

智慧园区电动汽车有序共享充电需求分析^①



石进永^{1,2}, 赵明宇^{1,2}, 汪映辉^{1,2}

¹(南瑞集团(国网电力科学研究院)有限公司, 南京 211106)

²(国电南瑞南京控制系统有限公司, 南京 211106)

通讯作者: 石进永, E-mail: 1827591386@qq.com

摘要: 针对智慧园区充电设施少不能满足电动汽车发展需求问题, 提出一种适用于智慧园区电动汽车有序共享充电需求建模分析方法, 通过分析充电数据提供充电计划, 并辅助园区能量管理系统制定有序充电策略. 利用功率谱密度估计方法统计分析单个 EV 充电电流, 并通过人工智能网络完成 EV 在线识别分类工作, 基于插入时间、能量和工作日之间的相关性统计分析每个 EV 充电习惯, 利用测量电网侧的电流来预测充电需求, 基于核密度估计建立充电需求统计模型. 通过某住宅小区充电设施采集的实际数据验证该模型精度的有效性和适用性, 为智能园区电动汽车充电提供帮助.

关键词: 电动汽车; 共享充电; 能量管理系统; 在线识别; 特征空间

引用格式: 石进永, 赵明宇, 汪映辉. 智慧园区电动汽车有序共享充电需求分析. 计算机系统应用, 2021, 30(1): 235-242. <http://www.c-s-a.org.cn/1003-3254/7746.html>

Orderly Shared Charging Demand Analysis for Electric Vehicles in Intelligent Park

SHI Jin-Yong^{1,2}, ZHAO Ming-Yu^{1,2}, WANG Ying-Hui^{1,2}

¹(NARI Group Corporation (State Grid Electric Power Research Institute), Nanjing 211106, China)

²(NARI-Tech Control System Co. Ltd., Nanjing 211106, China)

Abstract: In view of the problem that charging facilities in intelligent park cannot meet the development demand of electric vehicles, a modeling and analysis method suitable for orderly shared charging demand of electric vehicles in intelligent park is proposed. Charging plans are provided by analyzing charging data, and orderly charging strategies are formulated in the energy management system of the park. Power spectral density estimation method using statistical analysis of single EV charging current, and complete EV on-line identification in artificial intelligence network classification work, based on the correlation between insertion time, energy, and working day statistical analysis each EV charging habits, the grid side current is measured using to predict the charging demand, based on kernel density estimate charging demand statistics model is set up. The validity and applicability of the model are verified by the actual data collected from a charging facility in a residential area, which can provide help for EV charging in the intelligent park.

Key words: electric vehicle; charge share; energy management systems; on-line identification; feature space

电动汽车是当下新能源产业重要组成部分, 是缓解能源危机及环境问题的有效工具^[1,2]. 目前, 我国在电动汽车充换电设施标准体系建设、关键技术研究、关键设备研制和示范工程建设等方面已取得重要进展.

但同时, 我国当前普遍应用的电动汽车充电系统无法满足用户个性化充电需求. 因此, 通过对电动汽车充电技术的不断创新和优化, 采取科学合理的控制策略, 可以改善整体电力系统管理和能源效率, 同时也可以使

① 基金项目: 国家电网公司总部科技项目 (5418-201971184A-0-0-00)

Foundation item: Science and Technology Project of Headquarter of State Grid (5418-201971184A-0-0-00)

收稿时间: 2020-05-30; 修改时间: 2020-06-23; 采用时间: 2020-07-07; csa 在线出版时间: 2020-12-31

电力系统的运行更加清洁、高效和经济^[3,4]。

智慧园区能源管理和配置问题分析是掌握用户和电力市场的重要手段,尤其随着充电设施的广泛接入,更需要优化配置智慧园区能源形式.文献[5]为了充分利用电力大数据中的异构数据源挖掘出电网中存在的安全威胁,采用循环神经网络对得到的嵌入式向量数据建立画像,实现了数据中异常事件的检测;文献[6]提出一种面向电动汽车、快速充电站、配电网多元需求的电动汽车快速充电引导策略;文献[7]基于电动汽车充放电优化模型以及实时更新的配电系统预测负荷曲线,构造出动态分时电价更新策略;文献[8]提出基于不确定性测度的居民小区电动汽车充电定价策略并建立起电动汽车充电负荷动态概率模型,分析了电动汽车响应分时电价的不确定性而导致的居民负荷随机波动加剧等问题.文献[9]提出一种在线控制和离线优化相结合的有序充电控制方法,在电动汽车用户在住宅区利用夜晚时段进行充电的情况下,解决了移峰填谷、减少负荷波动的问题.

上述文献对电动汽车充电方式及策略研究较深入,但缺乏智慧园区电动汽车有序共享充电需求及管理模式研究.基于此,本文利用电动汽车(Electric Vehicles, EV)潜在的移动储能特性,提出一种适用于智慧园区共享充电桩的在线自主充电需求建模分析方法,在自动检测和识别用户电动汽车充电需求基础上,将其转移至电价较低时段以加强对住宅小区电力需求的管理.首先提出一种在线识别不同类型电动汽车的方法,采用基于人工神经网络监督学习方法分类得出每个电动汽车类别信息,并用支持向量机(Support Vector Machines, SVM)方法验证所提方法的可行性;其次,根据分类信息利用功率谱密度估计为每个EV提供统计模型,进行统计分析;最后根据台区接收的日前负荷响应指令预测充电需求,对充电习惯采用核密度估计建模,利用实测数据证明该方法的可行性和有效性.

1 智慧园区 EV 共享充电场景分析

依据园区已有能量管理系统(Energy Management Systems, EMS)需求响应策略,在确保用户舒适度的前提下,实现共享充电^[10],图1展现一个典型的园区EV调度场景.车主进入园区后,EMS确定该EV及充电需求后,根据来自其他EV、电器和电价等信息制定该EV充电计划.

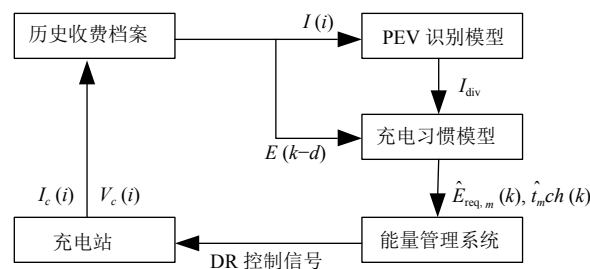


图1 智慧园区 EV 典型充电场景

假设该园区已建 M 个共享充电桩,第 m 个 EV 最佳充电起始时间 $t_{st,m}$ 取决于其充电所需电量 $E_{req,m}$ 和对应充电桩可用时间 $t_{av,m}$. EMS 可以利用每个 EV 充电习惯统计建模,预测充电电量需求和高峰时段负荷优先级.

设 $E_{req}(T)$ 为某天充电站所需总能量, T 表示 24 小时.

$$E_{req}(T) = \sum_{m=1}^M E_{req,m}(T) \quad (1)$$

$$E_{req,m}(i) = \sum_{i=0}^T P_m(i)\Delta t \quad (2)$$

其中, $E_{req,m}(i)$ 为当天第 m 个 EV 充电所需电量; $P_m(i)$ 为第 m 个 EV 瞬时充电功率; Δt 为时间步长.

$$P_m(i) = V(i)I_m(i) \cos(\phi_m(i)) \quad (3)$$

其中, $V(i)$ 为时段 i 处的充电点电压, $I_m(i)$ 为充电点电流的测量值, $\cos(\phi_m(i))$ 为功率因数.

EMS 的目标是估测 $E_{req,m}(i+p)$, 其中 p 是预测范围 ($p > 0$). 假设 Δt 和 $V(i)$ 是常数, 因此该问题可简化为预测 $I_m(i)$ 的任何可能值. 这主要取决于第 m 辆 EV 的充电计划、电池容量以及电池初始充电状态(State of charge, SOC) $SOC_{ini,m}$. 对于一个共享充电站, 如何用当前测量值来预测未来 $E_{req,m}$ 值是一个挑战. 本文采用两步法来解决该问题: 第 1 步识别每个单独 EV 充电情况; 第 2 步建立并更新之前识别的每个 EV 充电模式统计模型. 通过提出的 EV 识别算法来支持 EMS 的最终目标或功能. 通过这种方式, 可以预测每辆车的充电需求, 从而优化充电策略.

2 EV 充电识别模型

模式识别和数据分类过程在各个领域一直都引起广泛关注^[11]. 在本文中, 共享充电站下的 EV 充电识别问题是使用小样本电流测量对 M 辆 EV 充电配置进行

分类. 这种识别 EV 的方法不需要任何额外昂贵的安装费用. 然而, 由于在相同的电池容量范围内, EV 充电电流幅值有明显的相似性, 这也带来了一个很大的挑战. 用于 EV 识别方法分两步, 第 1 步是提取和选择交流充电电流原始样本特征, 旨在创建有区别的特性, 帮助提供更有用的分类; 第 2 步是对候选车辆充电曲线的电流幅值进行分类^[12]. I_{div} 是充电识别后的分类电流幅值.

2.1 信号特征提取

识别过程为了避免共享充电桩混淆不同车辆, 需要算法足够精确可靠, 需要从原始的充电电流测量中提取有用的识别特征, 以便在相同的电池容量范围内对不同的车辆分类正确. 基于输入信号的不同物理性质, 选用的信号特征也不同, 在时域中常用的特征是一阶统计量和高阶统计量; 在频域中常用的特征包括小波系数、FFT 和功率谱密度. 因此需要选择一个包括丰富信息的特征空间, 通过图 2 所示的序列前向选择法选择最优特征.

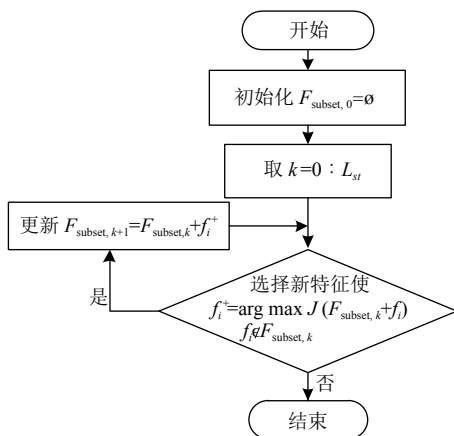


图 2 序列前向选择特征

序列前向选择法从空集开始, 每次选择一个新的特征 f_i^+ 加入特征子集 $F_{subset, k}$ 使特征函数 $J(F_{subset, k}+f_i)$ 最优化, 得到的特征子集就是最佳分类^[13]. 针对智慧园区共享充电需求分析, 需考虑尽可能多的充电特征, 因此选取一组 12 阶的特征向量, 见式 (4)、式 (5), 其中包括原始样本、Welch 功率谱密度估计、Thomson 功率谱密度估计、标准差、偏度、第 6 个非中心矩以及用离散小波变换从测量样本中提取的 3 个不同分辨率信号的标准差, 并选择了最常用的哈尔特征.

$$F^{init} = [F_1, F_2, \dots, F_{12}] \quad (4)$$

$$\begin{cases} F_1 = Rwdata = [f_{11}, f_{12}, \dots, f_{1N}] \\ F_2 = PSD_W = [f_{21}, f_{22}, \dots, f_{2N}] \\ F_3 = PSD_T = [f_{31}, f_{32}, \dots, f_{3N}] \\ F_4 = \sigma^{rw} = f_4 \\ F_5 = s = f_5 \\ F_6 = t_6 = f_6 \\ F_7 = \sigma_{d1}^{WT} = f_7 \\ F_8 = \sigma_{d1}^{WT} = f_8 \\ F_9 = \sigma_{d2}^{WT} = f_9 \\ F_{10} = \sigma_{d2}^{WT} = f_{10} \\ F_{11} = \sigma_{d3}^{WT} = f_{11} \\ F_{12} = \sigma_{d3}^{WT} = f_{12} \end{cases} \quad (5)$$

其中, σ^{rw} 是测量样品的偏度; $Rwdata$ 为交流充电电流的原始样品; PSD_W 和 PSD_T 分别为 Welch 功率谱密度估计和 Thomson 功率谱密度估计; s 为测量样品的标准偏差; t_6 是第 6 个非中心时刻; σ_{di}^{WT} 和 σ_{di}^{WT} 分别是第 i 级标准差的小波分解近似系数和细节系数.

2.2 用于 EV 识别分类方法

2.2.1 前馈神经网络

前馈神经网络是模式分类任务中最常用的一类神经网络^[14]. 本文所使用的网络拓扑结构为两层前馈神经网络, 如图 3 所示.

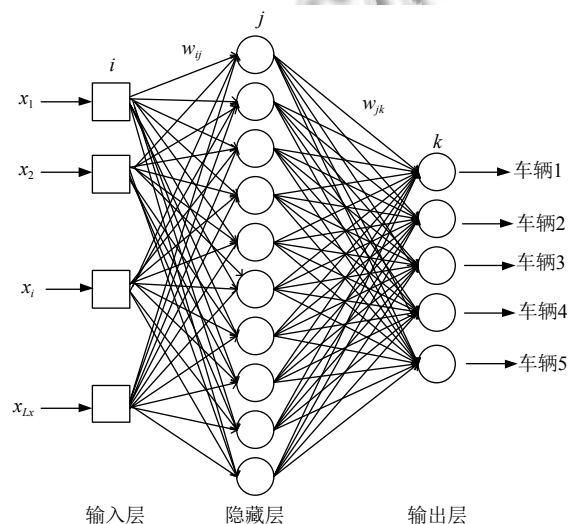


图 3 两层前馈网络拓扑图

在隐藏层中, 激活函数 Z_j 和非线性激活函数 σ_j 分别由式 (6) 和式 (7) 定义. 所使用的非线性激活函数为 Sigmoid 函数.

$$Z_j = \sum_{i=1}^{L_x} w_{ij} \cdot x_i + b_j \quad (6)$$

$$\sigma_j(Z_j) = \frac{1}{1 + e^{-Z_j}} \quad (7)$$

其中, w_{ij} 和 b_j 分别表示隐藏层的权值和偏差; x_i 是输入特征; L_x 是输入层的神经元数量.

在输出层, 激活函数 Z_k 和非线性激活函数 y_k 分别由式 (8) 和式 (9) 定义. 所使用的非线性激活函数为 Softmax 传递函数.

$$Z_k = \sum_{j=1}^{L_h} w_{kj} \cdot \sigma_j(Z_j) + b_k \quad (8)$$

$$y_k = \sigma_k(Z_k) = \frac{e^{Z_k}}{\sum_{j=1}^{L_h} e^{(\sigma_j(Z_j))}} \quad (9)$$

其中, w_{ik} 和 b_k 分别表示输出层的权值和偏差; L_h 是隐含层的神经元数量.

输入矩阵的每一列 \bar{x}_{sm}^m 包含从相应车辆 m 的交流充电电流采样窗口 s_m^{th} 提取的特征 x_{i,s_m}^m , 表示为:

$$\bar{x}_{sm}^m = \bar{F}^{sm} \quad (10)$$

其中, \bar{F}^{sm} 表示所选的特征.

对于目标矩阵, 每一列表示为:

$$y_t = \begin{cases} [1 & 0 & \dots & 0]^T, \text{第1辆车} \\ [0 & 1 & \dots & 0]^T, \text{第2辆车} \\ \vdots \\ [0 & 0 & \dots & 1]^T, \text{第M辆车} \end{cases} \quad (11)$$

2.2.2 支持向量机

支持向量机 (SVM) 是一种在模式分类和识别方面表现出良好性能的监督分类器^[15,16]. 最优的分离超平面将是边界最大的超平面, 定义为数据到决策面的最小距离 (对应于图 4 中的超平面). 准确落在边界上的训练数据称为支持向量, 支持最大边界超平面.




图 4 用 c_i 和 c_j 两类样本训练支持向量机的最大超平面和边界值示意图

构造 $n_{\text{class}} \times (n_{\text{class}} - 1)$ 分类器, 其中 n_{class} 在类的数量中与两个不同类的数据组成一个序列. 鉴于 c_i 和 c_j 的训练数据 $(x_1, y_1), \dots, (x_{ij}, y_{ij})$ 已知, 现将下面的二元分类问题转化为凸二次优化问题.

$$\min \left(\underbrace{\frac{1}{2} (w^{c_i c_j})^T w^{c_i c_j} + C \sum_{t=1}^{n_{ij}} \zeta_t^{c_i c_j} (w^{c_i c_j})^T}_{\text{Max, margin}} \right) \quad (12)$$

$$(w^{c_i c_j})^T x_t + b^{c_i c_j} \geq 1 - \zeta_t^{c_i c_j}, \text{ if } y_t = c_i$$

$$(w^{c_i c_j})^T x_t + b^{c_i c_j} \leq -1 + \zeta_t^{c_i c_j}, \text{ if } y_t = c_j$$

其中, $w^{c_i c_j}$ 表示特征空间中最优超平面的参数; x_t 是训练样本; $b^{c_i c_j}$ 是偏差; $\zeta_t^{c_i c_j}$ 是松弛变量; C 是正则化参数. 考虑分类 c_m , 这种方法是每次一个分类器指出 x 在 c_m 类中使用决策函数 $\text{sgn}((w^{c_i c_m})^T x_t + b^{c_i c_m})$ 时, c_m 类的投票就增加一个, x 就是最终得票最多的那一类.

3 充电习惯统计模型

对于 EMS 而言, 任何一辆 EV 充电所需电量主要受充电时 EV 的 SOC 和预计出发时间影响^[17]. 为了预测电动汽车充电能量需求, 需建立充电电量和出发时间的统计模型, 确定充电策略中充电优先级. 该模型旨在建立一个基于充电习惯和与其他间接观测变量相关的模型, 从而为 EV 充电调度框架提供一个有效的自动管理. 主要使用直方图和核估计对观测到的随机变量行为进行统计建模^[18].

3.1 日充电需求直方图

设 $E_m(1), E_m(2), \dots, E_m(N)$ 为第 m 个 EV 的日充电能量测量样本, $f(x)$ 为对应的概率密度函数. 为了建立直方图, 充电能量数据的范围被划分为 B_1, B_2, \dots, B_L , 通常选择相同的大小, 但也可以改变大小. 利用以下公式构建直方图:

$$B = \{B_1, B_2, \dots, B_L\} \quad (13)$$

$$\hat{f}_{\text{rnhist}}(E_m) = \sum_{l=1}^L \frac{\text{count}_l}{(\text{size of bin } B_l)} \quad (14)$$

其中, count_l 为数据 $E_m(i)$ 落入 B_l 的个数, $B_l \in B$.

3.2 基于插入时间的充电需求直方图

通过整合插入时间方式表述充电需求直方图, 利用三维直方图分布对这种相关性进行了建模. 因此, 插入时间 b^{pa} 的直方图分布定义为:

$$b^{pa} = \{b_1^{pa}, b_2^{pa}, \dots, b_j^{pa}\} \quad (15)$$

$count_{E_{mi},pa_j}$ 表示 E_{mi} 在时间 b_j^{pa} 落入 B_l 的个数.

3.3 日充电需求核密度估计

直方图方法的主要优点是易于构造和理解, 在统计分析中普遍存在. 但缺点是随着样本量的增大, 收敛速度相对较慢, 密度估计存在不连续, 这与底层密度假定的平滑性相矛盾. 通过估计核密度可以弥补这两个缺点. 这些可以看作是滑动直方图的推广, 或者是经验分布函数与光滑核函数的卷积. 核密度估计可表示为:

$$\hat{f}_K(x) = \frac{1}{Nh} \sum_{n=1}^N K\left(\frac{x - E_m(n)}{h}\right) \quad (16)$$

其中, K 是一个平滑函数, 称为核函数, $h > 0$ 是控制平滑量的平滑带宽. $E_m(i)$ 是日充电能量测量数据的第 i 个样本. N 是测量数据的个数. 高斯核函数表达式如下:

$$K(u) = \frac{e\left(-\frac{1}{2}u^T u\right)}{\sqrt{2\pi}} \quad (17)$$

3.4 EV 模型更新

统计建模需要考虑不同充电习惯的随机性. 对于每个单独的 EV, 有必要使用新的测量方法定期更新统计模型, 以捕获在能源需求、充电位置和连接时间方面的不同趋势. EMS 首先将不同的消费配置文件存储在数据库中, 再使用所提出的识别方法在线更新每个消费分布的新测量信息, 并创建图 5 所示的动态统计模型.

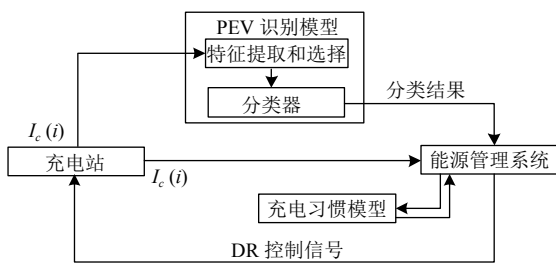


图 5 EV 模型更新

4 算例分析

4.1 数据收集

本实验数据采集频率为 1200 Hz, 并且每秒钟采集一次电网侧的充电电流幅值. 通过 5 辆电动汽车共享场景对识别算法进行测试. 这 5 辆车的详细情况如表 1 所示.

表 1 5 辆电动汽车的相关特性

序号	电池容量(kWh)	充电功率(kW)
EV1	60	7.2
EV2	30	6.6
EV3	10	3.3
EV4	20	3.3
EV5	25	6.6

4.2 EV 识别模型

EV 识别部分使用数据库已经分成两组, 如表 2 所示. 第 1 个数据库包含 83 个充电数据 (2019 年 8 月 5 日~25 日), 第 2 个数据库包含 49 个充电数据 (2019 年 9 月 6 日~20 日). 对于所有提出的结果, EV 识别是通过车辆接入后使用 300 个测量窗口来呈现.

表 2 识别过程中每个 EV 的充电数据的数量

数据库	EV1	EV2	EV3	EV4	EV5	总计
库1	18	16	19	11	19	83
库2	11	8	13	5	12	49

4.2.1 基于前馈神经网络分类器的 EV 识别

模型构建和在线性能测试采用独立数据. 对于模型的构建 (训练 70%、验证 15%、测试 15%), 使用表 2 中的数据库 1. 然后在线测试建立在数据库 2 中收集的新数据上的模型的性能. 用 Matlab 神经网络模式识别进行分类.

在输入层, 从测量样本中提取的 12 个特征, 如表 3 所示. 识别过程通过 300 个测窗口进行, 故 F1 的维度为 300, 通过计算确定 Welch 功率谱密度估计、Thomson 功率谱密度估计的 FFT 长度为 2 的 7 次幂及 2 的 8 次幂, 其特征空间维度分别为 129 与 257, 其余特征空间维度均为 1. 输入层 x_{sm}^m 的神经元最终数量即所有特征空间维度之和为 695. 通过改变隐藏层神经元的数目进行了多次模拟, 最后选择了包含 10 个神经元的隐层. 分类结果如图 6 所示. 虽然不同车辆的充电电流幅值非常相似, 但该方法在 5 种电动汽车的分类方面表现出了非常令人满意的性能, 在验证和测试阶段全部识别. 离线构建后, 对数据库 2 中 49 个新的充电电流测量值进行了在线测试, 如图 7 所示. 因为该模型成功地识别了 5 种 EV, 准确率达 96%. 在充电的 49 次测量中, 对两辆车的识别只出现了两次混淆. 此外, 增加训练数据库的大小可以改进识别过程. 本次验证研究中用于识别的 EV 类数量为 5 个. 这个数可少可多, 取决于小区内的 EV 用户数量.

表3 前馈神经网络输入层中使用的特征值

特征空间	维度
F1	(300,1)
F2	(129,1)
F3	(257,1)
F4	(1,1)
F5	(1,1)
F6	(1,1)
F7	(1,1)
F8	(1,1)
F9	(1,1)
F10	(1,1)
F11	(1,1)
F12	(1,1)




图6 数据库1前馈神经网络分类结果




图7 基于数据库2模型的在线验证性能分类结果

4.2.2 特征选择和模型敏感性研究

特征选择就是从提取的特征中挑选出最有用的子集特征. 将序列前向选择方法应用于 695 个特征的初始特征空间, 以选择最合适的子集特征, 再将得到的子集特征与使用所有特征空间得到的子集特征的识别模型进行性能比较. 此外, 还使用了不同大小的数据库进行特性选择. 所选的子集特征维数为 3 和 10. 在对几个核函数进行仿真评估后, 选择一个线性核函数作为支持向量机分类器. 研究 4 种场景 (即 25%、50%、75% 和 100%) 的数据来选择不同的子集特征, 使用相同比例的数据用于训练, 数据库 2 用于测试阶段, 用获得的子集特征测试 EV 识别模型泛化能力.

利用式 (5) 中局部最优特征得到的序列前向选择结果和精度如表 4 所示. 从不同的场景中得到的结果表明, 在原始信号和用 Welch 和 Thomson 方法估计的功率谱密度中, 信息丰富的特征更加集中. 敏感性研究

还强调了数据库大小对选择子集特性的重要性, 以及数据库中包含的数据质量. 随着更多的数据被用来选择特征, 序列前向选择算法更好地收敛到全局最优特征. 不同规模数据库 4 种场景中利用所有特征空间的性能几乎相同, 如图 8 所示.

表4 不同数据库 SVM 分类器子集特征选择结果

场景	参数	特征维数3	特征维数10
25%	Rwdata	2	1-8
	PSD _w	343 363	343 363
50%	Rwdata	1,2	1-9
	PSD _T	599	599
	Rwdata	-	1-5
75%	PSD _w	312 332 334	308 311 312 332
	Rwdata	2	334
	PSD _T	336 363	309 336 363




图8 不同数据库规模的EV识别模型的泛化能力与支持向量机分类器的最优特征比较

4.2.3 支持向量机和前馈神经网络性能比较

使用相同的输入特征和数据库, 将 SVM 分类器的性能与前馈神经网络分类器进行了比较, 所利用的特征是全局最优特征. 随机生成的数据库 1 的 75% 为训练数据库, 而数据库 2 用于测试阶段. SVM 分类器采用线性核函数, 前馈神经网络采用 13 神经元隐层, 对比结果如图 9 所示.




图9 使用最优特征的SVM分类器性能与前馈神经网络分类器的比较

SVM 和前馈神经网络的性能非常接近, 所以这两种方法都适合于 EV 识别的实际实现。然而, 因为在线应用是本文的主要目标, 所以与前馈神经网络相比, SVM 是一种计算开销较大的方法。SVM 由多个分类器组成, 考虑分类器的数量就增加了计算时间。而前馈神经网络可以只用一个分类器实现。

4.3 EV 充电需求统计建模

4.3.1 EV 日充电需求直方图

直方图是通过将能量轴划分为多个区间 $B = \{[0, 5], [5, 10], [15, 20], \dots, [60, 65]\}$ 来构建的。

由图 10 可以看出五种电动汽车的充电习惯非常不同。EV2、EV3、EV4 的分布较窄, 带宽较低。因此, 他们的能量需求更容易预测。相比之下, EV1 和 EV5 的消耗分布较为均匀, 具有一定的非平稳特性。在这种情况下, 充电能量与其他变量如充电时间、天气的相关性研究可以帮助预测充电需求。EV1 统计模型的演变如图 11 所示。如果某一天 EV 没有在小区充电站充电, 也可以通过识别模型捕捉到这一点。

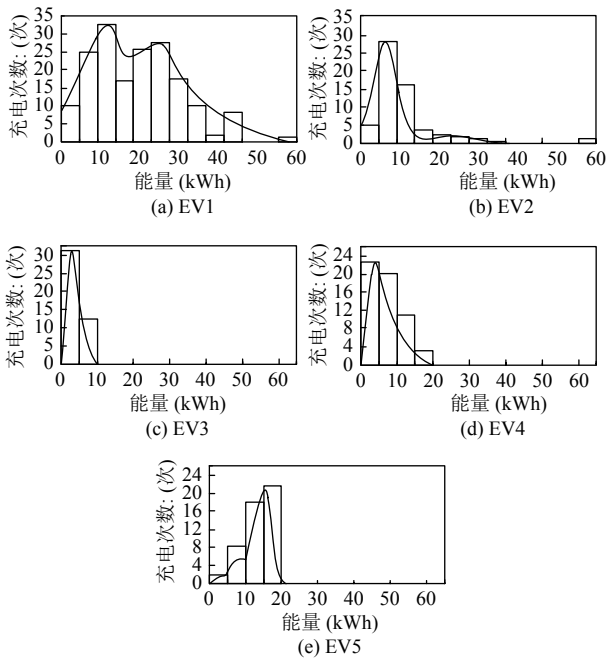


图 10 5 个 EV 历史充电能量的直方图和核平滑图

4.3.2 根据插入时间和工作日充电需求直方图

针对 EV1, 根据插入时间和星期几构建了充电能量需求的直方图模型, 结果如图 12 和图 13 所示。

从图 12 可以看出, 充电到 EV 电池电量与 EV1 的连接时间有关。同样, 从图 13 中可以看出, 充电能量需求也与 EV1 的星期几有关。因此, 对于 EV1, EMS 利用

与日期中某些变量的相关性来预测充电所需的能量。而其他变量可以减少估计误差, 比如是否晴天, 是否下雨或下雪等天气数据。

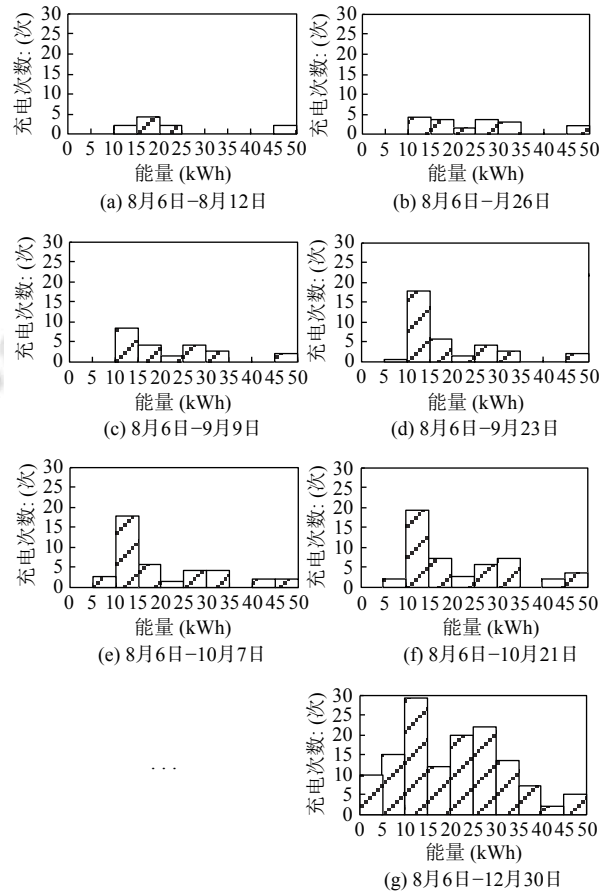


图 11 EV1 的在线统计建模

5 总结

在当前面向智慧园区电动汽车充电模式和充电策略研究基础上, 本文针对用户自主充电需求管理提出了一种适用于智慧园区有序共享充电需求分析模型。通过对电网侧充电电流测量, 实现了对单个充电电动汽车充电习惯的在线识别和统计建模。由于识别 EV 所需的充电电流样本更少, 首先分析了小区能量管理系统协助管理共享充电站充电调度任务; 然后通过人工神经网络监督分类, 建立识别模型在线识别 EV, 针对 EV 充电习惯建立统计模型, 预测其充电能量需求, 其中充电习惯包括电池充电状态、电动汽车插入时间以及是否是工作日; 最后, 根据采集实测数据验证了所提出建模方法的有效性, 为将来新兴住宅小区规模化电动汽车有序共享充电提供帮助。

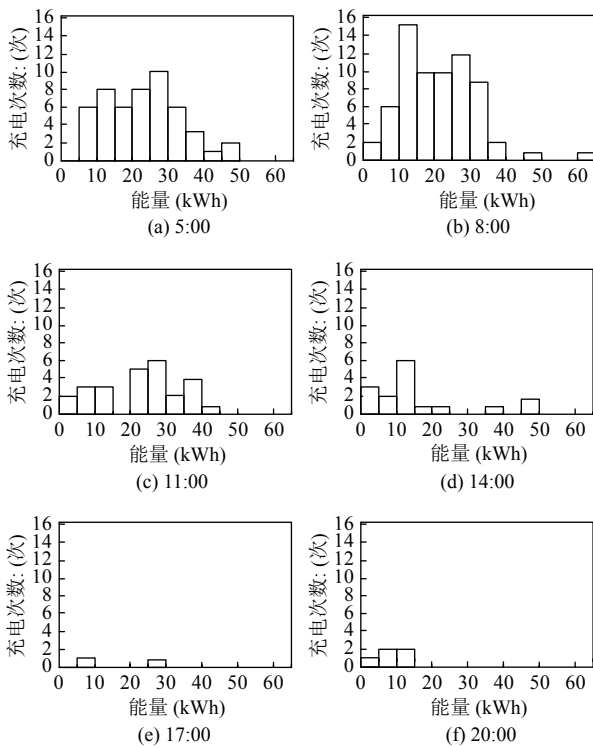


图 12 EV1 插入时间与充电能量直方图

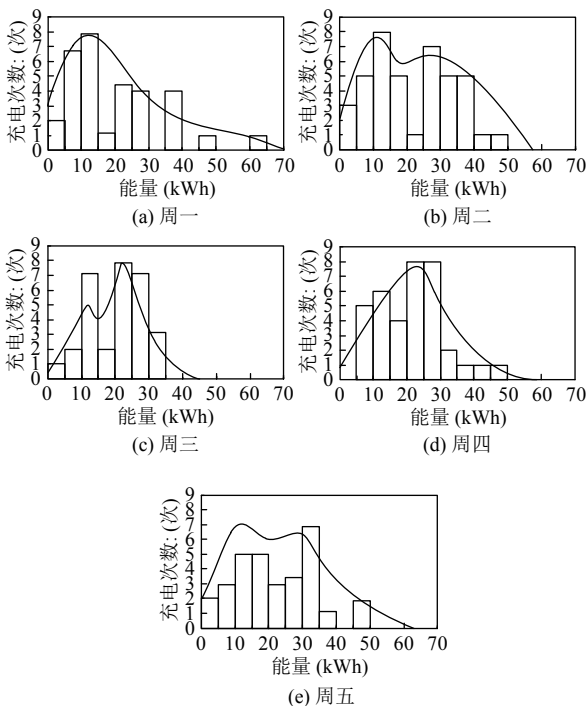


图 13 EV1 充电能量的直方图和核平滑图

参考文献

1 钟小强, 王天云, 麦鸿坤. 面向居民区电动汽车充电负荷预测与容量配置研究. 电测与仪表, 2018, 55(23): 54-59. [doi: 10.3969/j.issn.1001-1390.2018.23.009]

2 Sovacool BK, Kester J, Noel L, *et al.* Contested visions and sociotechnical expectations of electric mobility and vehicle-to-grid innovation in five Nordic countries. *Environmental Innovation and Societal Transitions*, 2019, 31: 170-183. [doi: 10.1016/j.eist.2018.11.006]

3 李国, 吴抒源. 含分布式电源的电动汽车充换电站运行优化. *电器与能效管理技术*, 2018, (23): 73-78.

4 黄华, 常湧, 李琦, 等. 满意度和清洁度优先的电动汽车与新能源双层多目标优化调度. *电测与仪表*, 2018, 55(3): 59-66, 79. [doi: 10.3969/j.issn.1001-1390.2018.03.011]

5 刘冬兰, 马雷, 刘新, 等. 基于深度学习的电力大数据融合与异常检测方法. *计算机应用与软件*, 2018, 35(4): 61-64, 136. [doi: 10.3969/j.issn.1000-386x.2018.04.011]

6 邵尹池, 穆云飞, 林佳颖, 等. “车—站—网”多元需求下的电动汽车快速充电引导策略. *电力系统自动化*, 2019, 43(18): 60-66, 101. [doi: 10.7500/AEPS20181127010]

7 张西竹, 刘洵源, 杨文涛, 等. 动态分时电价机制下的电动汽车分层调度策略. *电力建设*, 2018, 39(12): 73-80. [doi: 10.3969/j.issn.1000-7229.2018.12.009]

8 杨健维, 苟方杰, 黄宇, 等. 基于不确定性测度的居民小区电动汽车充电分时电价制定策略. *电网技术*, 2018, 42(1): 96-102.

9 齐先军, 李冬伟, 纪姝彦. 采用功率限制的住宅区电动汽车有序充电控制策略. *电网技术*, 2016, 40(12): 3715-3721.

10 仲海涛, 撒奥洋, 张智晟. 基于 MOHSA 的智慧社区能量管理系统优化调度研究. *电工电能新技术*, 2019, 38(3): 28-37.

11 党晓婧, 黄荣辉, 刘顺桂, 等. 基于时频域特征的局部放电单脉冲波形分析. *电测与仪表*, 2019, 56(20): 52-56.

12 何群, 赵婧怡, 江国乾, 等. 基于电流信号稀疏滤波特征融合的齿轮箱故障诊断方法. *电网技术*, 2020, 44(5): 1964-1971.

13 刘玉敏, 赵哲耘. 基于特征选择与 SVM 的质量异常模式识别. *统计与决策*, 2018, 34(10): 47-51.

14 崔明义, 苏白云. 前馈神经网络误差修正算法的改进和比较. *计算机应用与软件*, 2005, 22(9): 35-36, 120. [doi: 10.3969/j.issn.1000-386X.2005.09.013]

15 李亦滔. 基于支持向量机的改进分类算法. *计算机系统应用*, 2019, 28(10): 145-151. [doi: 10.15888/j.cnki.csa.007080]

16 孙卫喜. 用于网络安全态势预测的粒子群与支持向量机算法研究. *计算机应用与软件*, 2019, 36(6): 308-316. [doi: 10.3969/j.issn.1000-386x.2019.06.056]

17 何西, 涂春鸣, 王丽丽, 等. 考虑用户行车习惯的电动汽车充电双层控制策略. *电力系统自动化*, 2018, 42(3): 64-69. [doi: 10.7500/AEPS20170731005]

18 张建方, 王秀祥. 直方图理论与最优直方图制作. *应用概率统计*, 2009, 25(2): 201-214. [doi: 10.3969/j.issn.1001-4268.2009.02.010]