

文章编号: 1006-2467(2024)03-0273-12

DOI: 10.16183/j.cnki.jsjtu.2022.347

考虑不同充电策略的锂电池健康状态区间估计

张孝远, 张金浩, 杨立新

(河南工业大学 电气工程学院, 郑州 450001)

摘要: 评估锂离子电池健康状态(SOH)对于电池使用、维护、管理和经济性评价都有十分重要的意义,但当前锂电池 SOH 估计方法多针对特定充电策略,采用确定性估计模型,无法反映电池退化过程中的随机性、模糊性等不确定性信息. 为此,提出一种适用于不同充电策略的锂电池 SOH 区间估计方法. 该方法针对不同充电策略的电池循环充放电数据提取多个特征参数,通过交叉验证自动选择针对特定充电策略的最优特征参数组合. 另外,考虑到锂电池全生命期循环次数有限,属于小样本问题,提出集成支持向量回归与分位数回归优势的支持向量分位数回归模型(SVQR)进行锂电池 SOH 区间估计. 选用放电程度较深的锂电池充放电循环数据作为训练集,对 SVQR 模型进行离线训练,训练好的模型用于不同充电策略下锂电池 SOH 在线估计. 采用具有不同充电策略的数据集验证所提方法,实验结果表明:所提方法适用于不同充电策略,且估计结果优于分位数回归法、分位数回归神经网络法和高斯过程回归法.

关键词: 锂离子电池;健康状态;区间估计;充电策略;支持向量分位数回归

中图分类号: TM912

文献标志码: A

Interval Estimation of State of Health for Lithium Batteries Considering Different Charging Strategies

ZHANG Xiaoyuan, ZHANG Jinhao, YANG Lixin

(College of Electrical Engineering, Henan University of Technology, Zhengzhou 450001, China)

Abstract: State of health (SOH) estimation of lithium-ion (Li-ion) batteries is of great importance for battery use, maintenance, management, and economic evaluation. However, the current SOH estimation methods for Li-ion batteries are mainly targeted at specific charging strategies by using deterministic estimation models, which cannot reflect uncertain information such as randomness and fuzziness in the battery degradation process. To this end, a method for estimating the SOH interval of Li-ion batteries applicable to different charging strategies is proposed, which extracts multiple feature parameters from the cyclic charging and discharging data of batteries with different charging strategies, and automatically selects the optimal combination of feature parameters for a specific charging strategy by using the cross-validation method. In addition, considering the limited number of cycles in the whole life cycle of Li-ion batteries as a small sample, support vector quantile regression (SVQR), which integrates the advantages of support vector regression and quantile regression, is proposed for the estimation of SOH interval of lithium-ion batteries. Li-ion battery charge/discharge cycle data with deep discharge degree is selected as

收稿日期: 2022-09-05 修回日期: 2023-01-10 录用日期: 2023-03-03

基金项目: 国家自然科学基金(51409095), 河南工业大学粮食信息处理与控制教育部重点实验室开放基金(KFJJ-2016-110)资助项目

作者简介: 张孝远(1981-), 副教授, 从事能源与电力设备智能维护与健康管理研究; E-mail: freedon@haut.edu.cn.

the training set for offline training of the SVQR model, and the trained model is used for online estimation of the SOH of Li-ion batteries of different charging strategies. The proposed method is validated using three datasets with different charging strategies. The experimental results show that the proposed method is applicable to different charging strategies and the estimation results are better than those of quantile regression, quantile regression neural network and Gaussian process regression.

Keywords: lithium-ion battery; state of health (SOH); interval estimation; charging strategy; support vector quantile regression (SVQR)

在碳达峰、碳中和目标背景下,电动汽车得到大力发展. 锂离子电池作为电动汽车的核心部件之一,使用量呈现井喷式增长. 与此同时,由锂离子电池健康状态(State of Health, SOH)劣化引发的安全问题日益凸显,在一定程度上限制了电动汽车行业的发展. SOH 通过百分比的形式量化电池的老化情况,是评价电池老化程度的综合评价标准^[1]. 合理精确的 SOH 估计有助掌握电池的衰减情况,对电池安全使用、维护管理和经济性评估都有十分重要的意义^[2-3].

SOH 无法通过传感器直接测量,现有 SOH 评估方法主要分为模型法和数据驱动法^[4]. 模型法基于电化学机理建立物理等效电路模型来描述锂离子电池 SOH 的变化,模型参数可依据电池的不同衰退情况而变化,但锂电池内部化学变化是一个动态、非线性的复杂电化学系统,建立准确的电化学模型非常困难^[5]. 相较之下,数据驱动法无需考虑电池内部复杂的电化学机理,仅基于大量充放电数据提取能够表征电池 SOH 的特征参数,即可建立特征参数与 SOH 之间的定量映射关系. 因此,基于数据驱动的锂电池 SOH 估计得到众多研究者的青睐^[6-7].

数据驱动法一般包含特征参数选取和 SOH 回归估计两大步骤. 提取出能够充分表征 SOH 的特征参数是近年来的一个研究热点,文献[8]中从充放电曲线中获取增量容量(Incremental Capacity, IC)曲线,研究了 IC 曲线随循环次数的变化趋势,并验证 IC 峰值、IC 峰值位置等特征与 SOH 之间的相关性,但不同型号电池的 IC 峰值数量并不一致,所用特征并不适用于所用电池. 文献[9]中进一步研究不同型号电池包含多个 IC 峰值的情况. 但在 IC 曲线的提取过程中必须设计复杂的滤波算法来平滑原始电压测量值,同时,IC 峰值位置会随着电池老化而逐渐偏移;并且要获得所有老化周期下的 IC 特性,需要在较大的电压范围内进行采样,十分耗时. 针对这个问题,文献[10]中从放电电压曲线及温度曲线中获取放电平均电压和平均温度作为外部特征,估

算 SOH. 但在实际应用中,电池放电深度不一致导致平均电压变化且温度受环境影响较大. 为此,文献[11]中选择从恒压充电曲线中获取平均电流等作为外部特征,并用等效电路模型表征恒压曲线中的电池老化现象. 上述锂电池特征参数提取的最新研究较大程度上推动了基于数据驱动的锂电池 SOH 估计的发展. 但上述研究有一个共性不足——都是基于恒流恒压充电策略下进行的锂电池充放电实验,所用数据均为单一充电策略下所得数据,未考虑不同充电策略或锂电池实际放电情况等问题,在实际应用中缺乏普适性. 研究高效准确的适用不同充电策略的锂电池特征参数选择方法是迫切的现实需求.

获得与 SOH 高度相关的特征参数之后,需要建立所获取特征参数与 SOH 之间的映射关系,其本质是一类多元回归问题. 诸多机器学习方法可以用于解决这类问题. 反向传播(BP)神经网络、支持向量机、高斯回归、决策树等方法相继被用来建立 SOH 的回归估计模型^[4]. 如文献[12]中搭建 BP 神经网络对锂电池 SOH 进行在线估计;文献[3]中采用粒子群优化的支持向量回归模型实时估计不同老化状态下的电池 SOH;文献[13]中基于高斯过程回归(Gaussian Process Regression, GPR)建立 SOH 估算模型,取得较精确的估算精度;文献[10]中搭建布谷鸟搜索支持向量模型实现锂离子电池的 SOH 快速估计. 结合前述特征参数选取方法,上述回归估计模型在特定条件下能够较为精确地估计 SOH 值,但上述研究所采用的 SOH 估计模型均为点估计方法. 实际工作环境中锂电池剩余容量存在容量回升效应^[14],随着循环次数的推移,锂电池剩余容量会有一定幅度的波动甚至上升,导致在某一时刻的 SOH 估计结果无法充分揭示 SOH 的退化趋势. 同时,在实际运行中电动汽车工作环境复杂、负载波动较大,导致锂电池退化模式不固定,SOH 估计结果具有一定的不确定性^[15],传统点估计方法无法对锂电池退化过程进行合理量化.

针对锂电池 SOH 估计的不确定性量化估计问题,近年来有研究人员提出两类方法来构建电池 SOH 的预测区间. 第一类为理论方法,基于以下假设:预测误差遵循具有零均值的确定分布,通常为正态分布或拉普拉斯分布^[16]. 文献[17]中开发了一个基于平均熵和相关向量机的多步预测模型,并将其应用于电池的 SOH 评估和剩余寿命预测,该方法基于高斯分布构造 95% 的预测结果置信区间. 但实测的锂电池充放电数据涉及复杂过程和噪声干扰,很难确保满足高斯假设. 第二类为神经网络方法,该类方法无需考虑误差分布,因此受到研究者青睐. 如文献[18]中构建了一个改进的上下边界估计神经网络对锂电池 SOH 进行区间估计. 但此算法需要大量数据集进行训练,而锂电池全生命期,即 SOH 从 100% 退化到 80%,一般循环次数不超过 2 000,属于典型的小样本问题,这类方法效果有限.

针对当前有关锂电池 SOH 估计方面的研究在特征参数选取普适性和 SOH 估计不确定性量化两方面的不足,提出一种适用于多种充电策略的锂电池 SOH 不确定量化估计方法. 该方法充分考虑当前常用充电策略下充放电曲线的变化,从电压、电流及 IC 曲线中提取出多个外部特征,再通过交叉验证

方法自动选取出适用于不同充电策略的个性化最优特征组合. 首次提出使用支持向量分位数回归 (Support Vector Quantile Regression, SVQR) 模型进行锂电池 SOH 区间估计. 所采用的 SVQR 方法利用分位数回归 (Quantile Regression, QR) 模型解决了区间分布问题,同时,支持向量回归 (Support Vector Regression, SVR) 模型在小样本充放电数据下具有较好的泛化性能. 将所提方法在常用的 3 种不同充电策略的锂电池数据集上进行验证,并与 QR、分位数回归神经网络 (Quantile Regression Neural Network, QRNN) 及 GPR 进行对比,验证了所提方法的优越性.

1 所提方法的总体框架

所提方法的总体流程如图 1 所示,分为离线训练和在线评估两个阶段. 在离线训练阶段,首先从循环电压曲线、电流曲线及 IC 曲线中提取多个通用特征参数,然后采用交叉验证方法自动选择与 SOH 相关性最好的最优特征参数组合,并将其输入 SVQR 模型进行训练. 在线阶段将充放电数据输入训练好的 SVQR 模型,实现电池 SOH 的在线区间估计,从而给出锂电池使用安全指导建议.

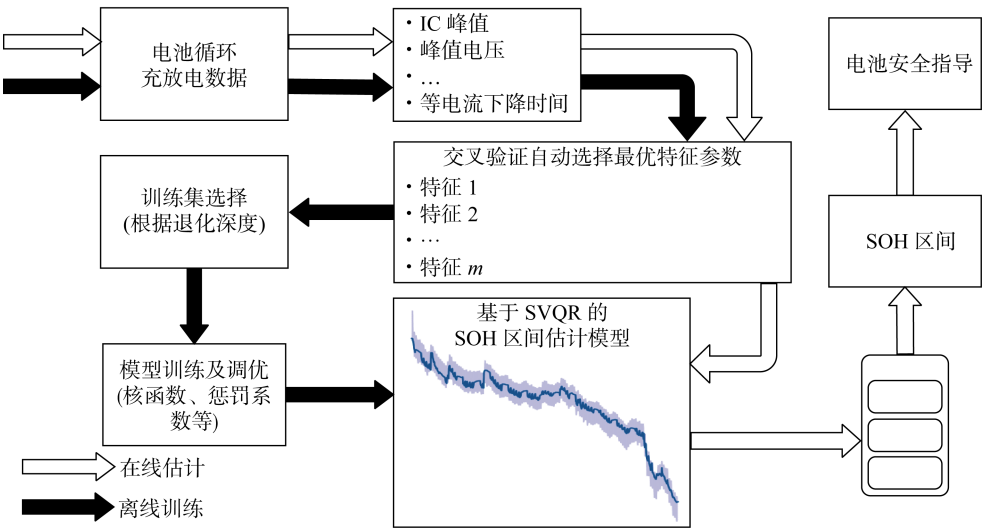


图 1 所提 SOH 区间估计方法流程

Fig. 1 Flow chart of the proposed SOH interval estimation method

2 考虑不同充电策略的锂电池 SOH 区间估计方法

2.1 锂电池常用充电策略及其特点

锂电池充电速度是制约电动汽车进一步发展的主要瓶颈之一^[19]. 人们希望提高充电速度,但充电速度的提高会造成温度的快速升高和电池寿命的快

速衰退. 因此,探索能够兼顾充电快速性、温度控制与合理寿命预期的充电策略一直是一个研究热点^[20]. 目前锂电池充电策略已由最初的恒压充电、恒流充电,发展到恒压恒流充电结合的多阶段充电^[21]. 结合当前锂电池充电策略发展的现状,重点考虑如下 3 类常用的充电策略. 第一类为恒流恒压 (Constant Current Constant Voltage, CC-CV) 充

电. CC-CV 充电第一阶段以恒定电流充电;当电压达到预定值时转入第二阶段进行恒压充电,此时电流逐渐减小;当充电电流下降到 0 时,蓄电池完全充满. 该充电策略可有效避免电池极化效应,但充电时间较长;第二类为恒流 (Constant Current, CC) 充电. CC 充电采用恒定电流对电池进行充电. 由于电流一般较大,电池会快速达到截止电压,充电时间较短,但控制不当则会增大电芯的极化;第三类为两

阶段快速充电 (Two Step Fast Charge, 2-step). 该充电策略历经两个充电阶段. 充电过程可表达为 “C1(Q1)-C2”, 其中 C1 和 C2 分别代表两个充电阶段, Q1 代表充电电流切换时电池的荷电状态 (State of Charge, SOC), 第一个阶段采用恒流充电至 SOC 为 Q1 结束;第二个阶段采用 CC-CV 方式直至电池充满. 上述 3 种充电策略的电压变化曲线如图 2 所示.




图 2 不同充电策略下电压变化
Fig. 2 Voltage change of different charging strategies

2.2 SOH 特征选择

锂电池充放电曲线中蕴含丰富的电池老化信息. 图 3 为某单体电池不同循环次数下电压、电流变化曲线. 可见,随着循环次数增多,充放电电压曲线和电流曲线也随之变化,充放电曲线的形状与电池的老化情况高度相关. 如何从充放电曲线中提取出与 SOH 高度敏感的特征参数是 SOH 估计的关键. 但不同充电策略所对应的敏感特征参数可能不同,很难找到普适于多个充电策略的特征参数. 当前有关锂电池 SOH 估计方法大多针对某一特定充电策略,没有考虑充电策略的不同及其进一步发展. 为此,提出一种更泛化的特征参数提取流程. 首先,充

分分析不同充电策略的单体电池在不同循环次数下电压、电流、IC 曲线变化特性,并参考文献[2, 6, 15]中的结论,从 IC 曲线提取 IC 曲线峰值 (P_{IC})、IC 曲线峰值对应电压 (U_{IC})、IC 曲线峰左斜率 (k_L)、IC 曲线峰右斜率 (k_R) 4 个特征,如图 4(a) 所示;从电流曲线提取 CV 充电下降到给定电流所用时间 (t_D) 和 CV 充电过程最后阶段的平均电流 (I_A),如图 4(b) 所示;从电压曲线提取 CC 充电上升到给定电压所用时间 (t_U) 和单次循环后静置时间内的电压回升数值 (U_V),如图 4(c) 所示. 然后,为了适应不同充电策略,采用交叉验证方法自动选择针对特定充电策略的个性化最优特征参数. 交叉验证方法在上述所提




图 3 某单体电池充放电曲线在不同循环周期下的变化情况

Fig. 3 Change of voltage and current in charging and discharging of a single battery of different cycles

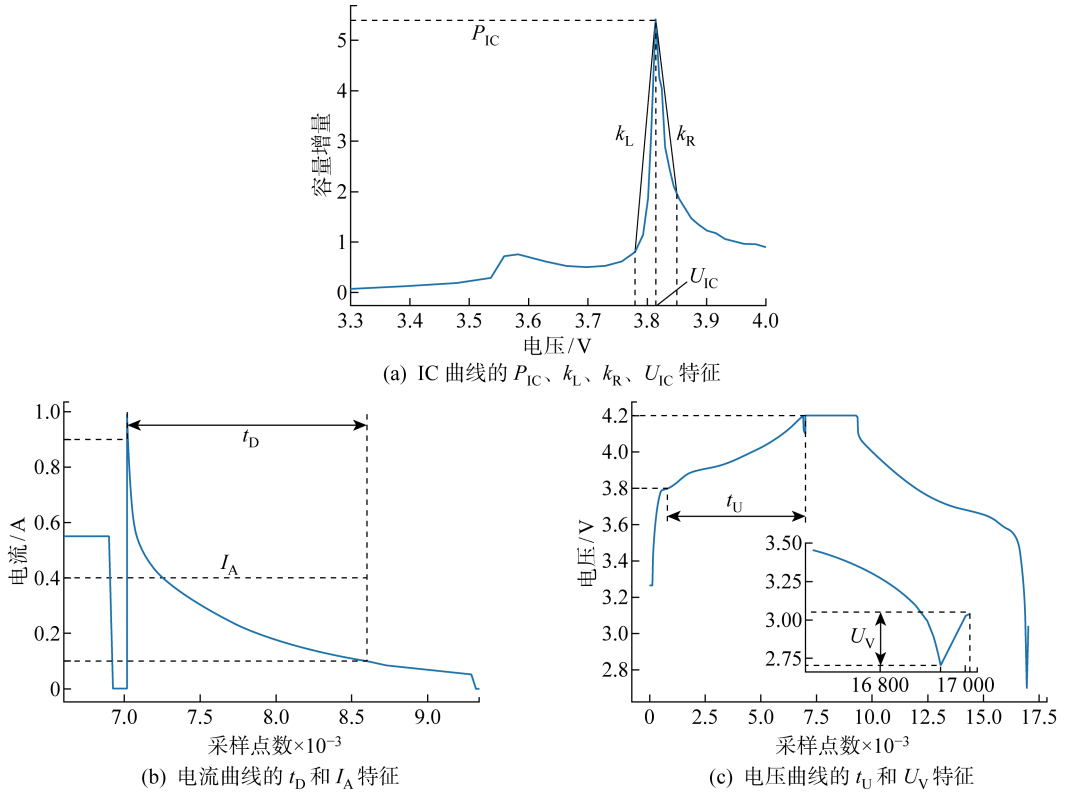


图4 电流、电压和IC曲线的提取特征

Fig. 4 Extracted features from current, voltage, and IC curve

取的通用特征集中遍历所有可能的特征参数组合,然后对各个特征组合的估计结果进行排序以选出最优特征参数组合。

2.3 分位数回归

QR 最初由 Koenker 和 Bassett^[22] 提出。把传统方法的均值回归推广到 QR,可以更详细地描述响应变量的全局特征,且不易受离群点影响,结果更稳健。尤为重要的是 QR 不需要回归残差满足正态分布、随机独立、方差齐同等均值回归方法的基本假设。这对于解决锂电池 SOH 估计这类实际问题十分有利,原因在于锂电池实际工作中受多变工况、运行环境等因素影响,监测数据很难满足正态分布的假设。给定训练集 $T = (\mathbf{x}_i, y_i)_{i=1}^n \in \mathbf{R}^d \times \mathbf{R}$, QR 模型可按下述过程构建。

$$q_\tau(\mathbf{x}_i) = \mathbf{x}_i' \boldsymbol{\beta}(\tau),$$

$$i = 1, 2, \dots, t; \quad \tau = \tau_1, \tau_2, \dots, \tau_M \quad (1)$$

式中: $\mathbf{x}_i = [x_{i,1} \ x_{i,2} \ \dots \ x_{i,d}]$ 为包含 d 个分量的独立变量, $x_{i,j}$ 是 \mathbf{x}_i 的第 j 个分量, $j = 1, 2, \dots, d$; y_i 为对应 \mathbf{x}_i 的因变量; $q_\tau(\mathbf{x}_i)$ 为因变量 y_i 在自变量 \mathbf{x}_i 下的第 τ 分位数,对于任意分位数 $0 < \tau < 1$, $\boldsymbol{\beta}(\tau) = [\beta_1(\tau) \ \beta_2(\tau) \ \dots \ \beta_d(\tau)]'$ 为 τ 分位数下的回归系数, $\boldsymbol{\beta}(\tau)$ 的估计值通过最小化检验函数 $\rho_\tau(\sigma)$ 获得。

$$\hat{\boldsymbol{\beta}}(\tau) = \operatorname{argmin} \sum_{i=1}^n \rho_\tau(y_i - \mathbf{x}_i' \boldsymbol{\beta}(\tau)) \quad (2)$$

检验函数 $\rho_\tau(\sigma)$ 为一段线性函数,定义为

$$\rho_\tau(\sigma) = \sigma(\tau - I(\sigma)) \quad (3)$$

式中: $I(\sigma)$ 为一个指示函数,定义为

$$I(\sigma) = \begin{cases} 0, & \sigma \geq 0 \\ 1, & \sigma < 0 \end{cases} \quad (4)$$

2.4 支持向量分位数回归

尽管 QR 方法可以更详细地描述响应变量的全局特征,无需所描述对象服从特定分布,但从 1.3 节可见,QR 本质上还是针对线性问题的回归分析。在实际工程问题中,自变量和因变量之间的关系往往非线性,且难以确定显性的函数形式。考虑到 SVR^[23] 可以通过核函数技巧隐式地把低维非线性数据映射到高维特征空间中做线性回归,且基于结构风险最小化原理,其在解决小样本、非线性问题上具有独特优势,自然地结合 SVR 与 QR 并充分利用二者优势将是很好的选择。Takeuchi 等^[24] 首次提出 SVQR 模型,较好地解决了经济系统中的非线性结构与经济行为在不同尾部的异质性。Shim 等^[25] 利用半参数方法,得到更为简单的 SVQR 模型。仍以训练集 $(\mathbf{x}_i, y_i)_{i=1}^n \in \mathbf{R}^d \times \mathbf{R}$ 为例。SVQR 模型采用式(3)的检验函数替代 SVR 的惩罚函数来建立,如

下式所示：

$$\min \frac{1}{2} \| \mathbf{w} \|^2 + \lambda \sum_{i=1}^n \rho_{\tau}(y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b) \quad (5)$$

式中： \mathbf{w} 为权重向量； λ 为惩罚参数； $\varphi(\mathbf{x})$ 为非线性映射函数，可将 d 维输入向量 \mathbf{x} 隐式地映射到高维特征空间来求解； b 为阈值. 同 SVR 的求解过程一样，通过引入松弛变量 ξ_i, ξ_i^* ，式(5)可转化为求解如下最优化问题.

$$\min_{\mathbf{w}, b, \xi, \xi^*} \left\{ \frac{1}{2} \| \mathbf{w} \|^2 + \lambda \sum_{i=1}^n [\tau \xi_i + (1 - \tau) \xi_i^*] \right\} \quad (6)$$

s. t. $y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b \leq \xi_i$
 $\mathbf{w}^T \varphi(\mathbf{x}_i) + b - y_i \leq \xi_i^*$
 $\xi_i, \xi_i^* \geq 0$

Shim 等^[25]采用半参数方法通过构造拉格朗日函数的方法对式(6)优化问题进行求解，即

$$\left. \begin{aligned} \mathbf{w}_{\tau} &= \sum_{t=1}^T (a_t - a_t^*) \varphi(\mathbf{x}_t) \\ [b_{\tau} \ \boldsymbol{\beta}_{\tau}]^T &= (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T [\mathbf{y} - \mathbf{K}(\mathbf{a} - \mathbf{a}^*)] \\ Q_{y_t}(\tau \mid \mathbf{u}_t, \mathbf{x}_t) &= b_{\tau} + \boldsymbol{\beta}_{\tau}^T \mathbf{u}_t + \mathbf{K}_t(\mathbf{a} - \mathbf{a}^*) \end{aligned} \right\} \quad (7)$$

式中： \mathbf{U} 为一个设计矩阵，由 $(1, \mathbf{u}_t^T)$ 组成； \mathbf{u}_t 为支持向量，其中 $t \in I_{SV}$ ， I_{SV} 为支持向量的下标集合，根据支持向量机原理，在 SVQR 模型中 $I_{SV} = \{t = 1, 2, \dots, T \mid 0 < a_t < \tau \lambda, 0 < a_t^* < (1 - \tau) \lambda\}$ ， a_t, a_t^* 为优化得到的最优拉格朗日乘子，分别组成向量 \mathbf{a}, \mathbf{a}^* ； $\mathbf{y} = \{y_t \mid t \in I_{SV}\}$ ； \mathbf{K} 为核矩阵， $\mathbf{K}(\mathbf{x}_s, \mathbf{x}_t) = \varphi(\mathbf{x}_s)^T \varphi(\mathbf{x}_t)$ 为核函数， \mathbf{K}_t 为 \mathbf{K} 的第 t 行. 显然，核函数和惩罚参数 λ 对 SVQR 的性能有较大影响，大量研究证明高斯核函数在大多数情况下表现优秀^[25]，因此采用高斯核函数，其形式如下：

$$\mathbf{K}(\mathbf{x}_s, \mathbf{x}_t) = \exp\left(-\frac{\|\mathbf{x}_s - \mathbf{x}_t\|^2}{2\sigma_K^2}\right) \quad (8)$$

式中： $\mathbf{x}_s, \mathbf{x}_t$ 为任意变量； σ_K 为核函数的宽度. 采用

广义近似交叉验证准则^[26]获得最优超参数组合，即

$$C_{GACV}(\boldsymbol{\theta}) = \frac{\sum_{t=1}^n \rho_{\tau}(y_t - Q_{y_t}(\tau \mid \mathbf{u}_t, \mathbf{x}_t; \boldsymbol{\theta}))}{n - \text{tr } \mathbf{H}} \quad (9)$$

式中： $\boldsymbol{\theta} = [\lambda \ \sigma_K^2]^T$ 为训练之前需要确定的超参数； \mathbf{H} 为一帽子矩阵，通过 $[Q_{y_1}(\tau \mid \mathbf{u}_1, \mathbf{x}_1) \ \dots \ Q_{y_n}(\tau \mid \mathbf{u}_n, \mathbf{x}_n)]^T = \mathbf{H} \mathbf{y}$ 求得， \mathbf{y} 为 \mathbf{x} 对应的因变量矩阵， $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_n]$.

3 实验设计

3.1 实验设置

采用 3 个具有不同充电策略的公开数据集来验证所提方法的有效性. 分别为马里兰大学高级生命周期工程中心公开数据集(简称 CALCE)^[27]、牛津电池老化数据集(简称 Oxford)^[28]和麻省理工-斯坦福-丰田研究中心电池数据集(简称 TRI)^[29]. 3 个数据集的基本信息如表 1 所示，更为详细的信息可参阅文献[27-29]. 图 5 分别以每个数据集中的一个电池为例，展示 3 个数据集各自电池容量随循环次数的变化情况. 可见尽管电池容量都随循环次数增加而下降，但不同数据集的变化情况不同.

表 1 3 个数据集的基本信息			
Tab. 1 Basic information of three datasets			
数据集	充电协议	标称电压/V	标称容量/(mA · h)
CALCE	CC-CV	4.2	1 100
Oxford	CC	3.7	740
TRI	2-step	3.3	1 100

在每个数据集中选用 1 个放电程度较深的单体电池充放电数据作为训练集，在其余单体电池中任选 3 个作为测试集来验证所提方法的性能. 所选训练集和测试集的情况如表 2 所示.




图 5 CALCE、Oxford、TRI 数据集电池容量变化
Fig. 5 Battery capacity change of CALCE, Oxford and TRI datasets

表 2 训练集和测试集情况

Tab. 2 Basic information of training set and test set

数据集 数据划分	CALCE		Oxford		TRI	
	训练集	测试集	训练集	测试集	训练集	测试集
电池标号	CS36	CS35; CS37; CS38	Cell1	Cell3; Cell7; Cell8	b0c31	b0c32; b0c34; b0c35
循环次数	791	716; 857; 849	78	76; 77; 76	839	683; 683; 640

3.2 参与比较的方法

所提方法的优势在于两个方面:①可以适用于不同的充电策略;②采用的 SVQR 方法可以在小样本数据集上更好地进行 SOH 区间估计. 第一个优势显而易见,如文献[13-14]的方法都针对某一特定充电策略,在遇到不同充电策略时所提取的特征参数不再适用. 为此,在实验部分重点论证所采用的 SVQR 相比于其他区间预测方法的优越性. 首先对比 SVQR 与 QR、QRNN、QR 把分位数的概念融入普通的线性回归中,本质上是一种线性方法;QRNN 将分位数概念与神经网络结合以解决非线性回归问题. 此外,最近 GPR 被报道在处理锂电池 SOH 区间估计方面具有优秀性能^[15],因此还将 SVQR 方法与 GPR 方法进行对比.

3.3 评价指标

为全面验证所提方法的性能,采用如下 3 个指标来评价 SOH 区间估计结果的优劣:平均区间分数(Average Interval Score, AIS)^[30]、平均预测区间中心偏差(Mean Prediction Interval Center Deviation, MPICD)^[31]以及平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)^[32]. 上述指标包含对估计结果区间宽度、区间覆盖率以及估计偏差等信息的衡量,各自定义如下:

(1) AIS 指标. AIS 指标定义为所有区间估计点的区间分数均值,可综合衡量区间覆盖率和区间宽度,其值越大越优,按下式计算.

$$\overline{S^{(a)}} = \frac{1}{N_{\text{test}}} \sum_{i=1}^{N_{\text{test}}} S^{(a)}(\mathbf{x}_i)$$

(10)

式中: α 为置信区间宽度; N_{test} 为测试集电池循环次数; $S^{(a)}(\mathbf{x}_i)$ 为第 i 个估计区间的区间分数,定义为

$$\begin{cases} -2\alpha\zeta_i^{(a)} - 4(L^{(a)}(\mathbf{x}_i) - y_i), & y_i < L^{(a)}(\mathbf{x}_i) \\ -2\alpha\zeta_i^{(a)}, & L^{(a)}(\mathbf{x}_i) \leq y_i \leq U^{(a)}(\mathbf{x}_i) \\ -2\alpha\zeta_i^{(a)} - 4(y_i - L^{(a)}(\mathbf{x}_i)), & y_i > U^{(a)}(\mathbf{x}_i) \end{cases}$$

(11)

式中: $L^{(a)}(\mathbf{x}_i)$ 、 $U^{(a)}(\mathbf{x}_i)$ 分别为预测下限和上限; y_i 为第 i 个评估点的实际值; $\zeta_i^{(a)} = U^{(a)}(\mathbf{x}_i) - L^{(a)}(\mathbf{x}_i)$, 为第 i 个预测区间的宽度.

(2) MPICD 指标. MPICD 表示预测区间中心位置与实际值的偏差,该值越小越优,按下式计算.

$$I_{\text{MPICD}} = \frac{1}{N_{\text{test}}} \sum_{i=1}^{N_{\text{test}}} \left| \frac{U^{(a)}(\mathbf{x}_i) - L^{(a)}(\mathbf{x}_i)}{2} - y_i \right|$$

(12)

(3) MAPE 指标. MAPE 按下式计算,该指标可衡量预测区间的宽度信息,狭窄的区间比宽大的区间更好.

$$I_{\text{MAPE}} = \frac{1}{N_{\text{test}}} \sum_{i=1}^{N_{\text{test}}} \left| \frac{U_i - L_i}{L_i} \right|$$

(13)

式中: L_i 、 U_i 分别为预测下限和上限.

4 实验结果与分析

经过特征提取和交叉验证特征自动优选过程,最终对 CALCE 数据集选择 IC 曲线峰值、IC 曲线峰值对应电压、IC 曲线左斜率、CC 充电上升到给定电压所用时间、CV 充电下降到给定电流所用时间 5 个特征;对 Oxford 数据集选择 IC 曲线峰值、IC 曲线左斜率、IC 曲线右斜率 3 个特征;对 TRI 数据集选择 IC 曲线峰值、IC 曲线右斜率、CV 充电下降到给定电流所用时间 3 个特征. 为了实验对比的公平性,其余 3 种方法在评估时针对不同的数据集采用与 SVQR 方法同样的特征参数. 表 3~5 分别展示所提方法与 QR、QRNN 和 GPR 方法分别在 CALCE、Oxford 和 TRI 数据集中各自任选的 3 个单体电池上的 SOH 评估结果,其中用粗体标出的为最优结果. 图 6~8 分别展示 4 种方法在 3 个数据集中 CS35、Cell7、b0c32 这 3 个电池上的 SOH 估计效果.

首先,从图 6~8 和表 3~5 可以看出,在所有数据集上,对于所有的评价指标 QRNN 与 QR 结果比较接近,但都远劣于 SVQR;QRNN 略优于 QR,这印证了 QR 本质上是线性回归方法,其在处理锂电池 SOH 非线性估计上性能不足. 而 QRNN 性能远劣于 SVQR,这充分印证了在本文数据集的量级上,SVQR 处理小样本非线性问题时具有更好的泛化能力. 其次,在所有实验中 SVQR 方法的结果与 GPR 接近,但在多数电池上多数指标都优于 GPR 方法. 尤其在 MAPE 指标方面,SVQR 方法在所有

数据集上全优于 GPR. AIS 指标方面,SVQR 方法在 Oxford 和 TRI 数据集上均取得最好结果,仅在 CALCE 数据集上,劣于 GPR 方法;MPICD 指标方面,SVQR 方法在 CALCE 和 Oxford 数据集上除

Cell7 电池外,均明显优于 GPR,仅在 TRI 数据集上略劣于 GPR. 文献[15]报道,GPR 方法是目前处理锂电池 SOH 估计的最优方法.但实际上,GPR 需要假设数据服从高斯分布,而实测的锂电池充放电数




图 6 4 种方法在 CALCE 数据集 CS35 电池的 SOH 区间估计对比结果
Fig. 6 Comparison of four methods for estimating SOH interval of CS35 battery in CALCE dataset




图 7 4 种方法在 Oxford 数据集 Cell7 电池的 SOH 区间估计对比结果
Fig. 7 Comparison of four methods for SOH interval estimation of Cell7 battery in Oxford dataset




图 8 4 种方法在 TRI 数据集 b0c32 电池的 SOH 区间估计对比结果
Fig. 8 Comparison of four methods in estimating SOH interval of b0c32 battery in TRI dataset

表 3 CALCE 数据集 3 个单体电池的 SOH 估计对比结果

Tab. 3 Comparison of SOH estimation of three single cells in CALCE dataset

10⁻³

单体电池	方法	AIS	MPICD	MAPE
CS35	QR	−0.147 2	1.679	12.39
	QRNN	−0.149 9	3.792	11.05
	SVQR	−0.058 2	0.97	6.62
	GPR	−0.052 4	3.109	16.32
CS37	QR	−0.121 1	1.816	12.07
	QRNN	−0.126 2	1.575	10.78
	SVQR	−0.051 3	0.707	5.46
	GPR	−0.041 6	0.959	14.57
CS38	QR	−0.125 6	4.773	12.39
	QRNN	−0.128 5	2.773	11.03
	SVQR	−0.086 8	1.64	7.29
	GPR	−0.056 7	2.232	18.1

表 4 Oxford 数据集 3 个单体电池的 SOH 估计对比结果

Tab. 4 Comparison of SOH estimation of three single cells in Oxford dataset

10⁻³

单体电池	方法	AIS	MPICD	MAPE
Cell3	QR	−1.946	1.91	105.36
	QRNN	−1.614	1.68	87.19
	SVQR	−0.43	1.34	19.892
	GPR	−0.698	2.49	32.63
Cell7	QR	−1.904	11.19	104.17
	QRNN	−1.567	3.96	84.75
	SVQR	−0.402	3.75	18.99
	GPR	−0.651	2.12	32.48
Cell8	QR	−1.929	2.709	105.35
	QRNN	−1.611	2.57	87.51
	SVQR	−0.4	0.322	20.54
	GPR	−0.705	3.218	32.56

表 5 TRI 数据集 3 个单体电池的 SOH 估计对比结果

Tab. 5 Comparison of SOH estimation of three single cells in TRI dataset

10⁻³

单体电池	方法	AIS	MPICD	MAPE
b0c32	QR	−0.031 2	1.934	12.39
	QRNN	−0.028 3	1.2	11.05
	SVQR	−0.023 4	1.811	6.62
	GPR	−0.041 1	0.035	16.326
b0c34	QR	−0.030 4	2.274	12.07
	QRNN	−0.027 3	1.51	10.78
	SVQR	−0.019 8	2.67	5.46
	GPR	−0.036 8	0.416	14.57
b0c35	QR	−0.036 2	3.49	12.39
	QRNN	−0.034	2.561	11.03
	SVQR	−0.033 1	3.972	7.29
	GPR	−0.050 8	1.13	18.1

据涉及复杂过程和噪声干扰,很难确保满足高斯假设.本文所提 SVQR 则无需此假设,这可以解释上述实验中 SVQR 总体优于 GPR 的原因.另外值得指出的是,实验采用同一充电协议下的某一放电深度较深电池的全生命期循环充放电数据来训练 SVQR 模型,用同数据集中其他电池来测试,这与其他多数研究采用同一电池的部分充放电数据来预测其剩余循环的退化情况相比更有实际意义.上述结论充分证明本文方法在 SOH 估计方面的优势.

5 结论

提出一种考虑不同充电策略的锂电池剩余容量 SVQR 区间估计方法.该方法在离线阶段,从锂电池充放电电压、电流及容量增量曲线中获取多个特征,并采用交叉验证方法自动选择最优特征组合.选取放电程度较深的单体电池循环充放电数据训练 SVQR 模型.在 SOH 在线估计阶段,采用和训练模型相同的特征作为模型输入,对服役中的锂电池进行 SOH 区间估计.最后在 3 个采用不同充电策略的数据集验证所提方法,并与 QR、QRNN 和 GPR 方法进行对比,可得出以下结论:

(1) 在不同充电策略下,利用相同外部特征对于锂电池 SOH 的估计结果也不同.采用两步特征提取策略,即首先针对不同充电策略提取足够多特征,再选取针对不同电池及充电策略的个性化特征参数,可以显著提高电池 SOH 估计的精度,且具有良好的普适性.

(2) 神经网络类方法的训练需要较大数据集样本,但在样本量有限的锂电池充放电数据集中神经网络类算法估计效果有限.而 SVQR 利用 SVR 算法适用于小样本数据集的特点,即使是在小样本条件下也可以较好地置信区间内估计锂电池 SOH.

(3) 相较于文献报告的当前最优的 GPR 方法,所提 SVQR 方法无需原始数据服从高斯分布,可在一定置信区间内实现较好的 SOH 估计结果,具有更好的适应性和鲁棒性.

参考文献:

[1] 孙丙香,任鹏博,陈育哲,等. 锂离子电池在不同区间下的衰退影响因素分析及任意区间的老化趋势预测[J]. *电工技术学报*, 2021, 36(3): 666-674.
SUN Bingxiang, REN Pengbo, CHEN Yuzhe, *et al.* Analysis of influencing factors of degradation under different interval stress and prediction of aging trend in any interval for lithium-ion battery[J]. *Transactions of China Electrotechnical Society*, 2021, 36(3):

666-674.

- [2] 杨胜杰,罗冰洋,王菁,等. 基于容量增量曲线峰值区间特征参数的锂离子电池健康状态估算[J]. *电工技术学报*, 2021, 36(11): 2277-2287.
YANG Shengjie, LUO Bingyang, WANG Jing, *et al.* State of health estimation for lithium-ion batteries based on peak region feature parameters of incremental capacity curve[J]. *Transactions of China Electrotechnical Society*, 2021, 36(11): 2277-2287.
- [3] 卢地华,陈自强. 基于双充电状态的锂离子电池健康状态估计[J]. *上海交通大学学报*, 2022, 56(3): 342-352.
LU Dihua, CHEN Ziqiang. State of health estimation of lithium-ion batteries based on dual charging state [J]. *Journal of Shanghai Jiao Tong University*, 2022, 56(3): 342-352.
- [4] 李建林,李雅欣,陈光,等. 退役动力电池健康状态特征提取及评估方法综述[J]. *中国电机工程学报*, 2022, 42(4): 1332-1347.
LI Jianlin, LI Yaxin, CHEN Guang, *et al.* Research on feature extraction and SOH evaluation methods for retired power battery[J]. *Proceedings of the CSEE*, 2022, 42(4): 1332-1347.
- [5] 张立强. 锂离子电池多物理模型参数辨识及健康特征提取[D]. 哈尔滨: 哈尔滨工业大学, 2015.
ZHANG Liqiang. Parameter identification and health feature extraction of multi-physical model of lithium-ion battery[D]. Harbin: Harbin Institute of Technology, 2015.
- [6] 王震坡,王秋诗,刘鹏,等. 大数据驱动的动力电池健康状态估计方法综述[J]. *机械工程学报*, 2023, 59(2): 151-168.
WANG Zhenpo, WANG Qiushi, LIU Peng, *et al.* Review on techniques for power battery state of health estimation driven by big data methods [J]. *Journal of Mechanical Engineering*, 2023, 59(2): 151-168.
- [7] 李凯铨,汪玉洁. 锂离子电池的健康状态估计综述[C]// *系统仿真技术及其应用*. 安徽: 中国科学技术大学, 2021: 330-333.
LI Kaiquan, WANG Yujie. A review of the estimation of the state of health of lithium-ion batteries[C] // *System Simulation Technology & Its Application*. Anhui, China: University of Science and Technology of China, 2021: 330-333.
- [8] OSPINA AGUDELO B, ZAMBONI W, MONMASON E. Application domain extension of incremental capacity-based battery SoH indicators[J]. *Energy*, 2021, 234: 121224.

- [9] SHE C Q, WANG Z P, SUN F C, *et al.* Battery aging assessment for real-world electric buses based on incremental capacity analysis and radial basis function neural network[J]. **IEEE Transactions on Industrial Informatics**, 2020, 16(5): 3345-3354.
- [10] 徐宏东, 高海波, 徐晓滨, 等. 基于证据推理规则 CS-SVR 模型的锂离子电池 SOH 估算[J]. **上海交通大学学报**, 2022, 56(4): 413-421.
XU Hongdong, GAO Haibo, XU Xiaobin, *et al.* State of health estimation of lithium-ion battery using a CS-SVR model based on evidence reasoning rule [J]. **Journal of Shanghai Jiao Tong University**, 2022, 56(4): 413-421.
- [11] WANG Z K, ZENG S K, GUO J B, *et al.* State of health estimation of lithium-ion batteries based on the constant voltage charging curve[J]. **Energy**, 2019, 167: 661-669.
- [12] 石伟杰, 王海民. 基于锂离子电池热特性的 SOH 在线诊断模型研究[J]. **仪器仪表学报**, 2020, 41(8): 206-216.
SHI Weijie, WANG Haimin. On-line diagnosis model of SOH based on thermal characteristics of lithium-ion battery[J]. **Chinese Journal of Scientific Instrument**, 2020, 41(8): 206-216.
- [13] 王萍, 弓清瑞, 张吉昂, 等. 一种基于数据驱动与经验模型组合的锂电池在线健康状态预测方法[J]. **电工技术学报**, 2021, 36(24): 5201-5212.
WANG Ping, GONG Qingrui, ZHANG Ji'ang, *et al.* An online state of health prediction method for lithium batteries based on combination of data-driven and empirical model[J]. **Transactions of China Electrotechnical Society**, 2021, 36(24): 5201-5212.
- [14] 刘金枝, 杨鹏, 李练兵. 一种基于能量建模的锂离子电池电量估算方法[J]. **电工技术学报**, 2015, 30(13): 100-107.
LIU Jinzhi, YANG Peng, LI Lianbing. A method to estimate the capacity of the lithium-ion battery based on energy model[J]. **Transactions of China Electrotechnical Society**, 2015, 30(13): 100-107.
- [15] ROMAN D, SAXENA S, ROBU V, *et al.* Machine learning pipeline for battery state-of-health estimation [J]. **Nature Machine Intelligence**, 2021, 3(5): 447-456.
- [16] LI K W, WANG R, LEI H T, *et al.* Interval prediction of solar power using an improved bootstrap method[J]. **Solar Energy**, 2018, 159: 97-112.
- [17] LI H, PAN D H, PHILIP CHEN C L. Intelligent prognostics for battery health monitoring using the mean entropy and relevance vector machine[J]. **IEEE Transactions on Systems, Man, & Cybernetics: Systems**, 2014, 44(7): 851-862.
- [18] 曹孟达. 卫星电源部件在轨退化状态评估方法研究[D]. 长沙: 国防科技大学, 2019.
CAO Mengda. Research on evaluation method of on-orbit degradation state of satellite power components [D]. Changsha: National University of Defense Technology, 2019.
- [19] 魏中宝, 钟浩, 何洪文. 基于多物理过程约束的锂离子电池优化充电方法[J]. **机械工程学报**, 2023, 59(2): 223-232.
WEI Zhongbao, ZHONG Hao, HE Hongwen. Multiphysics-constrained optimal charging of lithium-ion battery[J]. **Journal of Mechanical Engineering**, 2023, 59(2): 223-232.
- [20] 吴晓刚, 崔智昊, 孙一钊, 等. 电动汽车大功率充电过程动力电池充电策略与热管理技术综述[J]. **储能科学与技术**, 2021, 10(6): 2218-2234.
WU Xiaogang, CUI Zhihao, SUN Yizhao, *et al.* Summary of charging strategy and thermal management technology of power battery in high-power charging process of electric vehicle[J]. **Energy Storage Science & Technology**, 2021, 10(6): 2218-2234.
- [21] 郭剑成, 王惜慧, 岑海林. 一种基于温度变化的动力电池智能充电策略[J]. **电源技术**, 2022, 46(5): 518-522.
GUO Jiancheng, WANG Xihui, CEN Hailin. An intelligent charging strategy of power battery based on temperature change [J]. **Chinese Journal of Power Sources**, 2022, 46(5): 518-522.
- [22] KOENKER R, BASSETT G. Regression quantiles [J]. **Econometrica**, 1978, 46(1): 33-50.
- [23] CRISTIANINI N, SHAWE-TAYLOR J. An introduction to support vector machines and other kernel-based learning methods[M]. Cambridge: Cambridge University Press, 2000.
- [24] TAKEUCHI I, FURUHASHI T. Non-crossing quantile regressions by SVM[C]// **2004 IEEE International Joint Conference on Neural Networks**. Budapest, Hungary: IEEE, 2004: 401-406.
- [25] SHIM J, KIM Y, LEE J, *et al.* Estimating value at risk with semiparametric support vector quantile regression[J]. **Computational Statistics**, 2012, 27(4): 685-700.
- [26] YUAN M. GACV for quantile smoothing splines[J]. **Computational Statistics & Data Analysis**, 2006, 50(3): 813-829.
- [27] HE W, WILLIARD N, OSTERMAN M, *et al.* Prognostics of lithium-ion batteries based on Demp-

ster-Shafer theory and the Bayesian Monte Carlo method[J]. **Journal of Power Sources**, 2011, 196 (23): 10314-10321.

[28] BIRKL C. Diagnosis and prognosis of degradation in lithium-ion batteries[D]. Oxford, UK: University of Oxford, 2017.

[29] SEVERSON K A, ATTIA P M, JIN N, *et al.* Data-driven prediction of battery cycle life before capacity degradation[J]. **Nature Energy**, 2019, 4 (5): 383-391.

[30] LIAN C, ZHU L Z, ZENG Z G, *et al.* Constructing prediction intervals for landslide displacement using bootstrapping random vector functional link networks selective ensemble with neural networks switched[J]. **Neurocomputing**, 2018, 291: 1-10.

[31] LIAN C, ZENG Z G, WANG X P, *et al.* Landslide displacement interval prediction using lower upper bound estimation method with pre-trained random vector functional link network initialization[J]. **Neural Networks**, 2020, 130: 286-296.

[32] 何耀耀, 刘瑞, 撒奥洋. 基于实时电价与支持向量分位数回归的短期电力负荷概率密度预测方法[J]. **中国电机工程学报**, 2017, 37(3): 768-775.
HE Yaoyao, LIU Rui, HAN Aoyang. Short-term power load probability density forecasting method based on real time price and support vector quantile regression[J]. **Proceedings of the CSEE**, 2017, 37 (3): 768-775.

(本文编辑:王历历)