

面向 V2G 的电动汽车动态分类及多特征在线聚合方法

余洋^{1,2}, 钱学尧^{1,2}, 陈晓^{1,2}, 吕晨睿^{1,2}, 王研^{1,2}

(1. 华北电力大学(保定)(新能源电力系统全国重点实验室), 河北 保定 071003;

2. 华北电力大学(保定)(河北省分布式储能与微网重点实验室), 河北 保定 071003)

摘要:针对车网互动(vehicle-to-grid, V2G)场景下大规模电动汽车(electric vehicle, EV)接入电网时处理速度慢、精度低等问题,提出一种基于自适应密度空间聚类(density-based spatial clustering of applications with noise, DBSCAN)算法的 EV 动态分类和多步马尔科夫链聚合方法。在分类阶段,利用 k-dist 曲线和差分 k-dist 曲线对 DBSCAN 算法进行改进,并引入增量式聚类的概念,对 EV 数据进行动态分类,得到不同荷电状态(state of charge, SOC)、剩余在网时长及可控容量的多维特征 EV 集群。在聚合阶段,提出考虑多步状态转移的马尔科夫链理论,利用该理论对每一 EV 集群在线建立聚合模型,并考虑多步状态转移的情况,弥补了传统马尔科夫链无法处理多特征 EV 动态聚合的缺陷,从而得到更准确的聚合功率。仿真结果表明,所提出的分类方法能够快速准确地将接入电网的大规模 EV 划分为不同集群,并且 EV 集群经过聚合后其功率准确度得到显著提高,能够有效解决大规模 EV 入网时存在的问题。

关键词:电动汽车(EV);车网互动(V2G);自适应密度空间聚类(DBSCAN);蒙特卡洛模拟;多步马尔科夫链;聚合模型

中图分类号:TM73

文献标志码:A

文章编号:2096-3203(2025)06-0037-12

0 引言

近年来,全球能源紧缺的问题受到广泛关注,为保证可持续发展,各种可再生能源得到大力发展。可再生能源虽然能缓解能源紧缺的问题,但其存在间歇性、波动性及随机性等固有特性,当其大规模接入电力系统时,将给电网的安全稳定运行带来巨大挑战^[1]。在此背景下,电动汽车(electric vehicle, EV)凭借其零排放、高效率等优势逐渐取代传统燃油汽车。截至 2024 年底,中国 EV 保有量达 2 200 万辆,其中具备车网互动(vehicle-to-grid, V2G)功能的车型占比超 10%。作为 V2G 技术的核心载体,EV 的双向能量流动特性在辅助电网调峰、调频等调控场景中发挥关键作用^[2-5]。

由于接入电力系统的 EV 数量规模庞大,直接对单台 EV 进行控制难度极高,因此需要将特征相似的 EV 聚合为集群,以便分析与调控。在现有研究中,多使用 K-means 聚类算法对 EV 数据进行聚类^[6]。然而, K-means 算法容易陷入局部最优,因此对初始聚类中心的选择较为敏感,而不同的初始聚类中心将导致聚类结果差异性较大。文献[7-8]采用一致性 K-means 算法对 EV 数据进行聚类,避免了传统 K-means 算法聚类结果的随机性现象,但仍

需要人为确定聚类个数,给聚类结果引入了较强的主观性。文献[9]提出改进模糊 C 均值算法进行 EV 聚类,利用有效性函数和隶属度的评估结果确定聚类个数和聚类中心,但聚类的时间复杂度高,难以用于动态分类场景。自适应密度空间聚类(density-based spatial clustering of applications with noise, DBSCAN)是一种基于密度的空间聚类算法,能将数据中密度较大的个体聚集为一类,无须用户手动确定聚类个数,且对初始聚类中心的选择不敏感,有效降低了人为因素对聚类结果的影响。针对文献[7-8]中聚类结果客观性不强以及文献[9]中时间复杂度过高的问题,文献[10]采用 DBSCAN 算法对 EV 进行聚类,以解决聚类个数和聚类中心难以选择的问题,且其时间复杂度不高。传统 DBSCAN 算法使用全局统一的聚类参数,而 EV 特征多为正态分布,难以用该算法进行准确划分。在上述背景下,文中提出基于自适应密度的改进增量式 DBSCAN 算法,在准确划分 EV 集群的前提下,提高算法的运行效率,适用于动态分类的场景。

当前,关于 EV 聚合建模方法主要分为两类:第一类是采用蒙特卡洛模拟法,如文献[11-13]基于用户出行特征概率密度函数,建立 EV 充电负荷预测模型;文献[14]在出行特征的基础上进一步考虑了用户出行链。但蒙特卡洛模拟法无法得到具体的 EV 聚合模型,故后续无法对其进行控制。另一类

是建立面向控制的聚合模型,如文献[15]建立了EV充电负荷模型;文献[16]则采用负荷传输方法,建立基于偏微分方程的EV集群充电负荷模型。然而,上述研究均未考虑单台EV的固有参数和出行习惯差异,导致模型的准确性不高。基于马尔科夫链的聚合建模方法以马尔科夫链理论为基础,先对各单体间的差异性进行统计,构建相应的概率密度函数,再计算状态转移概率,最终完成建模。该方法目前多被用于温控负荷的聚合建模,如文献[17-18]将温控负荷集群的温度分布划分为若干区间,并使用马尔科夫链进行建模;文献[19]利用半马尔科夫链理论建立空调负荷的控制模型。相比于温控负荷,EV的充放电周期较长,容易出现“维数爆炸”的问题。文献[20]使用基于双层离散化区间划分方法的马尔科夫链对EV建立聚合模型,解决了“维数爆炸”的问题,但无法对不同充放电功率的EV进行建模,聚合结果存在较大误差。文献[21]基于马尔科夫链理论建立考虑出行特征的EV集群充电负荷模型,但只考虑了EV出行时的状态,并未从本质上对马尔科夫链进行通用性的精度改进。文献[22]基于高阶马尔科夫链对EV集群进行建模,虽然考虑了马尔科夫链的历史状态,但其状态转移概率的估计仅依赖历史数据。上述方法或因缺乏解析模型结构而无法支持实时控制,或因忽略单体异质性导致模型失真,或因状态转移情况考虑不全而引入系统性误差,均难以满足大规模EV聚合调控对模型精确性与动态性的需求。文中提出基于多步状态转移的马尔科夫链理论,实现对不同功率等级及容量配置的大规模EV在线聚合建模。

基于上述分析,为解决大规模EV接入电网时存在的各类问题,文中提出一种基于改进DBSCAN算法的EV动态分类及多步状态转移马尔科夫链聚合方法。主要贡献如下:在分类阶段,提出一种基于自适应密度的增量式DBSCAN聚类算法,通过分析k-dist曲线和差分k-dist曲线得到EV数据的密度区间划分结果,并使用k-dist方法自动分配聚类参数,在避免聚类结果受人为主观因素影响的同时,能够自动适应不同密度分布的EV数据;采用增量式聚类方法,在每个时间步长内只对变化的数据进行分析,避免冗余运算,提升动态分类的处理速度。在聚合阶段,提出基于多步状态转移马尔科夫链的EV聚合方法,考虑多步状态转移的情况,对每一EV集群中多维度特征的EV单体进行在线整合,从而建立更加精确的EV集群聚合模型。通过算例对比所提改进聚类算法与传统聚类算法的聚

类效果,并分析EV集群通过不同聚合方法得到的聚合功率曲线差异,验证了所提方法的有效性。

1 总体框架及流程

文中构建的EV动态分类及在线聚合方法采用两阶段式架构,包括分类阶段与聚合阶段,总体框架及流程如图1所示。

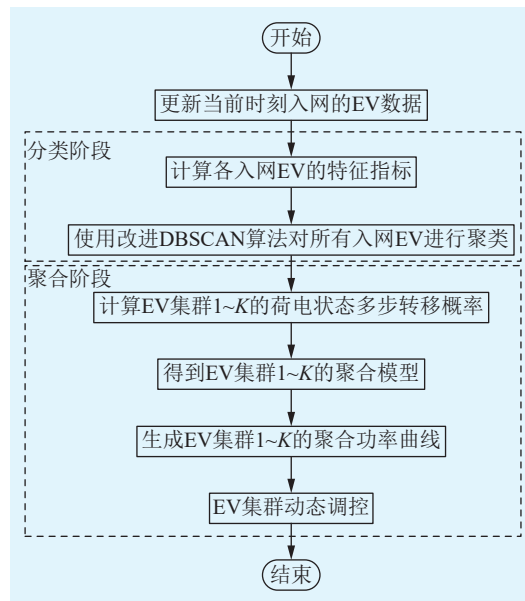


图1 总体框架及流程

Fig.1 Overall framework and flowchart

在分类阶段,基于EV的运行特性、充放电行为等多维特征,使用聚类算法将具有相似特征的EV进行分组,形成EV集群。通过分类,可减小聚合计算的复杂度,使后续聚合过程更具针对性。

在聚合阶段,针对每个EV集群,引入马尔科夫链理论建立数学模型,将集群内具有不同特征(充放电功率、电池容量等)的EV单体进行在线整合。通过对单体充放电状态转移概率的分析与计算,构建EV集群聚合模型,最终生成聚合功率曲线。

2 EV 集群划分

2.1 聚类算法

2.1.1 传统 DBSCAN 聚类算法

传统DBSCAN算法利用相似数据在空间上的连通性原理进行聚类^[23-24]。该算法有两个预设参数:邻域半径 R_{Eps} 和最小对象数 M_{minPt} 。设待聚类数据集为 $D = \{x_1, x_2, \dots, x_{n_d}\}$,并定义 $N_{Eps}(x_i) = \{x_j \in D | \text{dist}(x_i, x_j) \leq R_{Eps}\}$ 为数据点 x_i 邻近点的个数,其中 $\text{dist}(x_i, x_j)$ 为点 x_i 与点 x_j 之间的距离。

DBSCAN将待聚类的数据点划分为3类。第一类:核心点,指满足 $N_{Eps}(x_i) \geq M_{minPt}$ 的数据点。第

二类: 边界点, 指位于核心点的邻域半径 R_{Eps} 内且不满足 $N_{Eps}(x_i) \geq M_{minPt}$ 的数据点。当一个簇的边界都被边界点包围时, 即认为该簇的扩散已进行完毕。

第三类: 离群点, 指既不是核心点也不是边界点的数据点。

基于上述定义, DBSCAN 聚类算法的具体实现步骤如下。

步骤 1: 输入参数 R_{Eps} 和 M_{minPt} , 初始化聚类簇数 $N_d=0$ 。

步骤 2: 遍历每一个数据点, 将满足 $N_{Eps}(x_i) \geq M_{minPt}$ 的数据点标记为核心点, 其余标记为噪声点。并将所有遍历过的数据点标记为“已被访问”。

步骤 3: 若某数据点 x_i 被标记为核心点, 则聚类开始, 该核心点作为新簇中第一个点, 并将其邻域内所有的数据点 $(y_1, y_2, \dots, y_{m_d})$ 添加至该簇中。

步骤 4: 依次判断该核心点的每一邻域点 $y_i (i \in [1, m_d])$ 是否为核心点, 若为核心点, 则将 y_i 周围所有的邻域点也添加至该簇中, 以此进行簇的扩散, 直至该簇附近所有数据点都被标记为“已被访问”, 完成该簇的聚类, 聚类簇数 $N_d = N_d + 1$ 。

步骤 5: 重复步骤 1—步骤 4, 继续生成下一个簇, 直到所有数据点均被标记为“已被访问”, 聚类完成。

传统 DBSCAN 聚类算法由于使用全局统一的 R_{Eps} 作为输入参数, 难以准确处理 EV 等分布不均匀的数据的聚类^[25-26]。

2.1.2 基于自适应密度的增量式 DBSCAN 算法

文中在传统 DBSCAN 算法的基础上, 提出一种自适应密度聚类方法, 根据数据生成 k-dist 曲线^[27]和差分 k-dist 曲线, 并使用 k-dist 划分方法将 EV 数据划分为不同密度的区间, 然后针对不同区间的数据使用不同的参数进行聚类, 解决了传统聚类算法难以准确处理分布不均的 EV 数据的问题。其次, 在实际 EV 入网场景中, 接入某个聚合商的 EV 是动态变化的, 导致常规的聚类算法需要不断对 EV 数据进行聚类, 而调峰的时间尺度一般为小时级^[28], 调频甚至达到分钟级^[29]。因此, 为保证数据采集的准确度, 动态分类的时间尺度应更小。在短时间进行大规模的 EV 聚类, 对聚类算法的速度要求极高, 传统的聚类算法无法满足该要求。故文中引入增量式聚类的概念, 即在除第一次外的每一次聚类中, 只对变化的 EV 进行聚类, 并依据其对整体聚类结果的影响动态调整聚类结果, 避免对相同数据重复聚类。由于在较短的时间间隔内, EV 离网和新入网的数量通常较少, 故该方法可以显著提高动态分类的处理效率。

综上, 文中提出基于自适应密度的改进 DBSCAN 增量式聚类算法, 具体实现步骤如下。

(1) 首次聚类。

步骤 1: 计算待聚类数据中每个数据点的 k-dist 值, 将其按数值大小进行升序排列, 生成 k-dist 曲线。

步骤 2: 对 k-dist 曲线进行差分, 得到差分 k-dist 曲线。

步骤 3: 搜寻 k-dist 曲线上的拐点、差分 k-dist 曲线上的极值点, 将二者结合进行判断, 得到密度区间的分割点位置, 从而得到每个密度区间。

步骤 4: 使用 k-dist 方法为每个密度区间内的 EV 数据设定相应的 R_{Eps} , 并分别对每个区间进行 DBSCAN 聚类。

(2) 非首次聚类。

步骤 1: 更新数据的 k-dist 曲线和差分 k-dist 曲线, 得到每一个密度区间及其对应的参数。

步骤 2: 对于被剔除的点, 若其非核心点, 则直接从所属类别中剔除; 若其为核心点, 则判断该点属于哪些核心点的邻域点, 以及该点被剔除后这些核心点是否仍为核心点, 若是, 则无须重新聚类, 否则重新聚类。

步骤 3: 对于新增的点, 先判断其属于哪些核心点的邻域点, 若该新增点能使某一非核心点成为核心点, 则将该点划分至该类中; 若该新增点不能使任何一个非核心点成为核心点, 则找出该新增点的 M_{minPt} 个最近邻样本, 确定其各自所属的簇, 然后统计 M_{minPt} 个样本在各簇中的占比, 最后将新数据归入比重最高的簇中。

2.2 划分指标与结果

2.2.1 特征指标选取

文中选取荷电状态 (state of charge, SOC)、剩余在网时长、可调控容量作为聚类的特征指标。其中, 可调控容量由充电容量和放电容量两部分相加得到^[30-31], 具体定义如下。

(1) 充电容量。充电容量指 EV 可存储的电能大小, 根据定义, 可得到充电容量 S_c 的计算公式为:

$$S_c = (S_{dep} - S_0)C_{EV} \quad (1)$$

式中: S_{dep} 为 EV 的离网期望 SOC 值; S_0 为 EV 的入网起始 SOC 值; C_{EV} 为 EV 的电池容量。

(2) 放电容量。放电容量指 EV 可释放的电能, 其不仅取决于接入电网时刻的 SOC, 还需要保证放电过程中 SOC 的最小值能满足 EV 用户下一次出行。故放电容量表达式为:

$$S_d = (S_0 - S_{\min})C_{EV} \quad (2)$$

式中: S_{\min} 为充放电过程所允许的 SOC 最小值。

为防止因过度放电造成电池严重损伤, 设定 S_{\min} 的下限为 0.2, 故其计算公式为:

$$S_{\min} = \begin{cases} \frac{E_{100}d}{100C_{EV}} & \frac{E_{100}d}{100C_{EV}} \geq 0.2 \\ 0.2 & \frac{E_{100}d}{100C_{EV}} < 0.2 \end{cases} \quad (3)$$

式中: E_{100} 为 EV 的百公里耗电量; d 为 EV 日行驶里程数。

2.2.2 EV 集群模型

对 EV 进行分类后, EV 集群与集群内每一台 EV 之间的参数关系如下。

(1) EV 集群额定功率和额定容量。EV 集群 n 的额定功率 $P_{EV,n}$ 和额定容量 $C_{EV,n}$ 分别为:

$$P_{EV,n} = \sum_{m=1}^{M_n} P_{EV,m} \quad (4)$$

$$C_{EV,n} = \sum_{m=1}^{M_n} C_{EV,m} \quad (5)$$

式中: M_n 为集群 n 的 EV 总数; $P_{EV,m}$ 、 $C_{EV,m}$ 分别为第 m 辆 EV 的额定功率和额定容量。

(2) EV 集群 SOC。

$$S_n(t) = \sum_{m=1}^{M_n} S_m(t)/M_n \quad (6)$$

式中: $S_n(t)$ 为 EV 集群 n 在 t 时刻的 SOC; $S_m(t)$ 为第 m 辆 EV 在 t 时刻的 SOC。

3 基于多步状态转移马尔科夫链的 EV 聚合建模

EV 在接入电网后可能参与充电或放电操作。由于充电和放电过程具有可逆性, 使用马尔科夫链理论进行建模的方法类似, 因此文中以充电过程为例完成模型的推导与建立。

3.1 SOC 离散化状态区间划分

对于 EV 所剩电能大小, 通常使用 SOC 表示^[32]。当 EV 进行充放电时, 其 SOC 值将发生变化, 且该变化过程满足马尔科夫性^[33], 即当前状态的概率分布仅与前一状态有关, 与之前的历史状态无关。以充电为例, EV 在充电过程中的 SOC 离散递推公式为:

$$S(k+1) = S(k) + \frac{P_c(k)\eta_c \Delta t}{C_{EV}} \quad (7)$$

式中: $S(k)$ 、 $S(k+1)$ 分别为 EV 在 k 时刻、 $k+1$ 时刻的 SOC; $P_c(k)$ 为 k 时刻 EV 的充电功率; η_c 为充电效率; Δt 为单位时间步长。根据马尔科夫链的特性, $S(k+1)$ 的概率分布仅与 k 时刻的状态有关。

因此, 为便于利用马尔科夫理论对 EV 充电过程进行建模, 可对其 SOC 进行状态区间划分。为满足模型精度要求, 最大程度降低状态方程的维数, 文中采用文献[20]中的双层离散化方法对 SOC 进行状态区间划分, 具体过程如图 2 所示。




图 2 EV 充电过程 SOC 离散示意

Fig.2 Schematic diagram of SOC discretization in the EV charging process

由图 2 可知, EV 的状态区间被离散为两层。在第一层中, 考虑电池的安全性, 设置 SOC 的上限 S_{\max} 及下限 S_{\min} 。在上、下限范围内, SOC 被均等划分为 N_s 个状态大区间, 将每个大区间视为马尔科夫链的各个状态, 并据此确定 EV 集群充电聚合模型的状态空间维度。在第二层中, 将每个大区间进一步划分为 n_s 个更小的状态区间, 从而提高模型的精度。为便于后续推导, 将第 $i+1$ 区间的 SOC 下边界值表示为 $S_{\text{down}}(i+1)$, 第 i 个大区间中的第 j 个小区间的 SOC 下边界值表示为 $S_{\text{down}}(i, j)$ 。

3.2 充电状态下 SOC 多步转移概率推导

通过上述双层离散化后, 可将 EV 的充电过程视为一个马尔科夫链过程进行分析。对于转移概率的推导, 若直接采用文献[20]的方法, 将无法处理不同充放电功率的 EV, 且可能遗漏 SOC 在一个时间步长内跨越多个状态区间进行转移的情况, 导致模型在处理不同功率的 EV 数据时产生较大误差。而文献[22]提出的高阶马尔科夫链虽考虑历史状态, 但忽略了 EV 的跨区间转移情况, 且未结合电池容量与功率特征, 模型准确度不高。因此, 文中在其基础上推导了 EV 充放电功率的概率分布对 SOC 一步转移概率的影响, 并进一步得到多步转移概率。

为便于推导, 假设所有 EV 在充电过程中始终以最大功率进行充电, 并且充电效率为固定值。

分析式(7)可以发现, 当 η_c 已知时, 在 Δt 内, $S(k+1)$ 仅取决于电池容量 C_{EV} 和充电功率 $P_c(k)$, 即在固定的一个时间步长内, EV 充电随机过程只与其电池容量、充电功率有关。因此, 只须对 EV 的

电池容量和充电功率进行统计, 分别得到其概率密度函数, 即可推导得到 EV 充电过程的转移概率。假设参与聚合的 EV 电池容量和充电功率分别服从概率密度分布 $f_c(C_{EV})$ 和 $f_p(P_c)$, 对其进行积分可得到概率分布函数 $F_c(C_{EV})$ 和 $F_p(P_c)$ 为:

$$F_c(C_{EV}) = \int_{-\infty}^{C_{EV}} f_c(C_{EV}) dC_{EV} \quad (8)$$

$$F_p(P_c) = \int_{-\infty}^{P_c} f_p(P_c) dP_c \quad (9)$$

假设 $f_c(C_{EV})$ 和 $f_p(P_c)$ 之间不存在依赖关系, 则二者的联合概率密度函数为:

$$f(C_{EV}, P_c) = f_c(C_{EV}) f_p(P_c) \quad (10)$$

由于 SOC 从当前状态转入下一状态时的概率 $P\{S(k+1)|S(k)\}$ 仅取决于电池容量 C_{EV} 和充电功率 P_c , 因此可以根据联合概率密度函数计算得到转移概率:

$$P\{S(k+1)|S(k)\} = \int_{-\infty}^{C_{EV}} \int_{-\infty}^{P_c} \delta\left(S(k+1) - S(k) - \frac{P_c \eta_c \Delta t}{C_{EV}}\right) f(C_{EV}, P_c) dP_c dC_{EV} \quad (11)$$

式中: δ 为狄拉克函数, 其作用为筛选出满足转移条件的值。

分析可知, 当 $S_{down}(i, j)$ 高于某一临界值时, 经过 Δt 后, EV 从第 i 个大区间中的小区间 j 向第 $i+1$ 个大区间完成转移的概率为 1; 而当 $S_{down}(i, j)$ 低于另一临界值时, 这样的转移发生概率将为 0。由此, 可引入 $S_0(i)$ 和 $S_1(i)$ 两个临界 SOC, 用来对应转移概率为 0 和 1 的 SOC 阈值, 其与 C_{EV} 和 P_c 的上、下限值之间的关系为:

$$\begin{cases} S_0(i) = S_{down}(i+1) - \frac{P_{c,max} \eta_c \Delta t}{C_{min}} \\ S_1(i) = S_{down}(i+1) - \frac{P_{c,min} \eta_c \Delta t}{C_{max}} \end{cases} \quad (12)$$

式中: $P_{c,max}$ 、 $P_{c,min}$ 分别为参与聚合的 EV 中的充电功率最大值和最小值; C_{max} 、 C_{min} 分别为参与聚合的 EV 电池容量最大值和最小值。

k 时刻从第 i 个大区间中的小区间 j 向第 $i+1$ 个大区间转移的概率可表示为:

$$p_{(i,j) \rightarrow i+1}(k) = P\{S(k+1) = S_{down}(i+1) | S(k) = S_{down}(i, j)\} \quad (13)$$

结合以上推导, 可将 $p_{(i,j) \rightarrow i+1}(k)$ 转化为:

$$p_{(i,j) \rightarrow i+1}(k) = \begin{cases} 0 & S_{down}(i, j) < S_0(i) \\ \int_{-\infty}^{C_{EV}} \int_{-\infty}^{P_c} \delta\left(S_{down}(i+1) - S_{down}(i, j) - \frac{P_c \eta_c \Delta t}{C_{EV}}\right) \times \\ f(C_{EV}, P_c) dP_c dC_{EV} & S_0(i) \leq S_{down}(i, j) \leq S_1(i) \\ 1 & S_{down}(i, j) > S_1(i) \end{cases} \quad (14)$$

为得到相邻大区间之间的一步转移概率, 需要对其内部小区间之间的转移概率进行加权求和。因此, 第 i 个大区间和第 $i+1$ 个大区间的一步期望转移概率为:

$$P_{i \rightarrow i+1}(k) = \frac{1}{n_s} \sum_{j=1}^{n_s} p_{(i,j) \rightarrow i+1}(k) \quad (15)$$

进一步考虑 EV 负荷的跨状态区间转移情况, 可以推导得到马尔科夫过程的第 $i-L+1$ 个大区间和第 $i+1$ 个大区间之间的多步转移概率为:

$$P_{i-L+1 \rightarrow i+1}(k) = \prod_{l=1}^L P_{i-l+1 \rightarrow i-l+2}(k) = P_{i \rightarrow i+1}^L(k) \quad (16)$$

式中: L 为多步状态转移马尔科夫链所考虑的前序大区间数目, $1 < L \leq N_s$; $P_{i-l+1 \rightarrow i-l+2}(k)$ 为多步区间中的每一相邻状态区间之间的转移概率。

3.3 EV 充电负荷聚合建模

得到 SOC 大区间的一步和多步转移概率后, 将每个大区间作为离散状态, 便可根据负荷的动态转移过程建立 EV 的充电负荷聚合模型。传统的马尔科夫链只考虑各相邻状态间的一步转移情况, 而文中提出的考虑多步状态转移的马尔科夫链是传统马尔科夫链的拓展, 其具体思想为: 推导 $k+1$ 时刻状态区间 $i+1$ 的负荷数量时, 不仅包含 k 时刻由状态区间 i 转入区间 $i+1$ 的负荷, 还考虑 k 时刻处于区间 $i-L+1 \sim i-1$ 的负荷在 Δt 内跨越多个状态区间直接转移至区间 $i+1$ 的情况, 这使得聚合模型更加精确。基于此, 可知在 Δt 内处于区间 i ($i < N_s$) 的负荷具有 $L+1$ 种转移情况: 维持当前状态区间、转入相邻状态区间 $i+1$ 、...、转入状态区间 $i+L$ (第 N_s 个大区间为充电停止区间, 表示充电完成并退出聚合模型)。

综上所述, 基于多步状态转移马尔科夫链的充电负荷动态转移过程如图 3 所示, 阴影部分代表该区间的 EV 负荷水平。每个状态区间的净负荷变化量为该区间的流入负荷与流出负荷之差, 并考虑 EV 接入与退出充电的外部影响因素。对于状态区间 1, 仅需要计算流出负荷及外部因素导致的负荷变化。




图 3 充电动态负荷转移过程示意
Fig.3 Schematic diagram of the charging dynamic load transfer process

各状态区间内的 EV 负荷动态变化过程如式 (17)、式 (18) 所示。 $i = 1$ 时:

$$\begin{cases} x^c(k+1, 1) = x^c(k, 1) + \Delta x_{\text{out}}^c(k, 1) + W^c(k, 1) \\ \Delta x_{\text{out}}^c(k, 1) = - \sum_{l=1}^L P_{1,1+l} x^c(k, 1) \end{cases} \quad (17)$$

$2 \leq i \leq N_s$ 时:

$$\begin{cases} x^c(k+1, i) = x^c(k, i) + \Delta x_{\text{out}}^c(k, i) + \Delta x_{\text{in}}^c(k, i) + W^c(k, i) \\ \Delta x_{\text{out}}^c(k, i) = - \sum_{l=1}^L P_{i,i+l} x^c(k, i) \\ \Delta x_{\text{in}}^c(k, i) = \sum_{l=1}^L P_{i-l,i} x^c(k, i) \end{cases} \quad (18)$$

式中: $x^c(k+1, i)$ 、 $x^c(k, i)$ 分别为 $k+1$ 时刻和 k 时刻第 i 个区间内的 EV 负荷量; $\Delta x_{\text{out}}^c(k, i)$ 为 k 时刻从第 i 个区间转出的负荷量; $\Delta x_{\text{in}}^c(k, i)$ 为 k 时刻转入第 i 个区间的负荷量; $P_{i,i+l}$ 、 $P_{i-l,i}$ 分别为第 i 个区间与第 $i+l$ 个区间、第 $i-l$ 个区间与第 i 个区间的一步转移概率, 在计算某区间的转出和转入负荷量时, 对一步转移概率进行求和, 从而计算得到多步转移概率; $W^c(k, i)$ 为 k 时刻由于 EV 接入充电和退出充电引起的第 i 个区间的负荷变化量。

对区间 i 转入与转出负荷量进行多概率求和计算, 并将前 L 个状态区间的负荷转移量纳入 EV 负荷动态方程中, 进而实现对单位时间内跨状态转移情况的充分考虑。根据上述动态变化过程的表达式, 最终整理得到 N_s 维 EV 集群充电负荷聚合模型:

$$\begin{cases} \mathbf{x}^c(k+1) = \mathbf{A}^c \mathbf{x}^c(k) + \mathbf{W}^c(k) \\ \mathbf{y}^c(k) = \mathbf{P}^c \mathbf{C}^c \mathbf{x}^c(k) \end{cases} \quad (19)$$

式中: $\mathbf{x}^c(k)$ 为状态向量; $\mathbf{W}^c(k)$ 为外部因素变化向量; $\mathbf{y}^c(k)$ 为聚合模型的输出功率; \mathbf{A}^c 为状态矩阵, 其具体数值可由状态转移概率计算得到; \mathbf{P}^c 为 EV 的充电功率矩阵; \mathbf{C}^c 为包含电池容量信息的输出矩阵。当接收到外部调控指令时, 可对上述模型中的 $\mathbf{W}^c(k)$ 进行控制, 调整各状态区间的 EV 数量, 以改变输出功率 $\mathbf{y}^c(k)$ 。

文中提出的多步状态转移马尔科夫链方法, 通过 EV 充放电功率和电池容量的概率密度函数推导出 SOC 状态区间之间的一步转移概率和多步转移概率, 实现对不同功率和电池容量的多特征 EV 数据的聚合建模。并且, 聚合模型由于考虑多步状态转移情况, 其准确度得到提高, 从而可得到更精确的聚合功率。

4 算例分析

4.1 仿真参数

为构建贴近实际场景的 EV 算例, 文中参考文献

献[34-35]中的出行行为研究成果, 基于统计学方法生成包含工作出行、休闲出行、旅游出行及其他出行 4 种典型出行类型的 5 000 辆 EV 数据样本。

在充电模式设置方面, 考虑到旅游出行场景对充电速度的特殊需求, 将该类型 EV 统一设定为快速充电模式, 其余类型则采用普通充电模式。具体参数设置如表 1 所示。

表 1 仿真参数
Table 1 Simulation parameters

参数符号	参数定义	参数取值
N_{EV}	EV 规模/辆	5 000
$[S_{\min}, S_{\max}]$	SOC 限值	$[0.1, 0.9]$
C_{EV}	电池容量/(kW·h)	$U(30, 40)$
S_{ini}	起始 SOC	$N(0.45, 0.15)$
P_{sc}	普通充电功率/kW	7
P_{fc}	快速充电功率/kW	45
η_c	充电效率/%	95
N_s	马尔科夫链大区数	40
n_s	马尔科夫链小区数	5 000
T_c	分类的时间尺度/min	15
T_A	聚合的时间尺度/min	15

4.2 EV 分类结果分析

4.2.1 基于自适应密度的改进 DBSCAN 聚类结果

为确定 DBSCAN 算法参数, 选取 17:00 典型负荷时刻入网的 1 997 辆工作型 EV 作为研究对象。首先对每个数据点进行 k-dist 计算, 基于计算结果分别绘制 k-dist 曲线与差分 k-dist 曲线, 通过曲线形态分析精准定位拐点与极值点, 进而依据 k-dist 方法完成数据空间的密度区间划分。为便于后续表示, 文中按 k-dist 降序值给 EV 进行 1~1 997 编号。具体结果如图 4 所示。

由图 4(c) 可见, EV 数据被划分为 8 个密度区间, 对每个区间使用 k-dist 方法得到其邻域半径 R_{Eps} , 结果如表 2 所示。

然后, 按表 2 设定每个区间的 R_{Eps} 值, 并按照 DBSCAN 算法的配置要求, 取 $M_{\min Pt}$ 为各区间数据量的 $1/25$ ^[36], 对各区间的 EV 数据均使用 DBSCAN 算法进行聚类。最终, 传统 DBSCAN 和基于自适应密度的改进 DBSCAN 得到的聚类结果对比情况如图 5、图 6 所示。

由图 5 可见, 使用传统 DBSCAN 算法聚类时, EV 数据被划分为 2 个普通类别和 1 个蓝色噪声类别, 其中噪声数据呈现无序渗透状态, 大量分布于常规类别之间, 致使类别边界模糊不清, 难以准确界定各类别的特征范围。




图 4 密度区间划分结果

Fig.4 Results of density interval division

表 2 改进 DBSCAN 区间参数

Table 2 Interval parameters of the improved DBSCAN

编号区间	R_{Eps}	编号区间	R_{Eps}
[0,6]	0.553 0	[1 538,1 590]	1.398 0
[7,41]	0.583 7	[1 591,1 643]	1.496 9
[42,1 488]	0.870 9	[1 644,1 732]	1.595 3
[1 489,1 537]	1.309 0	[1 733,1 997]	2.553 8




图 5 传统 DBSCAN 聚类结果

Fig.5 Clustering results of the traditional DBSCAN

反观改进 DBSCAN 算法的聚类结果, EV 数据被重新划分为 4 个常规类别与 1 个蓝色噪声类别。改进算法不仅增加了聚类类别数量, 且噪声数据被有效分离, 集中分布于远离常规类别的区域, 使得各聚类之间的边界更为清晰。

以上结果表明, 改进 DBSCAN 算法可有效提升对 EV 数据分布特征的识别能力, 避免将大量正常数据误判为噪声数据。在类别划分的合理性与准确性方面, 改进 DBSCAN 算法相较于传统算法




图 6 基于自适应密度的改进 DBSCAN 聚类结果

Fig.6 Clustering results based on the improved DBSCAN with adaptive density

表现出显著优势, 能够更准确地反映 EV 数据的内在分布规律。

对于聚类结果的评价, 目前常用的评价指标主要为 DB(Davies-Bouldin)系数、轮廓系数、CH (Calinski-Harabasz) 分数和邓恩指数等。理想的评价指标应能同时反映同类数据的内聚程度与不同类别间的分离特性。基于此, 文中选取 CH 分数和 DB 系数作为聚类评价指标。根据定义, CH 分数的数值与聚类质量呈显著正相关, 而 DB 系数的数值与聚类质量呈负相关^[37-38]。同时, 对两种聚类生成的噪声点数量进行统计, 具体结果见表 3。

表 3 聚类评价指标结果

Table 3 Results of cluster evaluation indexes

评价指标	传统DBSCAN	改进DBSCAN
CH分数	353.850 5	562.918 5
DB系数	1.939 8	0.981 5
噪声点比例	18.7%	5.2%

通过多维度量化对比可见, 文中提出的改进 DBSCAN 算法较传统算法实现了对 EV 数据聚类性能的巨大提升。具体而言, 改进 DBSCAN 算法的 CH 分数较传统算法有大幅提高, 验证了簇类紧凑性与簇间分离度的双重优化; 同时, DB 系数降低至传统算法的近 50%, 表明簇类重叠度显著降低; 在噪声点比例方面, 改进聚类得到的噪声点比例仅为 5.2%, 较传统聚类下降 72.2%, 解决了传统全局参数对多密度 EV 数据的误判问题。这些指标的显著变化充分说明, 改进 DBSCAN 算法在处理 EV 数据时能够实现更精准的聚类划分。

4.2.2 基于增量式聚类的改进 DBSCAN 聚类结果

为研究增量式 DBSCAN 算法在动态数据环境下的聚类性能, 文中选取电网负荷高峰时段内相邻时间节点的数据进行对比分析。在前期完成

17:00 时刻 EV 数据聚类研究的基础上, 进一步采集 17:15 时刻新接入电网的 EV 数据, 使用增量式 DBSCAN 算法对其进行聚类, 结果如图 7 所示。




图 7 基于增量式的改进 DBSCAN 聚类结果

Fig.7 Clustering results of the improved DBSCAN based on incremental clustering

具体 17:00 时刻和 17:15 时刻的聚类数据情况如表 4 所示。

表 4 17:00 和 17:15 两时刻聚类结果对比
Table 4 Comparison of clustering results at 17:00 and 17:15

参数	17:00	17:15
类别数	5	5
类别1的EV数	11	14
类别2的EV数	91	108
类别3的EV数	831	829
类别4的EV数	1 026	1 031
类别5的EV数	38	69
总在网EV数	1 997	2 051

分析表 4 可知, 两相邻时刻的聚类类别数均为 5, 与 17:00 时刻相比, 17:15 时刻的入网 EV 总数略有增加, 且各类别的 EV 增加数接近。通过对比图 7 与图 6 的聚类结果可知, 在 17:15 时刻, 电网中新接入的 EV 仅引发少部分数据样本的类别归属变化, 整体聚类类别数量保持不变。

进一步从计算效率维度进行量化分析, 若采用传统全量数据重新聚类方法, 对 17:15 时刻所有 EV 数据进行处理须耗时 10.529 7 s; 而采用增量式 DBSCAN 聚类算法仅需 2.390 6 s 即可完成相同任务。对比结果显示, 增量式聚类算法在处理动态数据时, 将计算耗时缩短至原方法的 22.7%, 显著提升了数据处理效率, 有效降低了算法的时间复杂度。

4.3 EV 聚合结果分析

为验证文中所提聚合方法的有效性, 选取最有代表性的工作出行、旅游出行 EV 中不同规模的集

群, 分别采用蒙特卡洛模拟、传统马尔科夫链以及文中提出的聚合方法对各类集群进行聚合建模。3 种方法生成的聚合功率曲线如图 8、图 9 所示。




图 8 工作出行类别下不同规模 EV 集群的充电
负荷聚合功率曲线

Fig.8 Aggregated charging power curves of EV clusters with different sizes under the commuting travel category




图 9 旅游出行类别下不同规模 EV 集群的充电
负荷聚合功率曲线

Fig.9 Aggregated charging power curves of EV clusters with different sizes under the tourism travel category

分析图 8、图 9 可知, 相较于文献[20]的传统马尔科夫链方法, 文中提出的多步状态转移马尔科夫链方法在处理不同分布规律、不同规模数量的 EV 数据时均展现出显著优势。所提方法生成的功率曲线与蒙特卡洛模拟法的结果高度吻合, 二者在趋势一致性与数值接近度方面均表现优异。

为对聚合效果进行定量分析, 文中引入均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)和决定系数 R^2 等 3 种精度指标, 其中, RMSE 和 MAE 越低, R^2 越接近 1, 模型的精度将越高。分别计算图 8、图 9 中的指标数值, 具体结果如表 5 所示。

表 5 聚合模型精度指标结果对比
Table 5 Comparison of accuracy metrics for aggregated models

出行类型	聚合方法	EV 集群规模	指标		
			RMSE	MAE	R^2
工作出行	传统马尔科夫	大集群	68.87	35.095	0.985 3
	文中所提方法	大集群	18.257	12.879	0.992 9
	传统马尔科夫	小集群	65.072	34.893	0.987 4
	文中所提方法	小集群	17.478	11.690	0.993 8
旅游出行	传统马尔科夫	大集群	112.816	68.049	0.970 2
	文中所提方法	大集群	20.309	13.544	0.990 1
	传统马尔科夫	小集群	110.213	67.076	0.973 9
	文中所提方法	小集群	19.877	13.028	0.992 3

分析表 5 可知,文中所提方法通过引入多步状态转移机制,对不同出行规律、不同规模的 EV 集群都可有效降低建模误差。常规工作出行的 EV 集群由于较少使用快充,相较于传统马尔科夫链方法,采用文中所提方法的提升效果不是十分显著。而对于旅游出行的 EV 集群,特别是实验中的旅游出行 EV 小集群,与传统马尔科夫链方法相比, RMSE 由 110.213 降低至 19.877, MAE 由 67.076 降至 13.028, R^2 由 0.973 9 提升至 0.992 3。这是因为旅游出行 EV 中快充模式使用的比例较高,多步状态转移机制能够有效捕捉高功率充放电过程中 SOC 的跨区间转移情况,从而显著提高模型精度。上述结果表明,文中提出的多步状态转移马尔科夫链方法能够更精准地描述 EV 充电行为的动态演变过程,为后续 EV 辅助电网动态调控提供更可靠的依据。

为进一步分析双层离散化区间设置方式对模型精度、计算效率的影响,设计 4 种不同大、小区间组合方式对同一 EV 集群进行建模,得到聚合功率曲线如图 10 所示。

在图 10 所示 4 种区间组合方式下使用文中所提方法进行聚合建模,得到的精度数据及聚合所耗时间结果如表 6 所示。

分析图 10 和表 6 可知,在总区间数保持一致的条件下,大区间与小区间的划分比例对模型精度影响无显著差异。然而,随着大区间数量 N_s 的增加,聚合计算耗时呈显著增长趋势,这表明大区间数量是影响聚合计算效率的关键因素。因此,文中所采用的双层离散化 SOC 区间划分策略通过减少大区间数量并相应增加小区间数量的方式,在保证模型精度的前提下有效规避了“维数爆炸”问题,实现计算效率与建模精度的协同优化。

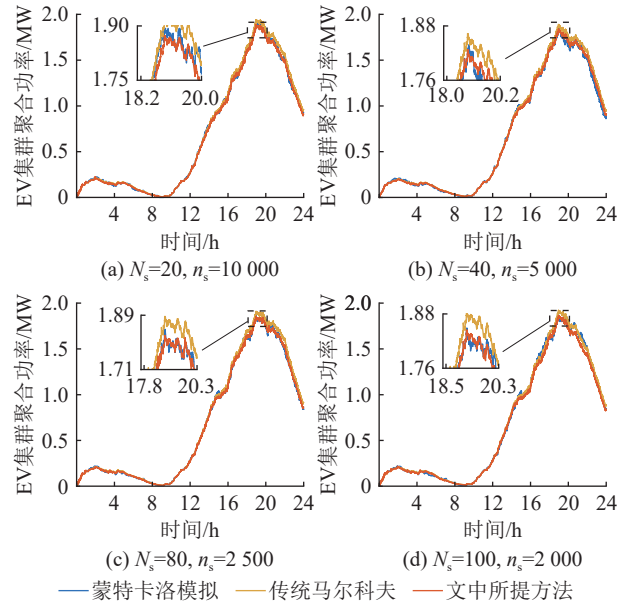


图 10 不同大、小区间数量下 EV 集群
充电负荷聚合功率曲线

Fig.10 Aggregated charging power curves of EV clusters under different numbers of macro and micro intervals

表 6 4 种区间组合方式的聚合指标结果对比

Table 6 Comparison of aggregation performance metrics under four interval configuration methods

区间组合方式	RMSE	MAE	R^2	耗时/s
$N_s=20, n_s=10\ 000$	18.741	13.383	0.990 4	4.515 3
$N_s=40, n_s=5\ 000$	18.257	12.879	0.992 9	10.260 1
$N_s=80, n_s=2\ 500$	17.580	12.012	0.993 6	23.072 2
$N_s=100, n_s=2\ 000$	18.394	12.982	0.993 1	30.751 0

5 结论

针对大规模 EV 接入电网辅助调控时处理速度慢、精度低等问题,提出一种基于改进 DBSCAN 的动态分类和多步马尔科夫链 EV 集群聚合方法。通过算例分析,得出如下结论:

(1) 基于自适应密度的改进增量式 DBSCAN 算法,在改善 EV 数据聚类效果的同时,将 EV 聚类时间从 10.529 7 s 缩减至 2.390 6 s,显著提高了对大规模 EV 的聚类速度。

(2) 使用考虑多步状态转移的马尔科夫链对 EV 负荷进行聚合建模,得到 EV 集群聚合模型和聚合功率。分析表明,与传统马尔科夫链方法相比,所提模型的聚合功率曲线与蒙特卡洛模拟结果表现出更高的吻合度。

(3) 文中提出的 EV 聚类-聚合方法能够解决大规模 EV 接入电网时存在的难以控制、模型精度低、处理速度慢等问题。

文中使用的 EV 数据是基于概率密度统计的结

果, 后续工作可使用实际采集数据进行进一步分析。

致 谢

本文得到河北省在读研究生创新能力培养项目(CXZZBS2025192)资助, 谨此致谢!

参考文献:

- [1] 李明, 常永康, 毛永涛, 等. 高渗透率新能源发电并网变流器跟网/构网型稳定控制技术综述与展望[J]. 高电压技术, 2024, 50(11): 4773-4788.
LI Ming, CHANG Yongkang, MAO Yongtao, et al. Review and prospect of stability control techniques for grid-following/grid-forming converters in high-penetration renewable energy generation[J]. High Voltage Engineering, 2024, 50(11): 4773-4788.
- [2] 侯慧, 王治华, 侯婷婷, 等. 电动汽车虚拟储能支撑的多元调峰辅助服务优化[J]. 中国电机工程学报, 2024, 44(S1): 168-179.
HOU Hui, WANG Zhihua, HOU Tingting, et al. Optimization of multi-element peak regulation auxiliary service supported by electric vehicle virtual energy storage[J]. Proceedings of the CSEE, 2024, 44(S1): 168-179.
- [3] 沙广林, 刘璐, 马春艳, 等. 考虑车网互动的电动汽车有序充电策略[J]. 供用电, 2023, 40(10): 46-54.
SHA Guanglin, LIU Lu, MA Chunyan, et al. Orderly charging strategy for electric vehicles considering the vehicle-network interaction[J]. Distribution & Utilization, 2023, 40(10): 46-54.
- [4] 侯慧, 何梓烟, 侯婷婷, 等. 大规模车网互动需求响应策略及潜力评估综述[J]. 电力系统保护与控制, 2024, 52(14): 177-187.
HOU Hui, HE Ziyin, HOU Tingting, et al. A review of demand response strategies and potential evaluation for large-scale vehicle to grid[J]. Power System Protection and Control, 2024, 52(14): 177-187.
- [5] 刘嘉彦, 李祖坤, 李畅, 等. 电动汽车与电力-交通耦合网互动: 综述与展望[J]. 电力科学与技术学报, 2024, 39(5): 12-24.
LIU Jiayan, LI Zukun, LI Chang, et al. Interaction between electric vehicles and power-transportation coupled networks: current status, challenges and development trends[J]. Journal of Electric Power Science and Technology, 2024, 39(5): 12-24.
- [6] SALMAN S, XIN A, MASOOD A, et al. Overview of storage system and EV aggregation charging behavior in energy market[C]//2018 2nd IEEE Conference on Energy Internet and Energy System Integration (EI2). Beijing, China. IEEE, 2018: 1-4.
- [7] ABO-ELYOUSR F K, SHARAF A M, DARWISH M M F, et al. Optimal scheduling of DG and EV parking lots simultaneously with demand response based on self-adjusted PSO and K-means clustering[J]. Energy Science & Engineering, 2022, 10(10): 4025-4043.
- [8] 陈忠华, 朱军, 王育飞, 等. 基于一致性 K 均值聚类的电动汽车充电负荷建模方法[J]. 现代电力, 2022, 39(3): 338-348.
CHEN Zhonghua, ZHU Jun, WANG Yufei, et al. A modeling method for electric vehicle charging load based on consensus K-means clustering[J]. Modern Electric Power, 2022, 39(3): 338-348.
- [9] 金永天, 谢俊, 周翠玉, 等. 基于 IFCM 算法的电动汽车群聚合调峰方法[J]. 高电压技术, 2024, 50(7): 3080-3089.
JIN Yongtian, XIE Jun, ZHOU Cuiyu, et al. Peak-regulating method of aggregating electric vehicle groups based on IFCM algorithm[J]. High Voltage Engineering, 2024, 50(7): 3080-3089.
- [10] 王杨洋, 茆美琴, 杨铖, 等. 面向多场景辅助服务的大规模电动汽车聚合可调度容量建模[J]. 电力系统自动化, 2024, 48(7): 103-115.
WANG Yangyang, MAO Meiqin, YANG Cheng, et al. Aggregated and schedulable capacity modeling of large-scale electric vehicles for multi-scenario auxiliary services[J]. Automation of Electric Power Systems, 2024, 48(7): 103-115.
- [11] JIN Y W, YU B, SEO M, et al. Optimal aggregation design for massive V2G participation in energy market[J]. IEEE Access, 2020, 8: 211794-211808.
- [12] ZHANG T Y, CHEN X, YU Z, et al. A Monte Carlo simulation approach to evaluate service capacities of EV charging and battery swapping stations[J]. IEEE Transactions on Industrial Informatics, 2018, 14(9): 3914-3923.
- [13] KIM S, HUR J. A probabilistic modeling based on Monte Carlo simulation of wind powered EV charging stations for steady-states security analysis[J]. Energies, 2020, 13(20): 5260.
- [14] 于海东, 张焰, 潘爱强. 电动私家车充电负荷中长期推演模型[J]. 电力系统自动化, 2019, 43(21): 80-87.
YU Haidong, ZHANG Yan, PAN Aiqiang. Medium- and long-term evolution model of charging load for private electric vehicle[J]. Automation of Electric Power Systems, 2019, 43(21): 80-87.
- [15] 余洋, 王紫阳, 张瑞丰, 等. 基于 VMD 和 MPC 的电动汽车-火电机联合调频控制[J]. 电力工程技术, 2023, 42(2): 29-39.
YU Yang, WANG Ziyang, ZHANG Ruifeng, et al. Combined frequency regulation control of electric vehicles and thermal power units based on VMD and MPC[J]. Electric Power Engineering Technology, 2023, 42(2): 29-39.
- [16] 艾欣, 赵阅群, 周树鹏. 适应清洁能源消纳的配电网集群电动汽车充电负荷模型与仿真研究[J]. 中国电力, 2016, 49(6): 170-175.
AI Xin, ZHAO Yuequn, ZHOU Shupeng. Study on aggregate electric vehicle charging load model and simulation for clean energy accommodation in distribution network[J]. Electric Power, 2016, 49(6): 170-175.
- [17] ESMAEIL ZADEH SOUDJANI S, ABATE A. Aggregation and control of populations of thermostatically controlled loads

- by formal abstractions[J]. *IEEE Transactions on Control Systems Technology*, 2014, 23(3): 975-990.
- [18] MATHIEU J L, KOCH S, CALLAWAY D S. State estimation and control of electric loads to manage real-time energy imbalance[J]. *IEEE Transactions on Power Systems*, 2013, 28(1): 430-440.
- [19] 王永权, 张沛超, 姚焱. 聚合大规模空调负荷的信息物理建模与控制方法[J]. *中国电机工程学报*, 2019, 39(22): 6509-6521.
- WANG Yongquan, ZHANG Peichao, YAO Yao. Cyber-physical modeling and control method for aggregating large-scale ACLs[J]. *Proceedings of the CSEE*, 2019, 39(22): 6509-6521.
- [20] 董锴, 蔡新雷, 崔艳林, 等. 基于马尔科夫链的电动汽车聚合建模及多模式调频控制策略[J]. *电网技术*, 2022, 46(2): 622-634.
- DONG Kai, CAI Xinlei, CUI Yanlin, et al. Aggregation modeling based on Markov chain and multi-mode control strategies of aggregated electric vehicles for frequency regulation[J]. *Power System Technology*, 2022, 46(2): 622-634.
- [21] 蔡新雷, 董锴, 崔艳林, 等. 基于马尔科夫链理论的电动汽车集群充电负荷建模及可调能力评估[J]. *南方电网技术*, 2023, 17(9): 29-37.
- CAI Xinlei, DONG Kai, CUI Yanlin, et al. Charging load modeling and dispatchable capability evaluation of electric vehicle cluster based on Markov chain theory[J]. *Southern Power System Technology*, 2023, 17(9): 29-37.
- [22] 刘航, 申皓, 杨勇, 等. 基于高阶马尔科夫链的纯电重卡集群负荷预测[J]. *中国电力*, 2024, 57(5): 61-69.
- LIU Hang, SHEN Hao, YANG Yong, et al. Load forecast of electric trucks aggregation based on higher-order Markov chains[J]. *Electric Power*, 2024, 57(5): 61-69.
- [23] 刘畅, 郑涛, 王志华, 等. 基于 DBSCAN 的智能变电站交流采样异常实时识别算法[J]. *电力系统保护与控制*, 2024, 52(24): 140-148.
- LIU Chang, ZHENG Tao, WANG Zhihua, et al. Algorithm for real-time identification of sampling abnormalities in smart substations based on DBSCAN[J]. *Power System Protection and Control*, 2024, 52(24): 140-148.
- [24] AREF Y, CEMAL K, ASEF Y, et al. Automatic fuzzy-DBSCAN algorithm for morphological and overlapping datasets[J]. *Journal of Systems Engineering and Electronics*, 2020, 31(6): 1245-1253.
- [25] 张夏韦, 梁军, 王要强, 等. 电动汽车充电负荷时空分布预测研究综述[J]. *电力建设*, 2023, 44(12): 161-173.
- ZHANG Xiawei, LIANG Jun, WANG Yaoqiang, et al. Overview of research on spatiotemporal distribution prediction of electric vehicle charging[J]. *Electric Power Construction*, 2023, 44(12): 161-173.
- [26] 田立亨, 史双龙, 贾卓. 电动汽车充电功率需求的统计学建模方法[J]. *电网技术*, 2010, 34(11): 126-130.
- TIAN Liting, SHI Shuanglong, JIA Zhuo. A statistical model for charging power demand of electric vehicles[J]. *Power System Technology*, 2010, 34(11): 126-130.
- [27] 李特, 王荣喜, 高建民. 风电机组数据采集与监控系统异常数据识别方法[J]. *西安交通大学学报*, 2024, 58(3): 106-116.
- LI Te, WANG Rongxi, GAO Jianmin. A method for abnormal data recognition of wind turbine supervisory control and data acquisition systems[J]. *Journal of Xi'an Jiaotong University*, 2024, 58(3): 106-116.
- [28] 黄珍瑶, 程诺, 江岳文. 考虑 EV 调峰需求响应可靠性的 V2G 聚合商多时间尺度调度策略[J]. *高电压技术*, 2025, 51(1): 401-411.
- HUANG Zhenyao, CHENG Nuo, JIANG Yuewen. Multi-time-scale scheduling strategy of V2G aggregators considering EV peak regulating demand response reliability[J]. *High Voltage Engineering*, 2025, 51(1): 401-411.
- [29] 赵燚, 杨俊丰, 庞建霞, 等. 考虑混合储能主动参与风光储电站的功率分配与调频策略[J]. *电力建设*, 2024, 45(7): 144-155.
- ZHAO Yi, YANG Junfeng, PANG Jianxia, et al. Power-distribution and frequency-regulation strategies for wind-solar power stations actively supported by hybrid-energy storage[J]. *Electric Power Construction*, 2024, 45(7): 144-155.
- [30] 鲍志远, 胡泽春. 大规模电动汽车充换电设施可调能力聚合评估与预测[J]. *中国电机工程学报*, 2025, 45(11): 4103-4117.
- BAO Zhiyuan, HU Zechun. Aggregated assessment and prediction of adjustable capacity for large-scale electric vehicle charging and battery swapping facilities[J]. *Proceedings of the CSEE*, 2025, 45(11): 4103-4117.
- [31] 刘峻岐, 蒋姝俊, 王照琪, 等. 基于时空耦合关联分析的电动汽车集群可调度能力评估[J]. *电力建设*, 2021, 42(12): 83-92.
- LIU Junqi, JIANG Shujun, WANG Zhaoqi, et al. Dispatchable capability of eclectic vehicle clusters considering temporal-spatial characteristics[J]. *Electric Power Construction*, 2021, 42(12): 83-92.
- [32] KUMAR R R, BHARATIRAJA C, UDHAYAKUMAR K, et al. Advances in batteries, battery modeling, battery management system, battery thermal management, SOC, SOH, and charge/discharge characteristics in EV applications[J]. *IEEE Access*, 2023, 11: 105761-105809.
- [33] HAN X J, WEI Z X, HONG Z P, et al. Ordered charge control considering the uncertainty of charging load of electric vehicles based on Markov chain[J]. *Renewable Energy*, 2020, 161: 419-434.
- [34] 吴赋章, 杨军, 林洋佳, 等. 考虑用户有限理性的电动汽车时空行为特性[J]. *电工技术学报*, 2020, 35(7): 1563-1574.

- WU Fuzhang, YANG Jun, LIN Yangjia, et al. Research on spatiotemporal behavior of electric vehicles considering the users' bounded rationality[J]. Transactions of China Electrotechnical Society, 2020, 35(7): 1563-1574.
- [35] 盛裕杰, 郭庆来, 刘梦洁, 等. 多源数据融合的用户充电行为分析与充电设施规划实践[J]. 电力系统自动化, 2022, 46(12): 151-162.
- SHENG Yujie, GUO Qinglai, LIU Mengjie, et al. User charging behavior analysis and charging facility planning practice based on multi-source data fusion[J]. Automation of Electric Power Systems, 2022, 46(12): 151-162.
- [36] 陈仕龙, 吴涛, 郭成, 等. 基于 DBSCAN 聚类 and 区间回归的多谐波责任划分[J]. 中国电力, 2024, 57(2): 138-148.
- CHEN Shilong, WU Tao, GUO Cheng, et al. Division of multi-harmonic responsibilities based on DBSCAN clustering and interval regression[J]. Electric Power, 2024, 57(2): 138-148.
- [37] 余浩, 高懿滴, 潘险险, 等. 基于改进高斯混合模型的变电站负荷聚类算法[J]. 全球能源互联网, 2024, 7(5): 591-601.
- YU Hao, GAO Yihao, PAN Xianxian, et al. Substation load clustering algorithm based on improved Gaussian mixture model[J]. Journal of Global Energy Interconnection, 2024, 7(5): 591-601.
- [38] 姚明明, 张新, 杨培宏, 等. 基于改进风光场景聚类联合虚拟储能的源网荷储低碳优化调度[J]. 电力系统保护与控制, 2024, 52(15): 115-130.
- YAO Mingming, ZHANG Xin, YANG Peihong, et al. Low-carbon optimal scheduling of source-grid-load-storage based on improved wind-solar scene clustering combined with virtual energy storage[J]. Power System Protection and Control, 2024, 52(15): 115-130.

作者简介:



余洋

余洋(1982), 男, 博士, 教授, 研究方向为储能技术、柔性负荷建模及调度(E-mail: ncepu_yy@163.com);

钱学尧(2001), 男, 硕士在读, 研究方向为电动汽车优化调度;

陈晓(1999), 男, 硕士在读, 研究方向为储能系统的电能分配。

Dynamic classification and multi-feature online aggregation method for electric vehicles oriented to V2G

YU Yang^{1,2}, QIAN Xueyao^{1,2}, CHEN Xiao^{1,2}, LÜ Chenrui^{1,2}, WANG Yan^{1,2}

(1. North China Electric Power University (Baoding) (State Key Laboratory of New Energy Power System), Baoding 071003, China; 2. North China Electric Power University (Baoding) (Key Laboratory of Distributed Energy Storage and Microgrid in Hebei Province), Baoding 071003, China)

Abstract: To address the issues of slow processing speed and low accuracy when a large number of electric vehicles (EVs) are integrated into the power grid under vehicle-to-grid (V2G) scenarios, a dynamic EV classification and multi-step Markov chain aggregation method based on a density-based spatial clustering of applications with noise (DBSCAN) algorithm is proposed. In the classification phase, the DBSCAN algorithm is improved using the k-distance curve and its differential form, and the concept of incremental clustering is introduced to dynamically classify EV data, resulting in EV clusters characterized by multi-dimensional features such as state of charge (SOC), remaining connection time, and controllable capacity. In the aggregation phase, a multi-step state transition Markov chain theory is developed to construct online aggregation models for each EV cluster. This approach addresses the limitations of traditional Markov chains in handling multi-feature EV aggregation and improves the accuracy of the aggregated power output. Simulation results demonstrate that the proposed classification method can quickly and accurately partition large-scale EVs integrated into the grid into different clusters, and that the aggregation model significantly improves the accuracy of aggregate power estimation, effectively addressing the challenges associated with large-scale EV integration.

Keywords: electric vehicle (EV); vehicle-to-grid (V2G); density-based spatial clustering of applications with noise (DBSCAN); Monte Carlo simulation; multi-step Markov Chain; aggregation model

(编辑 陆海霞)