合构成的概率模型,通过动态调节高斯分量个数及其对应的权重系数、均值与协方差参数,能够实现复杂概率分布函数的全局逼近^[13-15]。该模型在电动汽车充电行为特征解析方面具有显著优势,其多模态特征解析能力可有效表征充电负荷的非规则多峰分布特性。相较于传统单峰建模方法,GMM通过自适应分量配置机制,可依据数据特征自动优化模型复杂度,从而提升充电行为概率表征的准确性。假设电动汽车充电负荷特征数据 x 服从由 M 个高斯分布加权组合而成的联合概率密度

函数,则其GMM概率密度函数可以表示为:

$$p(x) = \sum_{m=1}^M \pi_m N(x|\mu_m, \Sigma_m) \quad (1)$$

式中: M 为高斯分布的数量; π_m 为第 m 个高斯分布的权重,满足 $\sum_{m=1}^M \pi_m = 1$; $N(x|\mu_k, \Sigma_k)$ 为第 m 个高斯分布的概率密度函数。

1.2 高斯分量个数的确定

在统计建模中, AIC(赤池信息量准则)和BIC是两种经典的信息准则,它们通过权衡模型拟合优度与复杂度,用于选择GMM最合适的高斯分量个数。

AIC的拟合优度通过最大似然估计值进行表征。拟合优度越高,模型对观测数据的拟合程度越好,最大似然估计值就越大。此外,准则通过复杂度惩罚项避免过度拟合的问题^[16]。当AIC值最小时对应的阶数即为最优高斯分量个数,将其定义为:

$$A_{\text{AIC}} = -2\ln(L) + 2k \quad (2)$$

式中: $\ln(L)$ 为最大似然估计; $2k$ 为复杂度惩罚项。

BIC基于贝叶斯理论,通过最大化模型的后验概率来选择模型。与AIC类似, BIC也利用最大似然函数考虑了模型对数据的拟合程度,并引入了对模型复杂度的惩罚项。但BIC的惩罚项与样本量有关,对模型复杂度的惩罚更加严厉^[17]。当BIC值最小时对应的阶数即为最优高斯分量个数,将其定义为:

$$B_{\text{BIC}} = -2\ln(L) + k\ln(n) \quad (3)$$

式中: $\ln(L)$ 为最大似然估计; $k\ln(n)$ 为复杂度惩罚项; n 为样本量。

鉴于现实场景中电动汽车充电负荷特征呈现多峰分布特性,常采用3阶或高阶混合分布模型进行描述。为验证模型选择准则的有效性并使其更适配电动汽车充电负荷特征,本节设置了验证实验,生成符合3阶高斯混合分布的样本数据集。通过AIC与BIC分别进行混合高斯模型阶数选择实验,结果表明: AIC倾向于选择更高阶模型,其确定的最优阶数为4阶;而BIC凭借更加严厉的惩罚机制,表现出对简约模型的偏好,其确定的最优阶数为3阶,与实验预设的样本数据集阶数一致。基于AIC与BIC的GMM拟合曲线如图1所示。AIC值和BIC值与高斯分量个数的关系如图2

所示。该实验结果验证了BIC在控制模型复杂度方面的优势。




图1 基于AIC与BIC的GMM拟合曲线

Fig.1 GMM fitting results under AIC and BIC criteria




图2 AIC值和BIC值与高斯分量个数的关系

Fig.2 Relationship between AIC/BIC values and the number of Gaussian components

当电动汽车负荷特征数据规模较大时,仅采用AIC进行最优聚类数判定可能导致模型不收敛且精度不足。因此,需要选择BIC进行判别以弥补AIC的潜在缺陷^[18],从而获得拟合度更高的GMM拟合函数。

2 电动汽车充电负荷特征

2.1 起始充电时间概率分布

电动汽车起始充电时间 T_c 受车辆类型和用户行为等多种因素的影响。电动私家车平均日行驶里程较短、耗电量较少,通常采用一日一充或多日一充的模式;而电动出租车与电动公交车因其运营需求,平均日行驶里程较长,多采用一日多充的模式。

电动汽车起始充电时间概率分布及拟合曲线如图3所示(横坐标0—24 h分别对应00:00—次日

00:00), 电动私家车和电动出租车充电时间分布呈明显的多峰趋势。在18:00—20:00私家车充电时间达到最高峰, 反映用户下班后集中充电的行为模式, 且在12:00左右出现次高峰, 对应用户中午短途出行后的补电需求。传统正态模型忽略了上述两个特征, 导致峰值时间提前了约4 h。在13:00和17:00左右, 电动出租车充电时间形成两个高峰, 这一双峰分布分别对应司机换班和晚餐时段的补电需求, 两个峰值概率密度仅相差7.5%。传统正态模型同样无法体现实际需求下的充电时间特征。电动公交车因电池容量大且运行规律, 在11:00和21:00左右有两个峰值, 整体呈现双峰趋势, 分别对应上午和晚上运营结束后的补电行为。GMM能够较好地拟合出双峰特征, 而传统正态模型由于均值偏移, 导致峰值出现较大差异。

使用一阶正态模型无法准确表征多峰特征下起始充电时间的趋势, 出现较大误差。通过GMM拟合起始充电时间概率密度函数, 相较于一阶正态分布模型展现出更佳的拟合优度。

2.2 起始充电SOC概率分布

在现有研究中, 电动汽车起始SOC通常根据日行驶里程的统计数据推导而来。然而, 这种假设将充电行为限定为单日单次充电模式, 与实际情况存在明显偏差^[19]。实证研究表明, 用户的充电决策主要受剩余电量水平驱动, 而非单纯依赖行驶里程。鉴于此, 建议在构建充电负荷预测模型时, 将起始充电SOC作为核心特征, 以规避日行驶里程可能引入的模型误差。

与起始充电时间类似, 起始充电SOC的分布也具有非标准正态分布特性。为提高拟合优度, 可采用GMM构建SOC分布模型。电动汽车起始充电SOC概率分布及拟合曲线如图4所示。由图4中的起始充电SOC分布直方图可知, 私家车SOC峰值集中在0.2~0.6, 占比达79.4%, 这反映出用户因续航焦虑而采取的保守充电策略; 出租车SOC分布范围较窄, 集中在0.3~0.6, 且峰值明显左移, 这体现了出租车运营距离长和耗电量大的特点; 公交车SOC峰值集中在0.4~0.7, 作为公共交通工具, 为确保稳定运行, 其充电时SOC相对较高。三类电动汽车的起始充电SOC虽呈现单峰趋势, 但仍具有偏态的非标准正态特性, 需灵活建模。传统拟合方法得到的均值和峰值依然存

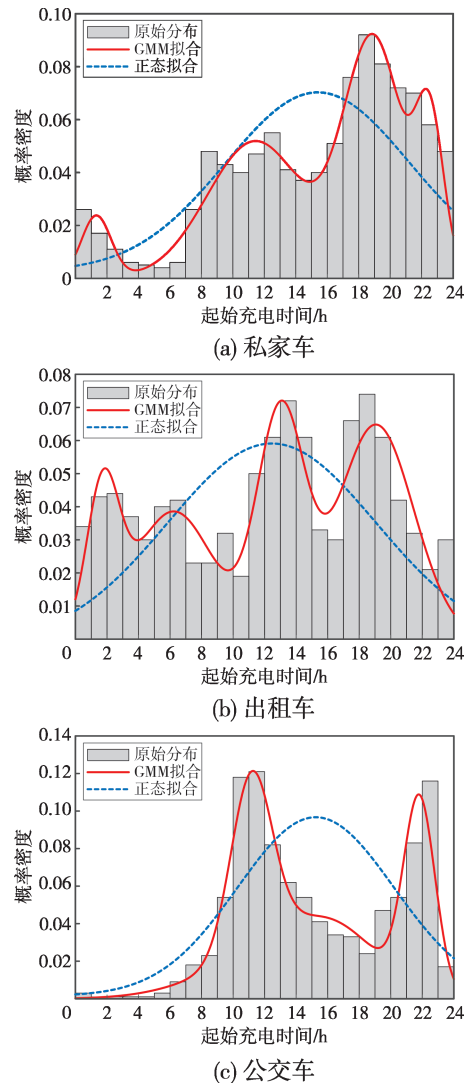


图3 电动汽车起始充电时间概率分布及拟合曲线
Fig.3 Probability distribution and fitted curves of EV charging start time

在偏差, 而GMM通过BIC自适应分量选择, 即使在单峰场景下, 也能优化拟合优度。

通过计算概率分布曲线与原始概率分布数据的相关系数, 可得各类电动汽车的充电负荷特征(起始充电时间和起始充电SOC)相关系数如表1所示: 相关系数均趋近于1, 拟合效果较好。

2.3 电动汽车充电负荷计算

本文关注的电动汽车充电行为主要有起始充电时间和起始充电SOC。充电时长和充电电量与起始充电SOC直接相关; 充电持续时间则与起始充电时间有关。充电电量 ΔQ 可以表示为:

$$\Delta Q = (S_{\text{SOC, end}} - S_{\text{SOC, start}})E \quad (4)$$

式中: $S_{\text{SOC, start}}$ 为起始充电SOC值; E 为电动汽车

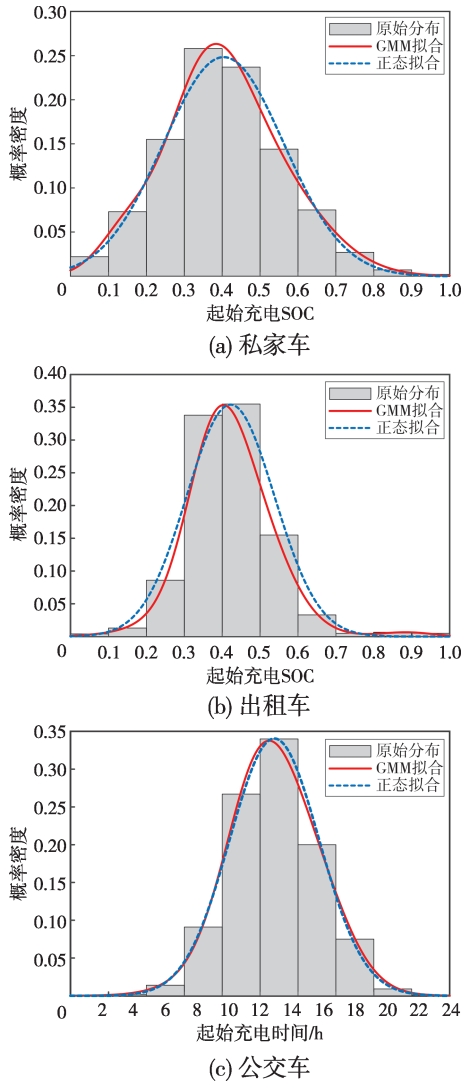


图 4 电动汽车起始充电 SOC 概率分布及拟合曲线

Fig.4 Probability distribution and fitted curves of EV charging start SOC

表 1 各类电动汽车充电负荷特征相关系数

Table 1 Correlation coefficients of charging load characteristics for across EV types

电动汽车类型	相关系数	
	起始充电时间	起始充电 SOC
私家车	0.968 4	0.999 5
出租车	0.865 3	0.998 0
公交车	0.963 8	0.998 6

电池容量; $S_{SOC, end}$ 为结束充电 SOC 值, 通常为 1。

在现实情况中, 不同类型电动汽车的电池容量差异较大, 若采用相同数值进行计算, 会导致负荷预测误差较大。根据电动汽车分类统计结果, 不同类型的电动汽车电池容量满足伽马分布^[20-21]。其概率分布函数可表示为:

$$f(E; \alpha, \beta) = \frac{1}{\beta^\alpha \Gamma(\alpha)} E^{\alpha-1} e^{-\frac{E}{\beta}} \quad (5)$$

式中: α 为形状参数; β 为尺度参数; $\Gamma(\alpha)$ 为伽马函数。

充电持续时间 ΔT 取决于充电功率 P_c 与充电效率 η , 可以表示为:

$$\Delta T = T_{end} - T_{start} = \frac{\Delta Q}{P_c \eta_c} \quad (6)$$

结合式(5), 充电时长可以写成:

$$\Delta T = \frac{(S_{SOC, end} - S_{SOC, start})E}{P_c \eta_c} \quad (7)$$

式中: η 为充电效率, 一般取 0.9; P_c 为充电功率, 取决于用户所用的充电设备, 分为快充和慢充, 私家车用户习惯在行程结束后采用慢充, 而出租车和公交车在工作时段以效率为主, 常使用快充。

设区域内电动汽车数量为 N , 按类型分为私家车数量 N_{pri} , 出租车数量 N_{car} , 公交车数量 N_{bus} , 其电池容量 E_{pri} 、 E_{car} 、 E_{bus} 分别服从以下伽马分布:

$$\begin{cases} E_{pri} \sim \text{Gamma}(\alpha_1, \beta_1) \\ E_{car} \sim \text{Gamma}(\alpha_2, \beta_2) \\ E_{bus} \sim \text{Gamma}(\alpha_3, \beta_3) \end{cases} \quad (8)$$

式中: (α_1, β_1) 、 (α_2, β_2) 、 (α_3, β_3) 分别为电动私家车、电动出租车和电动公交车的电池容量参数。

电动私家车充电频率低, 以慢充为主, 单台电动私家车充电负荷计算公式为:

$$P_{pri, t} = \begin{cases} P_{pri, slow}, T_{c, pri} \leq t \leq T_{c, pri} + \Delta T_{c, pri} \\ 0, \text{其他时间} \end{cases} \quad (9)$$

电动出租车的充电负荷计算需体现其一天内多次充电的需求特点。单台电动出租车充电负荷计算公式为:

$$P_{car, t} = \sum_{s=1}^{n_c} \begin{cases} P_{car, fast}, T_{c, car, s} \leq t \leq T_{c, car, s} + \Delta T_{c, car, s} \\ 0, \text{其他时间} \end{cases} \quad (10)$$

式中: s 为充电时段数; n_c 为最大充电次数。

电动公交车多以两段式充电为主, 日间补电和夜间充电相结合, 单台电动公交车充电负荷计算公式为:

$$P_{bus, t} = \begin{cases} P_{bus, fast}, T_{c, bus, night} \leq t \leq T_{c, bus, night} + \Delta T_{c, bus, night} \\ P_{bus, fast}, T_{c, bus, day} \leq t \leq T_{c, bus, day} + \Delta T_{c, bus, day} \\ 0, \text{其他时间} \end{cases} \quad (11)$$

在获取单台电动汽车全天充电负荷数据后,将某一时刻各类电动汽车充电负荷进行求和,可得到在该时刻所有电动汽车的充电负荷。进一步统计全天电动汽车集群的总充电负荷,其计算公式为:

$$P_{\text{total}} = \sum_{p=1}^N P_{jp,t}, j \in \{\text{pri, car, bus}\} \quad (12)$$

3 基于改进蒙特卡洛模拟的电动汽车充电负荷预测

3.1 GRA 模型

GRA 模型由邓聚龙教授于1985年提出,其核心原理是通过分析序列曲线几何形态的相似性,以此来评估序列间的关联强度^[22]。该方法主要用于量化参考序列与比较序列间的相似性水平,从而验证比较序列数据的有效性。

设参考序列为 $Y = [Y(1), Y(2), \dots, Y(n)]$, 比较序列为 $X_i = [X_i(1), X_i(2), \dots, X_i(n)]$, 其中 i 为序列维数, n 为序列元素个数。首先对数据进行归一化处理,将其转化为 $(0,1)$ 区间的数据,归一化后的数据为:

$$X'_i(k) = \frac{X_i(k) - \min X_i(k)}{\max X_i(k) - \min X_i(k)}, k = 1, 2, \dots, n \quad (13)$$

关联系数反映参考序列与比较序列的关联程度,其计算公式如下:

$$\gamma_i(k) = \frac{\min_i \min_k \Delta_i(k) + \rho \max_i \max_k \Delta_i(k)}{\Delta_i(k) - \rho \max_i \max_k \Delta_i(k)} \quad (14)$$

$$\Delta_i(k) = |X_i(k) - Y(k)|, k = 1, 2, \dots, n \quad (15)$$

式中: ρ 为分辨系数,通常取0.5; $\Delta_i(k)$ 为比较序列与参考序列的差值。

在电动汽车充电负荷预测的GRA过程中,关联度是关联系数的平均值,反映了比较序列与参考序列的整体关联程度。具体步骤如下:首先,确定参考序列 Y 为历史负荷数据序列,构建比较序列 X_i 为仿真生成数据序列;随后,基于原始数据矩阵,通过式(15)对序列间差值 $\Delta_i(k)$ 进行量化计算;接着,应用式(14)完成关联系数 $\gamma_i(k)$ 的迭代求解;最终,通过计算其算术平均值计算得到关联度 r_i 。

$$r_i = \frac{1}{n} \sum_{k=1}^n \gamma_i(k) \quad (16)$$

根据关联度 r_i 的大小排序,其中 $r_i \in [0,1]$ 。当 r_i 越接近于1时,证明比较序列与参考序列间的关联性越强;反之则证明关联性越弱。依据这一特性,可以筛选出灰色关联度最大的组别,将其作为充电负荷预测的数据。

3.2 改进的蒙特卡洛模拟

蒙特卡洛模拟是一种概率统计方法,被用于电动汽车充电需求负荷研究中^[23]。其基本思路是:通过概率分布描述电动汽车充电行为的随机性,再利用随机抽样模拟各电动汽车的充电安排,进而计算出电动汽车集群的总充电负荷^[9]。

通过传统蒙特卡洛模拟算法预测电动汽车充电负荷时,起始充电时间 T_c 和起始充电 SOC 的概率分布拟合采用的是一阶高斯分布。相比之下,改进的蒙特卡洛模拟方法利用 GMM 进行拟合,运用 BIC 确定高斯分量的个数,取 BIC 值最小时的分量个数,可以更好地反映概率分布趋势,减小误差。

此外,传统蒙特卡洛模拟仅抽取1组随机数据,这可能导致随机数据与原始数据偏离较大,从而降低负荷预测的准确度。因此,改进的蒙特卡洛模拟基于概率密度函数抽取 i 组随机数据,以减少偶然性带来的偏差。改进的蒙特卡洛电动汽车充电负荷预测流程如图5所示。

$$T_i = [T_i(1), T_i(2), \dots, T_i(n)] \quad (17)$$

$$S_{\text{soc},i} = [S_{\text{soc},i}(1), S_{\text{soc},i}(2), \dots, S_{\text{soc},i}(n)] \quad (18)$$

基于上述理论框架,改进的蒙特卡洛法电动汽车充电负荷预测的具体步骤如下:

步骤1:采用 GMM 对电动汽车起始充电时间 T_c 与起始充电 SOC 的概率分布进行拟合,结合式(1)构建不同车辆类型的充电负荷特征概率分布函数。通过 BIC 优化模型分量个数,确保对多峰分布特性的精确表征。

$$p_{T_c}(x) = \sum_{m=1}^M \pi_m^{T_c} N(x | \mu_m^{T_c}, \Sigma_m^{T_c}) \quad (19)$$

$$p_{\text{soc}}(x) = \sum_{m=1}^M \pi_m^{\text{SOC}} N(x | \mu_m^{\text{SOC}}, \Sigma_m^{\text{SOC}}) \quad (20)$$

步骤2:基于步骤1建立的概率分布函数,分别从电动私家车、电动出租车及电动公交车的充电负荷特征分布函数中抽取若干组起始充电时间 T_c 、起始充电 SOC 参数样本集。同时,依据不同

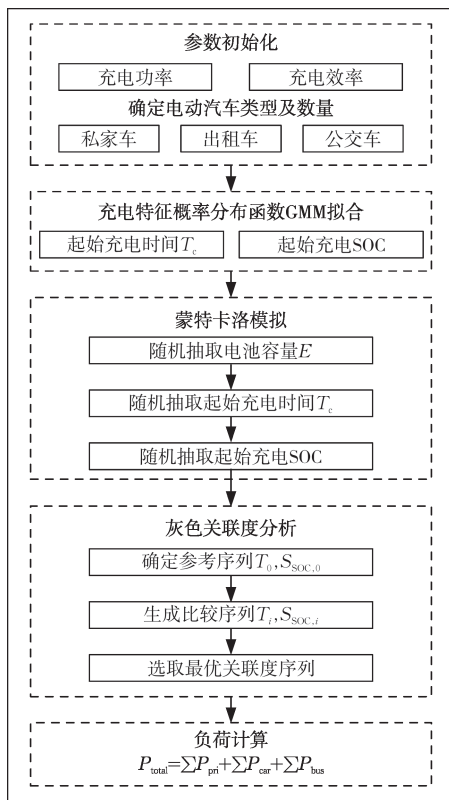


图5 改进的蒙特卡洛法电动汽车充电负荷预测流程
Fig.5 Flowchart of the enhanced Monte Carlo method for EV charging load forecasting

类型电动汽车电池容量的伽马分布函数, 随机生成异质性电池容量参数 E , 以反映车辆电池容量差异对充电需求的影响。

步骤3: 运用GRA对蒙特卡洛模拟生成的多元抽样数据集与原始数据集进行关联度评估, 根据式(16)计算并筛选出关联度 r_i 最佳的1组数据序列, 将其用于充电负荷预测, 以降低异常抽样对预测结果的干扰。

步骤4: 聚合每台电动汽车的充电负荷, 结合式(9)–(12)计算各类电动汽车的充电负荷 P_{pri} 、 P_{car} 、 P_{bus} 和总充电负荷 P_{total} 。

4 仿真实验

4.1 参数设置

根据某地区数据, 设置电动私家车13 537辆, 电动出租车2 200辆, 电动公交车1 151辆。因私家车与出租车同属小型车辆, 其电池容量服从 $f(10.8, 3.8)$ 的伽马分布; 公交车属于客车, 电池容量服从 $f(35.8, 5.8)$ 的伽马分布。充电功率设置

为快充(20 kW)与慢充(7 kW)两档, 充电效率统一设置为0.9。

4.2 最优数据组选取

根据概率分布函数抽取5组数据(每组数据元素个数与设置车辆数一致)。分别对三类电动汽车5组比较序列与原始参考序列通过GRA, 选取关联度最高的数据作为充电负荷预测数据。本文分别计算了5组电动私家车、电动出租车、电动公交车的起始充电时间 T_c 和起始充电SOC的灰色关联度, 并筛选出最优组关联度组。三类电动汽车充电负荷特征灰色关联度如表2所示。

根据每组的灰色关联度结果, 可筛选出私家车、出租车与公交车的最优数据组: 起始充电时间分别选取第2组、第3组和第5组; 起始充电SOC分别选取第3组、第4组和第2组。

表2 电动汽车充电负荷特征灰色关联度

Table 2 Grey relational analysis of EV charging load characteristics

电动汽车类型	组号	灰色关联度	
		起始充电时间	起始充电SOC
私家车	1	0.658 5	0.573 2
	2	0.697 7	0.624 5
	3	0.637 4	0.719 9
	4	0.611 0	0.623 1
	5	0.685 7	0.603 6
出租车	1	0.670 8	0.695 8
	2	0.655 2	0.727 2
	3	0.671 6	0.726 0
	4	0.643 3	0.747 5
	5	0.668 2	0.693 1
公交车	1	0.805 7	0.671 3
	2	0.791 4	0.779 3
	3	0.740 6	0.763 1
	4	0.756 1	0.637 2
	5	0.836 3	0.700 1

4.3 预测结果分析

通过改进蒙特卡洛模拟预测充电负荷, 预测结果如图6所示: 充电总负荷在21:00—22:00达到峰值(49.31 MW); 并在12:00—13:00, 出现小高峰(43.82 MW)。这是由于夜间和午间通常为多数车主的非工作时间, 车主倾向于利用这些空闲时间对电动汽车进行充电。电动私家车的充电日负荷总体呈现“前低后高”趋势, 峰值出现在21:00

左右(32.27 MW)。电动出租车在14:00和19:00左右出现两个峰值(均在12 MW附近)。电动公交车两个峰值出现在12:00(14.48 MW)和22:00(11.93 MW),而在01:00—06:00充电负荷基本为零。




图6 电动汽车充电负荷预测结果

Fig.6 EV charging load forecasting results

传统蒙特卡洛模拟方法受限于单峰正态分布假设的固有局限性,其概率密度函数对实际充电行为的非规则特征表征能力不足,导致充电负荷曲线呈现单一峰值(集中于16:00附近)。然而,此时段处于下午工作时间,现实中鲜有大量电动汽车接入充电桩充电,与实际情况存在差异。

5 结论

针对传统蒙特卡洛模拟算法在预测电动汽车充电负荷存在的概率分布拟合及数据关联度不高的问题,本文提出了基于GMM-GRA的改进蒙特卡洛模拟算法,并采用电动汽车数据进行了算例分析,得到以下结论:

1)提出了基于GMM-BIC融合的多峰值分布建模方法,有效提升了多峰值分布的拟合度(误差均控制在5%以内),更好地反映了真实情况,提高了概率分布模型的准确性。

2)针对电动汽车电池容量的异质性问题,引入了伽马分布描述电池容量,更准确地表征了电动汽车的充电需求,提高了充电负荷预测结果的可信度。

3)提出了基于GRA数据筛选方法,在蒙特卡洛模拟过程中,提升了充电负荷特征抽样数据与原始分布的相关度,降低了因极端数值造成的误差影响,将充电负荷预测的精度提高了30%以上。

参考文献

- [1] 新华社.我国新能源汽车产销量连续10年位居全球第一[EB/OL].(2025-01-21)[2025-03-02].https://www.gov.cn/lianbo/bumen/202501/content_7000306.htmlslb=true.
- [2] 新华社.我国将加强新能源汽车动力电池回收利用[EB/OL].(2025-02-22)[2025-03-02].https://www.gov.cn/zhengce/202502/content_7004966.htmddtab=true.
- [3] 宣羿,樊立波,孙智卿,等.考虑低碳交通的电动汽车充电站优化配置方法[J].浙江电力,2024,43(6):69-79.
XUAN Yi, FAN Libo, SUN Zhiqing, et al. An optimal allocation method for electric vehicle charging stations considering lowcarbon transportation [J]. Zhejiang Electric Power, 2024, 43(6): 69-79.
- [4] 黄健,陈建红,何剑杰,等.基于GCN-LSTM的电动汽车负荷预测方法[J].浙江电力,2024,43(12):59-67.
HUANG Jian, CHEN Jianhong, HE Jianjie, et al. An EV load forecasting method for using GCN-LSTM [J]. Zhejiang Electric Power, 2024, 43(12): 59-67.
- [5] 黄凤娇.规模化电动汽车充电负荷对电网影响的研究[J].电工技术,2024(20):113-116.
HUANG Fengjiao. Study on the impact of load of large-scale EV charging on power grid [J]. Electric Engineering, 2024(20): 113-116.
- [6] 王浩林,张勇军,毛海鹏.基于时刻充电概率的电动汽车充电负荷预测方法[J].电力自动化设备,2019,39(3):207-213.
WANG Haolin, ZHANG Yongjun, MAO Haipeng. Charging load forecasting method based on instantaneous charging probability for electric vehicles [J]. Electric Power Automation Equipment, 2019, 39(3): 207-213.
- [7] GUO C L, ZHU K J, CHEN C C, et al. Characteristics and effect laws of the large-scale electric Vehicle's charging load [J]. eTransportation, 2020, 3: 100049.
- [8] 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.
- [9] TIAN J, LV Y, ZHAO Q, et al. Electric vehicle charging load prediction considering the orderly charging [J]. Energy Reports, 2022, 8: 124-134.
- [10] 郭创新,刘洞宇,朱承治,等.电动汽车居民区充电负荷建模分析[J].电力自动化设备,2020,40(1):1-9.
GUO Chuangxin, LIU Dongyu, ZHU Chengzhi, et al. Modeling and analysis of electric vehicle charging load in residential area [J]. Electric Power Automation Equipment, 2020, 40(1): 1-9.
- [11] 蒋建东,韩文文,苑子俊,等.居民区电动汽车充电负荷建

- 模研究[J]. 郑州大学学报(理学版), 2019, 51(1): 73-77.
- JIANG Jiandong, HAN Wenwen, YUAN Zijun, et al. The modeling of electric vehicle charging load in residential areas[J]. Journal of Zhengzhou University (Natural Science Edition), 2019, 51(1): 73-77.
- [12] 毛建斌, 杨少兵, 杨湘彦, 等. 基于有限混合模型的规模化电动汽车充电负荷在线预测方法[J]. 电网技术, 2025, 49(5): 1931-1940.
- MAO Jianbin, YANG Shaobing, YANG Xiangyan, et al. Charging load online forecasting method based on finite mixture model for large-scale electric vehicles[J]. Power System Technology, 2025, 49(5): 1931-1940.
- [13] 熊紫维, 秦志友, 邓志坤, 等. 基于神经网络和混合高斯模型的光伏出力预测研究[C]//2024年电力行业技术监督专业技术交流研讨会优秀论文集. 南宁, 2024: 1106-1117.
- Xiong Ziwei, Qin Zhiyou, Deng Zhikun, et al. Research on photovoltaic power output prediction based on neural network and Gaussian mixture model [C]//Proceedings of Electric Power Industry Technical Supervision Professional Technology Exchange Conference 2024. Nanning, 2024: 1106-1117.
- [14] 朱亮, 支妍力, 梅贱生, 等. 基于GMM-FHMM的工业产线非介入式负荷辨识[J]. 浙江电力, 2024, 43(12): 68-76.
- ZHU Liang, ZHI Yanli, MEI Jiansheng, et al. Non-intrusive load monitoring for industrial production line based on GMM-FHMM [J]. Zhejiang Electric Power, 2024, 43(12): 68-76.
- [15] 闫威, 李南, 沈月秀, 等. 基于CNN-GAN与半监督回归的电动汽车充电负荷预测[J]. 浙江电力, 2023, 42(2): 83-89.
- YAN Wei, LI Nan, SHEN Yuexiu, et al. Electric vehicle charging load forecasting based on CNN-GAN and semi-supervised regression [J]. Zhejiang Electric Power, 2023, 42(2): 83-89.
- [16] 夏飞, 袁博, 彭道刚, 等. 基于信息量准则的锂离子电池变阶RC等效电路模型建模及优化方法[J]. 中国电机工程学报, 2018, 38(21): 6441-6451.
- XIA Fei, YUAN Bo, PENG Daogang, et al. Modeling and optimization of variable-order RC equivalent circuit model for lithium ion batteries based on information criterion [J]. Proceedings of the CSEE, 2018, 38(21): 6441-6451.
- [17] 肖碧涛, 赖晓路, 郭鹏, 等. 高斯混合模型风电机组异常数据识别方法研究[J]. 可再生能源, 2023, 41(8): 1051-1056.
- XIAO Bitao, LAI Xiaolu, GUO Peng, et al. Abnormal data identification for wind turbine based on Gaussian Mixture Model [J]. Renewable Energy Resources, 2023, 41(8): 1051-1056.
- [18] 邓俊, 张阳, 李怡然, 等. 基于高斯混合模型聚类的双馈风电场动态等值建模方法[J]. 太阳能学报, 2024, 45(1): 342-350.
- DENG Jun, ZHANG Yang, LI Yiran, et al. Dynamic equivalence modeling of doubly-fed wind farm based on Gaussian mixture model clustering algorithm [J]. Acta Energiae Solaris Sinica, 2024, 45(1): 342-350.
- [19] 陈丽丹, 聂涌泉, 钟庆. 基于出行链的电动汽车充电负荷预测模型[J]. 电工技术学报, 2015, 30(4): 216-225.
- CHEN Lidan, NIE Yongquan, ZHONG Qing. A model for electric vehicle charging load forecasting based on trip chains [J]. Transactions of China Electrotechnical Society, 2015, 30(4): 216-225.
- [20] 李磊, 赵新, 李晓辉, 等. 基于动态交通信息的电动汽车充电需求预测模型及其对配网的影响分析[J]. 电网与清洁能源, 2020, 36(3): 107-118.
- LI Lei, ZHAO Xin, LI Xiaohui, et al. Electric vehicle charging demand prediction model based on dynamic traffic information and its impacts on distribution networks [J]. Power System and Clean Energy, 2020, 36(3): 107-118.
- [21] MU Y F, WU J Z, JENKINS N, et al. A Spatial-temporal model for grid impact analysis of plug-in electric vehicles [J]. Applied Energy, 2014, 114: 456-465.
- [22] 王雁凌, 吴梦凯, 周子青, 等. 基于改进灰色关联度的电力负荷影响因素量化分析模型[J]. 电网技术, 2017, 41(6): 1772-1778.
- WANG Yanling, WU Mengkai, ZHOU Ziqing, et al. Quantitative analysis model of power load influencing factors based on improved grey relational degree [J]. Power System Technology, 2017, 41(6): 1772-1778.
- [23] 方尚尚, 王冰, 胡庆焱, 等. 基于蒙特卡洛算法的电动汽车充电需求负荷研究[J]. 系统仿真技术, 2020, 16(3): 150-155.
- FANG Shangshang, WANG Bing, HU Qingyi, et al. Research on electric vehicle charging demand load based on Monte Carlo algorithm [J]. System Simulation Technology, 2020, 16(3): 150-155.

收稿日期: 2025-04-01; 修回日期: 2025-05-26

作者简介:

刘瑞霖(2001), 男, 硕士研究生, 主要研究方向为电动汽车充电负荷预测与调控。

余洋(1982), 男, 工学博士, 博士生导师, 主要研究方向为电力储能技术、灵活资源建模与调度。(通信作者)。

(本文编辑: 张瑞敏)