

DOI: 10.13382/j.jemi.B2508181

# 基于静置电压曲线和改进后 DBSCAN 聚类算法的 退役电池 SOH 快速估计策略\*

黄海宏 刘鑫

(合肥工业大学电气与自动化工程学院 合肥 230009)

**摘要:**退役动力电池即将迎来回收高峰,二次利用可以有效避免电池退役造成的资源浪费和环境污染。健康状态(state of health, SOH)评估是退役电池二次使用场景的关键依据,但是传统的退役电池 SOH 估计方法存在耗时和耗能的缺点。在将退役电池放电至相同电压下限后,不同 SOH 电池的荷电状态(state of charge, SOC)将存在差异,导致不同 SOH 电池静置电压曲线变化趋势不同。提出基于静置电压曲线的退役电池 SOH 快速估计策略,从这种静置电压差异中分析健康特征,可实现退役电池 SOH 的快速估计。针对在退役电池数据采集时部分电池会由于采集误差形成离群点,进而会导致训练集无法正确训练回归算法模型的问题,分析了离群点数量对回归算法估计电池 SOH 精度的影响,并利用基于密度的聚类算法(density-based spatial clustering of applications with noise, DBSCAN)标识这些离群点,并在此基础上提出了离群点标识效果评估方法,可避免离群点影响 SOH 估计模型的准确性,有效提高了 SOH 估计精度。

**关键词:**磷酸铁锂电池;静置电压;健康状态;快速估计

中图分类号: TN0; TM93

文献标识码: A

国家标准学科分类代码: 470.40

## Rapid SOH estimation strategy for retired batteries based on resting voltage curves and DBSCAN clustering algorithm

Huang Haihong Liu Xin

(School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

**Abstract:** The recycling of retired power batteries is about to reach a peak. The secondary use of retired batteries can effectively avoid the waste of resources and environmental pollution. State of health (SOH) assessment is a key evaluation index for the secondary use. But traditional methods for estimating the SOH have the disadvantages of time and energy consumption. This paper proposes a rapid estimation strategy for the SOH of retired batteries based on resting voltage curves. After discharging the retired batteries to the same voltage lower limit, there will be differences in the state of charge (SOC) of different SOH batteries. Eventually, the resting voltage curves of different SOH batteries varies. By analyzing the health characteristics from this resting voltage difference, this paper achieves rapid estimation of the SOH of retired batteries. There are outliers in data collection due to acquisition errors, which can lead to incorrect training of regression algorithm models in the training set. In order to address this problem, this paper analyzes the impact of the number of outliers on the accuracy of regression algorithm estimation of SOH. This paper proposes using the density-based spatial clustering of applications with noise (DBSCAN) clustering algorithm to identify these outliers. The identifications of outliers can avoid the impact of outliers on the accuracy of SOH estimation model and effectively improve the accuracy of SOH estimation.

**Keywords:** lithium iron phosphate battery; static voltage; state of health; fast estimation

## 0 引言

新能源产业近些年发展十分迅猛,锂电池由于高能

量密度、低成本以及长寿命被应用于汽车、储能等场景<sup>[1-2]</sup>。随着时间的推移,越来越多的动力电池面临退役后如何处理的问题。电池的剩余健康状态(state of health, SOH)跌至 70%~80%时,将被视为不适合继续在

车载场景使用<sup>[3]</sup>。另外汽车故障以及模组内小部分电池故障也会造成整个电池模组退役。退役电池多样化的退役原因导致退役电池的残值性能参数参差不齐,需要根据电池剩余性能进行分选<sup>[4-5]</sup>。

SOH 被用于描述退役电池的老化程度,是判定退役电池二次利用的场景的关键因素<sup>[6-7]</sup>。SOH 无法通过直接检测获得,只能依赖电压、电流、温度、内阻等信息进行推测<sup>[8]</sup>。退役电池 SOH 评估在离线场景下进行,但现有相关 SOH 估计研究主要针对车载在线场景。安时积分法通过累积电池在放电过程中释放的电荷量<sup>[9]</sup>,具备精度高的优点,但也由于耗时问题难以适应退役电池快速二次分选的需求。安时积分法会受到电流、电压采集误差的影响,自适应滤波算法为此被提出用于降低测量误差对 SOH 估计精度的影响。常见的自适应滤波算法包括卡尔曼滤波、粒子滤波、神经网络算法。文献[10]建立了一个新的分数阶模型,提出一种基于卡尔曼滤波的改进 SOH 和荷电状态(state of charge, SOC)联合估计方法。文献[11]提出一种动态迁徙模型,结合粒子滤波实现了电池 SOC 和 SOH 的联合估计。但是这类方法仅适用于在线场景,无法在未知历史数据的退役电池分选场合中应用。数据驱动方法将电池视为黑盒子模型,通过分析电池老化过程中健康特征(health factor, HF)的变化规律结合人工智能算法实现 SOH 的估计<sup>[12]</sup>。人工智能算法以及 HF 都会影响 SOH 的估计效果,故针对数据驱动 SOH 估计方法的研究主要围绕这两方面。人工智能算法需要依赖充足的训练数据,常见的人工智能算法包括人工神经网络、支持向量机、相关向量机、高斯过程回归、随机森林回归(random forest regression, RFR)等。文献[13]从电池电压和温度中提取 HF,并在此基础上提出一种基于数据驱动模型的 SOH 估计算法。文献[14]从电池充电过程中的电流、电压以及温度数据中提取 HF,结合人工神经网络实现了 SOH 的估计。文献[15]提出利用粒子群优化算法解决长短时记忆网络的超参数选取问题,从增量容量曲线中提取 HF 实现了 SOH 估计。文献[16]从电池充放电的历史数据中提取了 4 个 HF,提出一种改进的蚁群优化支持向量回归(support vector regression, SVR)算法实现了 SOH 的估计。与在线场景不同,退役电池 SOH 估计拥有充足的算力且对实时性的要求很低,这也是数据驱动算法能够被应用于退役电池 SOH 估计的原因之一。

离群点,也称为歧异值或野值,是数据集中显著偏离大部分数据的数据点<sup>[17]</sup>。数据驱动算法在利用包含离群点的数据集估计电池 SOH 时,SOH 估计精度会受到离群点的影响。离群点存在的原因包括检测失误以及电池经历异常工况等原因,在大量退役电池测试中不可避免会产生离群点。目前针对离群点检测方法已经有较为广

泛的研究,但缺乏对退役电池估计 SOH 时离群点相关的分析论述。离群点检测方法大致分为基于统计模型方法、基于距离方法和基于聚类方法<sup>[18]</sup>。基于统计模型方法通过假定数据集服从特定的概率分布,根据数据在概率分布中的位置判断离群点。基于距离的离群点检测方法通过计算数据点之间的距离判定离群点;当距离小于设定阈值时为正常点;当距离大于正常值时即为离群点。基于聚类的离群点检测方法通过对数据聚类分析,按照数据的潜在特征将数据分为多个簇<sup>[19]</sup>。异常电池 HF 数据会以离群点的形式影响建立退役电池快速评估模型的准确度。HF 会按照特定的趋势随着 SOH 变化,离群点往往以单独点或者簇偏离大多数数据存在。但是退役电池 HF 中离群点存在的形式并不特定,HF 数据集难以确定具体的概率分布函数且离群点与正常数据的距离阈值无法确定。为此,本文提出利用基于密度的聚类算法(density-based spatial clustering of applications with noise, DBSCAN)识别退役电池数据集中的离群点,从而避免离群点对训练集的污染。

除了人工智能算法,HF 也对电池 SOH 估计效果有很大的影响。特征提取是退役电池 SOH 估计中的关键一步,其过程应简单、快速。在线场景下,车载电池的 HF 能够从历史数据中提取,且电池的 SOC 是已知的,这使得电池 SOH 特征能够从特定 SOC 下获取。文献[20]提出从电池运行的温度中提取 HF 结合神经网络算法实现 SOH 的估计。但是退役电池检测时电池的历史数据未知,且 SOC 也是未知的。文献[21]从电化学阻抗谱中提取 HF 并结合高斯过程回归实现电池 SOH 估计,但是电化学阻抗谱在不同 SOC 时不同。不同电池退役时 SOC 不同且退役电池在检测前由于经历过长时间运输会导致电荷量损失,故退役电池检测时 SOC 难以确定。文献[22]从增量容量曲线中提取 HF,利用 SVR 估计电池 SOH,但是增量容量曲线的获取需要长时间的充放电数据。增量容量法是从电池充放电曲线中提取 HF 估计电池 SOH 的常见方法,但是增量容量曲线需要以小电流对电池进行充放电获取完整的充电或放电曲线,这个过程耗费大量时间。文献[23]提出了一种基于充电段的区间容量老化 FP 及其提取方法,然后结合数据驱动算法估计电池 SOH。但基于充电曲线的 FP 需要在退役电池特定 SOC 下获取,这使得这种方法很难估计未知 SOC 退役电池的 SOH。车载电池的 HF 可以基于在线数据获取,但退役电池二次分选场景时电池历史数据未知且电池状态多种多样。针对以上问题,本文提出了一种适用于未知 SOC 退役电池快速 SOH 估计策略,将退役电池放电至特定电压后从静置曲线中提取 HF,具有耗时短、易实现的优点。

磷酸铁锂电池是电动汽车和储能系统退役可再利用

电池的主流,所以本文研究针对磷酸铁锂电池展开。分析了离群点数据对 SOH 估计效果的影响,提出了基于改进后 DBSCAN 算法的异常退役电池数据标识方法及标识效果评估方程,旨在降低离群点对电池数据驱动模型的影响。提出通过磷酸铁锂电池放电至不同截止电压后构造静置电压与 SOH 的相关性,研究了基于退役电池静置电压曲线的 SOH 快速估计方法,能够利用低成本设备大幅降低退役电池 SOH 估计耗时。

## 1 健康特征获取

退役电池测试时,电池的 SOC 未知且并不固定。而电池的电压、内阻等参数均受到 SOC 的影响,因此退役电池的 SOH 提取过程需要基于固定的 SOC 或者已知电池 SOC。退役电池处于离线状态,退役电池能够以恒定电流放电,本文提出将电池放电至指定电压后分析静置电压从而提取 HF。首先,将退役电池恒流放电至设定的电压下限,从而保持不同退役电池处于相同的基准;然后,将退役电池静置 3 min 后,分析静置过程中电压曲线的变化。

常见的等效电路模型包括 Rint 模型、Randles 模型、PNGV 模型、 $n$  阶 RC 模型和 RC 分数阶模型等,这些模型在模型精度和运算复杂度上有不同的特点。图 1 所示是 Thevenin 等效电路模型,具有简单精度高的优点。其中由开路电压、欧姆电阻  $R_0$  以及极化电阻  $R_1$  以及电容  $C$  组成。其中欧姆内阻  $R_0$  包含接触电阻和导线电阻。电池的端电压由开路电压、 $R_0$  承担的电压分量、 $R_1$  与  $C$  承担的电压分量 3 部分组成,而  $R_0$  和  $R_1$  承担的电压分量受到电流的影响。图 1 中,当电池充电时, $I$  为正;当电池放电时, $I$  为负。

$$U_{ct} = R_0 I + IR_1 e^{(-C_1 R_1 I)} + U_{ocv} \quad (1)$$




图 1 Thevenin 等效电路模型

Fig. 1 Thevenin equivalent circuit model

随着电池的老化,电池内部的活性物质以及电解液的浓度逐渐降低,同时固态电解质膜的厚度逐渐增加。这造成电池内的电子和离子在运动过程中阻力逐渐增

大,进而导致电池内阻逐渐增加。如图 1 所示,电池的端电压由开路电压、电池内阻以及电流决定。如果所有退役电池测试时的放电电流且放电截止的电压相同,放电截止时内阻越大的退役电池对应的开路电压  $U_{ocv}$  越高。当放电过程停止时, $R_0$  和  $R_1$  承担的电压分量迅速跌落,电池端电压逐渐回升最终趋于稳定。因此,当放电停止时,老化程度越高(SOH 越低)的退役电池对应剩余的 SOC 越高,同时相应的开路电压越高。这种特征使得可以从电池放电停止后静置电压变化中提取 HF,但是放电电压下限的选取影响着不同 SOH 电池静置电压之间的差异。

电池开路电压(OCV)与 SOC 关系如图 2 所示,当 SOC 介于 10%~90% 时,磷酸铁锂电池开路电压随 SOC 变化幅度很小。而在 SOC 接近 0 或 1 时,磷酸铁锂电池开路电压随 SOC 变化特别大。当电池 SOC 接近 0% 时,磷酸铁锂电池微小的 SOC 差异能够从电池静置电压中体现出来,使得从电池电压中提取 HF 可在电池低 SOC 时获取。




图 2 电池开路电压与 SOC 关系

Fig. 2 Open-circuit voltage versus SOC

基于以上分析,本文将退役电池以恒定电流放电至相同的电压下限,然后从电压曲线中提取 HF。合适的放电电压下限便于从电池电压中分析不同退役电池 SOC 的差异,放电电压下限的选择是需要分析的另一问题。如果放电电压下限选取的值过高,退役电池剩余 SOC 可能会介于 10%~90%,此时由于磷酸铁锂电池电压的平坦区,无法从磷酸铁锂电池电压中分析不同 SOH 电池的 SOC 差异。

如果放电设定的电压下限过低,则不同 SOH 电池之间的 SOC 差异较小,导致相应的电压差异较小。一般,磷酸铁锂电池的放电电压下限在 2~2.5 V 之间以避免电池过放而对电池造成永久性伤害。如果需要准确获取退役电池的容量,则退役电池的放电截止电压应在安全范围内设置的尽可能低以避免内阻大的退役电池未充分放电。如果需要放电停止时不同 SOH 电池的静置电压

曲线存在差异,则放电电压下限应避免过低使得低 SOH 电池不能充分放电而高 SOH 电池被充分放电。本文选取放电电压下限为 2.5 V,此时 SOH 高内阻低的电池 SOC 接近 0,但是 SOH 低、内阻大的电池 SOC 未接近 0。开路电压与电池 SOC 有稳定的关联性,但开路电压的获取需要对退役电池进行数小时的静置,所以本文未将开路电压作为判定不同 SOH 电池 SOC 差异的 HF。

为保证退役电池 HF 获取的快速性,可记录电池放电结束后的 3 min 静置电压分析不同 SOH 电池端电压差异。放电过程停止后,电池端电压迅速回升,不同 SOH 电池静置电压由于 SOC 差异回升幅度和速度存在差异。如图 3 所示,不同 SOH 的退役电池被放电至相同的放电电压下限 2.5 V。当放电停止时,电池电压快速回升。在静置大约 20 s 后,电池电压的回升速度逐渐变慢,最终趋于稳定,且随着电池 SOH 的增加,静置过程电池电压的增加幅度逐渐降低。这是由于高 SOH 电池被充分放电,当放电电压到达 2.5 V 时剩余的 SOC 较高;而低 SOH 电池由于电池内阻增加,当放电电压到达 2.5 V 时剩余的 SOC 较高。本文提出基于以上描述的退役电池静置电压特性提取 HF,从而实现退役电池的 SOH 快速估计。




图 3 不同 SOH 电池静置电压随时间变化

Fig. 3 Variation of resting voltage with time for different SOH cells

如图 4 所示,为了充分利用静置过程中的电池电压,需要等间距将静置过程划分为若干时间间隔。如果选取的时间间隔如果过大,则电池静置过程不能得到充分利用。本文将静置回压过程划分为 6 个区间,然后选取电池停止放电后特定时刻电池电压  $V_1 \sim V_6$  作为 HF。 $V_1 \sim V_6$  依次是静置阶段开始后 30、60、90、120、150、180 s 时刻电池的电压,这些电压被用于分析在电池恒流放电结束后电池回压的幅度。老化程度越高的电池,在恒流放电结束时电池所剩余的 SOC 越高,电池回压的幅度越高。因此, $V_1 \sim V_6$  与电池 SOH 呈现负相关性,这是选取

这些电压作为 HF 的原因。




图 4 静置特征电压选取示意图

Fig. 4 Schematic diagram of characteristic voltage selection

## 2 退役电池 SOH 快速估计策略

由于退役电池的 SOH 检测是在离线情况下实现,故数据驱动算法能够依赖充足计算能力的计算机被用于 SOH 的估计。HF 和数据驱动算法都影响着 SOH 估计效果,但是传统的 SOH 估计策略存在耗时和耗能问题。如图 5 所示,基于不同 SOH 电池静置电压差异,本文提出了基于静置电压差异的 SOH 估计策略,HF 具体步骤如下。

1) 将退役电池放电至设定的电压下限 2.5 V;对于开路电压小于 3.1 V 的退役电池,需要先将其充电 10% 额定容量后再放电至电压下限 2.5 V。

2) 将退役电池静置 3 min 并记录电压曲线。

3) 由于不同 SOH 退役电池的 SOC 不同,电压在放电停止后,静置电压回升幅度也不同。从静置电压曲线中提取 HF。

本文提出基于静置电压曲线的 HF 提取方法,旨在降低退役电池分选时 SOH 的评估时间。在选取合适的 HF 后,需要讨论如何充分利用 SOH 特征实现退役 SOH 的快速估计。从选取退役电池回归算法以及解决测试数据中离群点影响 SOH 估计精度两种角度说明本文提出的退役电池 SOH 快速估计策略。

### 2.1 支持向量回归

为了充分利用静置电压曲线中的健康特征,本文采用 SVR 算法结合 HF 构建 SOH 估计模型。SVR 是一种基于支持向量机的回归方法,将所有样本点整理到一个超平面上,以样本最小点距离超平面的距离最小为目标,寻找最优回归超平面。在不敏感损失函数  $\varepsilon$  的控制下,通过引入惩罚参数  $C$  和松弛因子  $\xi_i$  和  $\xi_i^* > 0$  来求解超平面。回归问题的最优超平面应满足:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

$$\text{s. t.} \begin{cases} y_i - \omega x_i - b \leq \varepsilon + \xi_i \\ \omega x_i + b - y_i \leq \varepsilon + \xi_i^* \end{cases}$$

$$i = 1, 2, \dots, n \quad (2)$$

通过引入拉格朗日乘子构造拉格朗日函数:

$$L = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i + y_i - \omega x_i - b) - \sum_{i=1}^n (\mu_i \xi_i + \mu_i^* \xi_i^*) \quad (3)$$

利用 KKT (Karush-Kuhn-Tucker) 条件得到最优解, 代入拉格朗日函数中即可得到 SVR 的对偶问题:

$$\max - \frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) \quad (4)$$

$$\text{s. t.} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0; 0 \leq \alpha_i, \alpha_i^* \leq C$$

式中:  $\alpha_i, \alpha_i^*, \alpha_j, \alpha_j^*$  代表拉格朗日乘子。代入回归函数中, 得到 SVR 回归预测模型为:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (5)$$

## 2.2 DBSCAN 的聚类算法

退役电池测试时, 部分电池会由于检测原因产生离群点数据。离群点通常指残差非常大的点, 模型预测的 SOH 值与真实的 SOH 值相差非常大。如果未正确检测并处理离群点, 包含离群点的训练集无法正确训练回归算法模型。离群点数据会影响退役电池回归预测模型的准确性, 故对于不正确的数据、偏离正常测试值的离群点数据, 应修正或删除。本文提出利用 DBSCAN 聚类算法将电池训练集中的离群点标识出来, 然后将离群点从训练集中删除。

DBSCAN 聚类算法以对象点和核心点之间距离的大小为判断依据, 是一种基于密度的聚类算法。其通过将一组足够密度的相连点定义为一簇, 并且能发现任何形状的簇。测试数据中的离群点数据一般以单个点或簇数据的形式在数据集中存在, 单个点或者簇数据偏移绝大多数数据。离群点会影响回归模型中的回归系数, 从而影响回归模型的训练精度。DBSCAN 算法的优点是它不需要预先知道簇的数量, 可以发现任何形状的簇, 并且可以识别并处理噪声点。

DBSCAN 算法的工作原理如下。

1) 对于退役电池训练集中的每个点, 若该点的邻域(以该点为中心, 半径为  $\varepsilon$  的圆)内的样本点数不

小于最小样本数 MinPts, 则创建一个新的簇。

2) 扩展该簇, 将邻域内所有直接密度可达的点添加到这个簇。然后, 对这些点的邻域进行同样的检查, 如果邻域内的样本点数  $\geq$  MinPts, 则继续添加到簇中。这个过程一直持续到簇不再扩展为止。

3) 若还有未被访问的点, 为每个新的未被访问的点重复步骤 1) 和 3), 直到所有的点都被访问。

在 DBSCAN 算法聚类完成后, 一般通过轮廓系数评估算法聚类的实际效果, 但是不适用于本文的离群点识别场景。

轮廓系数的计算公式为:

$$SC = \frac{1}{n_{\text{cluster}, \max}} \sum_{i=1}^{n_{\text{cluster}, \max}} \frac{(b(i) - a(i))}{\max\{a(i), b(i)\}} \quad (6)$$

式中: SC 是最大簇轮廓系数;  $a(i)$  表示对应簇内第  $i$  个数据点与其所属簇中其他数据点的平均距离, 反映簇的紧凑性(内聚度);  $b(i)$  表示第  $i$  个数据点与非所属簇中最近簇的数据点的平均距离, 反映簇间的分离性;  $n_{\text{cluster}, \max}$  是最大簇数据集中的电池数量。轮廓系数只考虑了聚类效果中的内聚度和分离度两种因素, 并未考虑正常数据是否被充分保留、离群点是否被成功分离。为此, 本文提出适用于本文场景的离群点标识效果评估公式:

$$Fit = SC \frac{COV(X, SOH)}{\sigma(X) \cdot \sigma(SOH)} \frac{n_{\text{cluster}, \max}}{N_{\text{Cell}}} \quad (7)$$

式中:  $COV(X, SOH)$  为最大簇数据集健康特征  $X$  与 SOH 的协方差;  $\sigma(X)$  和  $\sigma(SOH)$  分别是最大簇数据集中 HF 与 SOH 的标准差;  $N_{\text{Cell}}$  是数据集中所有的电池数量。式(7)可用于从多个聚类簇中自动选取正常的数据集, 实现标识效果的数据化评估。同时, 相比常规的轮廓系数, 本文提出的离群点标识效果评估方程考虑了离群点标识效果及正常数据被判定为离群点的比例, 有助于准确实现本文算法中超参数的优化。离群点标识效果通过式(7)中的皮尔逊相关系数实现, 正常数据被判定为离群点的比例通过式(7)中  $n_{\text{cluster}, \max}$  与  $N_{\text{Cell}}$  的比值实现。

电池工作的环境和工况一般在一定范围内变动, 故电池性能参数的衰退轨迹较为稳定。但退役电池检测时, 不可避免的测量误差会导致部分电池电压、电流偏离正常值。此外, 部分故障电池的特征也会偏离正常区间。DBSCAN 算法能够标识训练集中的离群点电池, 避免离群点电池影响 SVR 模型的准确建模。

退役电池 SOH 快速估计策略流程如下:

1) 训练集获取, 如图 5 所示, 随机选取一定数量的退役电池, 对退役电池完整充放电两次利用安时积分法获取电池准确 SOH。然后依次将这些电池放电至放电电压下限 2.5 V, 放电结束后静置 3 min 并记录相应的电压提取 HF。

2) 利用 DBSCAN 算法标识 HF 及对应 SOH 中异常数据,然后将异常数值点从训练集中剔除。利用 DBSCAN 算法筛选后的 HF 及 SOH 训练 SVR 模型。

3) 未知退役电池 SOH 估计,当开路电压 < 3.1 V,将退役电池充电 10% 标称容量然后静置 10 min。然后将退

役电池放电至放电电压下限 2.5 V,然后静置 3 min 提取 HF。将 HF 输入训练好的 SVR 模型获得相应的 SOH。当开路电压 > 3.1 V 时,将退役电池放电至放电电压下限 2.5 V,然后静置 3 min 提取 HF。将 HF 输入训练好的 SVR 模型获得相应的 SOH。

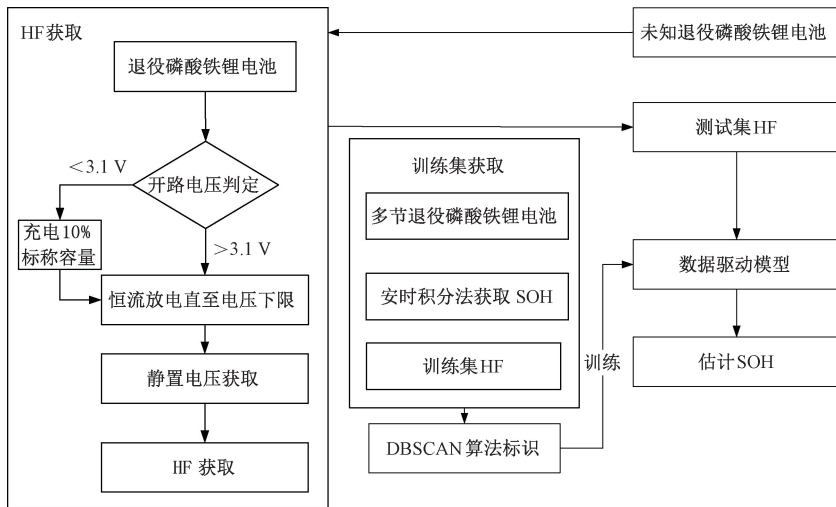


图 5 退役电池 SOH 快速估计策略结构

Fig. 5 Structure diagram of SOH fast estimation strategy for retired batteries

### 3 实验与讨论

为了验证所提出退役电池 SOH 估计策略的有效性,搭建了测试平台如图 6 所示,由电池测试柜、恒温箱、上位机构成。电池测试柜对电池进行充放电获取准确容量,恒温箱提供可控的测试温度,上位机采集记录电流和电压数据。为了避免温度对实验结果的影响,选取出厂额定容量为 30 AH 的退役磷酸铁锂电池,环境测试温度维持在 25 °C (±2 °C)。

- 2) 静置 30 min 使电池内部反应稳定。
- 3) 以 20 A 恒定电流将两节退役电池放电至 2 V,然后静置 3 min。
- 4) 依次将 3) 中放电截止电压更改为 2.1、2.3、2.5、2.7、2.9 V,重复步骤 1)~3),直至结束。

如图 7 所示,不同 SOH 退役电池在被放电至相同电压下限后静置电压变化差异十分明显。选取的放电电压下限越低,静置电压回升的幅度越大,这验证了放电截止电压选取不应过高。



图 6 电池测试平台

Fig. 6 Battery test and experiment platform

为了验证选取放电截止电压的合理性,选取 SOH = 90%、SOH = 67% 的两节退役电池,依次采取如下步骤:

- 1) 以 20 A 电流对两节退役电池充电 10 min。




图 7 不同放电截止电压时静置电压对比

Fig. 7 Correlation coefficient between resting voltage and SOH

表 1 所示为放电结束后电池静置 30、60、90、120、150、180 s 对应的电池电压  $V_1 \sim V_6$  以及不同 SOH 电池对应的电压差值。不同 SOH 电池对应的特征电压差值越大,表明特征电压随电池老化变动的幅度越大。随 SOH 变化幅度越大的特征电压分辨不同 SOH 电池越容易。当放电下限选取为 2.3 或 2.5 V 时, $SOH=67%$ 与  $SOH=$

90%之间  $V_1$  差值最大。当放电下限选取为 2.3 V 时, $SOH=67%$ 与  $SOH=90%$ 之间  $V_1$  和  $V_2$  差值最大。但放电下限选取为 2.3 和 2.5 V 时的  $V_1$  和  $V_2$  差值接近。当放电下限选取为 2.5 V 时, $SOH=67%$ 与  $SOH=90%$ 之间  $V_3$ 、 $V_4$ 、 $V_5$  以及  $V_6$  差值最大,故选取 2.5 V 为放电电压下限。

表 1 不同放电电压下限时, $SOH=90%$ 和  $SOH=67%$ 对应特征电压差值

Table 1 Characteristic voltage difference values corresponding to  $SOH=90%$  and  $SOH=67%$  at different discharge voltage limits

电压	SOH	2 V	2.1 V	2.3 V	2.5 V	2.7 V	2.9 V
$V_1/V$	$SOH=90%$	2.300 0	2.353 3	2.470 8	2.621 2	2.803 5	2.996 9
	$SOH=67%$	2.428 3	2.478 6	2.611 2	2.761 3	2.918 5	3.071 3
	差值	0.1283	0.125 3	0.140 4	0.140 1	0.115 0	0.074 4
$V_2/V$	$SOH=90%$	2.339 7	2.385 9	2.495 9	2.637 3	2.814 0	3.006 2
	$SOH=67%$	2.479 5	2.517 0	2.639 5	2.780 5	2.932 4	3.083 1
	差值	0.139 8	0.131 1	0.143 6	0.143 2	0.118 4	0.076 9
$V_3/V$	$SOH=90%$	2.362 9	2.405 1	2.510 8	2.646 3	2.819 9	3.010 6
	$SOH=67%$	2.508 0	2.538 1	2.653 4	2.789 8	2.938 9	3.088 4
	差值	0.145 1	0.133 0	0.142 6	0.143 5	0.119 0	0.077 8
$V_4/V$	$SOH=90%$	2.379 4	2.418 4	2.521 3	2.652 8	2.823 6	3.013 7
	$SOH=67%$	2.528 2	2.552 7	2.662 7	2.796 0	2.943 3	3.091 5
	差值	0.1488	0.134 3	0.141 4	0.143 2	0.119 7	0.077 8
$V_5/V$	$SOH=90%$	2.392 4	2.429 3	2.529 1	2.657 8	2.825 8	3.015 2
	$SOH=67%$	2.543 7	2.563 8	2.669 8	2.799 7	2.945 8	3.093 6
	差值	0.1513	0.134 5	0.140 7	0.141 9	0.120 0	0.078 4
$V_6/V$	$SOH=90%$	2.402 6	2.437 6	2.535 3	2.661 2	2.827 6	3.016 4
	$SOH=67%$	2.555 8	2.572 8	2.675 7	2.803 1	2.947 6	3.094 9
	差值	0.153 2	0.135 2	0.140 4	0.141 9	0.120 0	0.078 5

表 2 重构曲线与静置曲线的决定系数

Table 2 Coefficient of determination between reconstruction curve and standing curve

	1 次函数	2 次函数	3 次函数	4 次函数	5 次函数	6 次函数	7 次函数
$R^2$	0.68	0.9	0.96	0.98	0.99	0.99	0.99

为了验证 HF 分别选取为 30、60、90、120、150、180 s 对应电池电压的合理性,展开以下实验:从电池静置电压曲线中分别选取 2、3、4、5、6、7、8 个 HF,然后利用选取的 HF 点对静置电压曲线进行重构拟合。

$$U_{fit}(t) = a_n t^n + a_{n-1} t^{n-1} + \dots + a_2 t^2 + a_1 t + a_0 \quad (8)$$

式中: $U_{fit}$  为电池静置期间端电压值; $t$  为静置时间; $a_n$  为系数值。当选取两个 HF 时,最多能计算两个系数值  $a_1$  和  $a_0$ ,此时重构后的曲线方程为一次函数。类似的,当选取  $n$  个 HF 时,重构后的曲线方程为  $n-1$  次函数。表 2 为利用 1、2、3、4、5、6、7 次函数重构静置电压曲线时,重构曲线与实际曲线的决定系数  $R^2$ 。

式中: $U_{fit,i}$  为  $i$  秒重构曲线对应电压值; $U_{ct,i}$  为  $i$  秒实际电池静置电压值。当决定系数接近 1 时,代表重构(8)能够较好的拟合实际曲线。从表 2 可以看出,当式(8)中函数为 5 次时,重构曲线与实际曲线的决定系数趋于稳定,故从静置电压曲线中选取 6 个等间隔分布的 HF 点。

为了验证静置时间的合理性,选取  $SOH=67%$  的退役电池,在放电至 2.5 V 后静置 10 min 时间,并记录电压曲线变化。如图 8 所示,随着时间的推移,电池电压的回升速度逐渐变缓。在放电结束的 3 min 后,电池电压的回升过程已结束。为了避免退役电池的分选过程耗费过长时间同时兼顾充分利用静置电压变化,在放电至电压下限 2.5 V 后静置 3 min。

随机选取 830 节额定为 30 AH 的磷酸铁锂退役电池,将这些退役电池分为训练集和测试集。训练集用于训练 SVR 模型,测试集用于验证训练好的 SVR 模型估计

$$R^2 = 1 - \frac{\sum_{i=1}^{180} (U_{fit,i} - U_{ct,i})^2}{\sum_{i=1}^{180} (U_{ct,i} - \frac{1}{180} \sum_{i=1}^{180} U_{ct,i})^2} \quad (9)$$




图 8 电池被放电至 2.5 V 后,静置 10 min 电压变化  
Fig. 8 After the battery is discharged to 2.5 V, the voltage changes in 10 minutes standing process

SOH 的准确度。

通过完整充放电获取电池的真实 SOH,实现步骤如下:首先,将退役电池以恒定电流 20 A 充电至截止电压上限 3.65 V,然后以维持恒定电压不变直至电流跌至

1 A。接着,以恒定电流 20 A 对退役电池进行放电直至电压下降至截止电压 2 V。重复以上过程两次,以放电过程中退役电池释放的电荷量为电池的容量。

为了定量描述 SOH 估计效果,计算 SOH 估计的均方根误差 (RMSE)。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (SOH_{real}(i) - SOH_{estimate}(i))^2} \quad (10)$$

式中: $SOH_{real}$  为电池的真实 SOH; $SOH_{estimate}$  指估计的电池 SOH; $N$  代表测试电池的数量。

### 3.1 相关性系数计算

训练集中的 800 节退役电池 HF 包括  $V_1 \sim V_6$ 。随退役电池 SOH 的变化,如图 9 所示。SOH 的值越小,电池的老化程度越高,相应的 HF 的值越小。但由于不同退役电池经历的历史工况不同导致 HF 的老化幅度不同,故这种相关性并不是严格存在的。这使得依赖仅单独某一个 HF 难以准确实现退役电池 SOH 估计,因此下节将介绍如何利用 SVR 算法结合多个 HF 实现退役电池 SOH 估计。




图 9 特征电压随 SOH 的变化

Fig. 9 Variation of characteristic voltage with SOH

为了分析所选取特征与 SOH 的相关性,SOH 与 HF 之间的皮尔逊相关系数被计算:

$$\rho = \frac{\sum (f_i - \bar{f}_i)(SOH - \overline{SOH})}{\sqrt{\sum (f_i - \bar{f}_i)^2} \sqrt{\sum (SOH - \overline{SOH})^2}} \quad (11)$$

式中:  $\rho$  代表 HF 与 SOH 之间的皮尔逊相关系数;  $f_i$  表示 HF 中的第  $i$  个样本;  $\bar{f}_i$  表示 HF 的样本平均值。

通过结合上述特征,能够充分利用静置过程中电压包含的 SOH 信息,提高 SOH 估计精度。电池静置时电压与 SOH 的  $\rho$  随时间的变化如图 10 所示。静置阶段电压与 SOH 相关性随着静置时间的增加而逐渐增加。随着静置时间的增加,不同 SOH 退役电池的电压差异逐渐增大。在相同时间内,SOH 越低的电池增加幅度越快且越大,这使得在静置 20 s 后电池的电压与 SOH 之间的  $\rho$  更大,故选取在静置过程开始 30 s 后电池电压作为 HF。




图 10 静置电压和 SOH 的相关系数

Fig. 10 Correlation coefficient between resting voltage and SOH

### 3.2 数据预处理

为了验证训练集中离群点对 SOH 估计的影响以及 DBSCAN 的聚类算法对标识训练集中离群点后 SOH 估计的影响,从训练集中选取  $Num$  节电池,将其实际 SOH 加入高斯噪声模拟由于检测失误或电池内部故障形成的离群点。

$$SOH_{noise} = SOH_{real} - \eta \cdot rand \quad (12)$$

式中:  $\eta$  描述电池 SOH 偏离真实 SOH 的最大幅值,取 0.25,  $rand$  指 0~1 的随机数。

如图 11 所示,加入高斯噪声的数据集中,离群点以随机点的形式偏离绝大多数电池。  $Num$  取值为 50, DBSCAN 的聚类算法将密度足够的离群点定义为一簇,将远离大多数电池的单个电池也识别为离群点。离群点的存在会扭曲 SVR 算法模型,导致无法建立准确的 SVR 算法模型。在训练集训练 SVR 模型之前,依次标识  $V_1 \sim V_6$  存在离群点数据的退役电池,并将其从训练集中剔除。其中数据量最大的一簇作为 SVR 模型的训练集,被识别为离群点的电池不作为训练集,这可以避免离群点对 SVR 模型影响 SOH 估计精度。

DBSCAN-SVR 算法优越性验证步骤如下。

1) 利用图 11 中 800 节退役电池训练集训练 SVR 模型,然后利用训练好的 SVR 模型估计测试集中 30 节未知电池的 SOH。

2) 利用 DBSCAN 的聚类算法标记训练集中的离群点,将离群点从训练集中剔除。

3) 将不包含离群点的训练集训练 SVR 算法,利用训练好的 DBSCAN-SVR 模型估计测试集电池 SOH。

### 3.3 SOH 估计结果验证

为了验证离群点标识效果评估方程作为适应度函数对离群点标识效果相比轮廓系数的优越性,利用粒子群算法实现 DBSCAN 算法超参数感知半径和最小样本数的自动获取,从而获得在两种适应度函数场景下的两种 DBSCAN 算法超参数。

样本的数据集由 800 节退役电池健康特征  $V_1 \sim V_6$  构成,这些样本数据被人工施加有色噪声和白噪声。利用轮廓系数获得的超参数代入 DBSCAN 算法后,分别针对  $V_1 \sim V_6$  数据集中的离群点电池进行标识,结果如图 12 所示,其中方体为数据集中被判定为离群点的异常退役电池,圆体为标识后的正常退役电池数据集。当采取轮廓系数作为粒子群算法的适应度函数时,粒子群算法的迭代过程仅考虑聚类结果的内聚度和分离度两种因素,并不能正确的标识异常电池离群点数据。大量正常数据被判定为离群数据。但当利用离群点标识效果评估方程作为适应度函数时,除了考虑轮廓系数,还要考虑离群点标识效果及正常数据被判定为离群点的比例。如图 13 所示,将式(7)作为粒子群算法的适应度函数获得的超参数代入 DBSCAN 算法后,退役电池数据集中的异常数据被剔除。

为验证所提出的 SOH 快速估计方案的优势,选取了 30 节退役电池作为测试集。从 SOH 估计时间对比以及 DBSCAN 算法对 SOH 估计精度的提高两个角度展开论述。以卡尔曼滤波为代表的自适应滤波算法在不断迭代中不断提高 SOH 估计精度,但退役电池历史数据难以获得导致此类方法无法直接应用。传统 SOH 估计方法包括安时积分法、电化学阻抗谱法、增量容量法,这些方法应用在离线场景下的退役电池 SOH 估计存在缺陷。

电化学阻抗谱法估计电池 SOH 时会受到电池 SOC 的影响,然而退役电池测试时 SOC 是未知的,且电化学阻抗谱的检测需要昂贵的设备。增量容量法需要以小电流对电池进行充放电,然后从电压曲线中提取 HF,这个过程依然耗费较多的时间。所以现阶段用于退役电池 SOH 估计的方案依然是安时积分法,退役电池 SOH 估计的速度依然很慢。测试集退役电池的初始 SOC 折线图如图 14 所示,测试集电池的 SOC 随机分布在 0%~100%。柱状图分别描述了安时积分法和本文提出方法




图 11 当训练集包含离群点时,特征电压随 SOH 的变化

Fig. 11 When the training set contains outliers, variation of characteristic voltage with SOH




图 12 利用轮廓系数作为适应度函数时,离群点标识结果

Fig. 12 Outlier identification results when using contour coefficients as fitness functions




图 13 利用本文方法作为适应度函数时,离群点标识结果

Fig. 13 Outlier identification results when using proposed method as fitness functions

在 20 A 充放电电流下所耗费的时间。

相比安时积分法,本文提出的方法估计 SOC 越低的退役电池 SOH 的耗费时间越短。当退役电池 SOC 接近 100%时,本文提出的 SOH 估计策略能够小幅降低 SOH 获取时间。当 SOC 接近 0%时,该 SOH 估计策略能够大幅缩短 SOH 估计的耗费时间。相比传统退役电池 SOH

估计方案,本文提出的 SOH 估计方案仅需要价格低廉的电池测试柜、能够适用于未知 SOC 电池且测试速度更快。实际测量中,误差除了高斯噪声,也会存在有色噪声和零漂。为了验证 DBSCAN 算法识别训练集中包含有色噪声离群点的效果,展开了以下实验。

选取有色噪声模型如下:

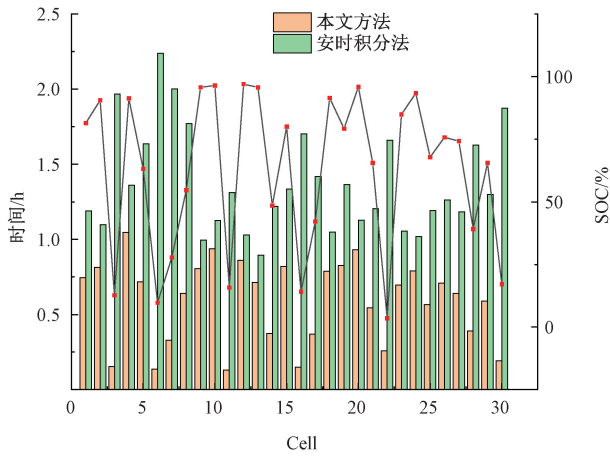


图 14 SOH 估计的时间对比

Fig. 14 Comparison of estimated time for SOH

$$noise_{k+1} = \lambda_{k+1,k} noise_k + \zeta_k \quad (13)$$

$$SOH_{color-noise} = SOH_{real} + noise_{color} - c \quad (14)$$

式中:  $noise_k$  为有色噪声;  $\lambda_{k+1,k}$  为有色噪声传递矩阵;  $\zeta_k$  为零均值白噪声;  $c$  为固定数值模拟测量时固定偏差。

如图 15 所示, 利用包含有色噪声的训练集训练 SVR 模型时, 训练好的 SVR 模型无法充分匹配训练集。若用不准确的 SVR 模型利用 HF 估计退役电池 SOH, SOH 估计结果的准确性将无法得到保证。




图 15 有色噪声离群点对 SVR 训练集预测结果影响

Fig. 15 Impact of different numbers of outliers on SOH estimation results

如图 16 所示, 直接利用包含高斯噪声离群点 ( $Num=200$ ) 的训练集训练 SVR 模型估计测试集电池 SOH 的均方根误差为 3.3%, RFR 算法估计 SOH 均方根误差为 5.7%, DBSCAN-RFR 算法估计 SOH 均方根误差为 3.8%, 而利用 DBSCAN-SVR 方法估计电池 SOH 的均方根误差为 2.8%。相比 SVR 算法, DBSCAN-SVR 方法的 SOH 更贴近绝大多数的电池 SOH, 这验证了采用

DBSCAN 算法通过标识离群点来提高退役电池 SOH 的有效性。

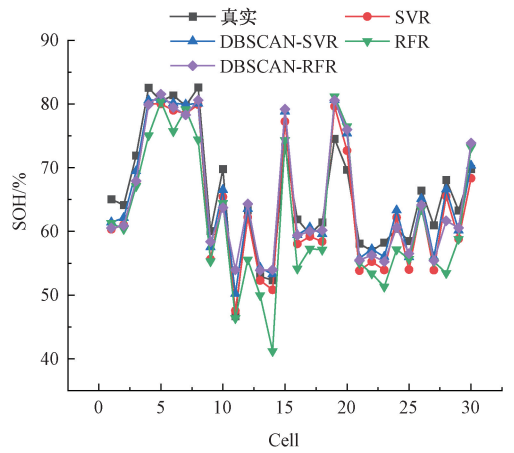


图 16 训练集包含高斯噪声时, SOH 估计结果对比

Fig. 16 Comparison of SOH estimation results

直接利用包含有色噪声离群点 ( $Num=200$ ) 的训练集训练 SVR 模型估计测试集电池 SOH 的均方根误差为 3.1%, RFR 算法估计 SOH 均方根误差为 6.8%, 而 DBSCAN-RFR 算法估计 SOH 均方根误差为 3.7%, 利用 DBSCAN-SVR 方法估计电池 SOH 的均方根误差为 2.81%。如图 17 所示, 与包含高斯噪声的训练集训练回归算法模型相似, DBSCAN 算法可大幅提高 RFR 算法的 SOH 估计精度。SVR 模型估计 SOH 效果受离群点影响相对较小, 但 DBSCAN 算法依然降低了离群点对 SVR 模型的影响。




图 17 训练集包含有色噪声时, SOH 估计结果对比

Fig. 17 Comparison of SOH estimation results

图 18 所示为当训练集中存在不同数量的离群点时, SVR 和 DBSCAN-SVR 模型分别估计训练集 SOH 的 RMSE 值。Num 表示训练集中离群点的数量, DBSCAN-Num 表示训练集中离群点已经被 DBSCAN 算法标识。

当训练集中离群点数量增多后,SOH 估计误差的 RMSE 值不断增加,这表明样本中离群点数目影响着电池建模的准确性。同时,随着样本中离群点数目的增加,DBSCAN 算法标识离群点后降低 SOH 估计误差的幅度越大。




图 18 不同数量离群点对 SOH 估计结果影响

Fig. 18 Impact of different numbers of outliers on SOH estimation results

## 4 结 论

本文提出了一种新的退役电池 HF 获取策略,采用的退役电池 SOH 快速估计方案能够大幅降低退役电池的分选时间,并且通过利用 DBSCAN 算法标识离群点有效提高了退役电池 SOH 估计精度。本文分析了退役电池放电至相同电压下限后不同 SOH 电池 SOC 存在差异的现象,并明确了不同 SOH 电池静置电压曲线将由于 SOC 差异变化趋势不同。本文基于此提出了基于静置电压曲线的 HF 获取方法,然后选取了合适的放电电压下限,最后通过实验验证了方法的有效性和优越性。

## 参考文献

[ 1 ] 黄海宏,汪宇航,王海欣. 基于粒子群优化粒子滤波算法的 SOC 估算研究[J]. 电子测量与仪器学报, 2022, 36(2): 245-253.  
HUANG H H, WANG Y H, WANG H X. Research on SOC estimation based on particle swarm algorithm and particle filter algorithm [ J ]. Journal of Electronic Measurement and Instrumentation, 2022, 36 ( 2 ): 245-253.

[ 2 ] 刘大同,宋宇晨,武巍,等. 锂离子电池组健康状态估计综述[J]. 仪器仪表学报, 2020, 41(11): 1-18.  
LIU D T, SONG Y CH, WU W, et al. Review of state of health estimation for lithium-ion battery pack [ J ]. Chinese Journal of Scientific Instrument, 2020,

41(11): 1-18.

[ 3 ] LUO K, CHEN X, ZHENG H, et al. A review of deep learning approach to predicting the state of health and state of charge of lithium-ion batteries [ J ]. Journal of Energy Chemistry, 2022, 74: 159-73.

[ 4 ] LAI X, DENG C, TANG X, et al. Soft clustering of retired lithium-ion batteries for the secondary utilization using Gaussian mixture model based on electrochemical impedance spectroscopy [ J ]. Journal of Cleaner Production, 2022, 339: 130786.

[ 5 ] LUO F, HUANG H H, NI L P, et al. Rapid prediction of the state of health of retired power batteries based on electrochemical impedance spectroscopy [ J ]. Journal of Energy Storage, 2021, 41: 102866.

[ 6 ] FU Y, XU J, SHI M, et al. A Fast impedance calculation-based battery state-of-health estimation method [ J ]. IEEE Transactions on Industrial Electronics, 2022, 69(7): 7019-28.

[ 7 ] FENG L, JIANG L, LIU J, et al. Dynamic overcharge investigations of lithium ion batteries with different state of health [ J ]. Journal of Power Sources, 2021, 507: 230262.

[ 8 ] GU X, SEE K W, LI P, et al. A novel state-of-health estimation for the lithium-ion battery using a convolutional neural network and transformer model [ J ]. Energy, 2023, 262: 125501.

[ 9 ] SHI M, XU J, LIN C, et al. A fast state-of-health estimation method using single linear feature for lithium-ion batteries [ J ]. Energy, 2022, 256: 124652.

[ 10 ] WANG C, WANG S, ZHOU J, et al. A novel back propagation neural network-dual extended Kalman filter method for state-of-charge and state-of-health co-estimation of lithium-ion batteries based on limited memory least square algorithm [ J ]. Journal of Energy Storage, 2023, 59: 106563.

[ 11 ] MA L, XU Y, ZHANG H, et al. Co-estimation of state of charge and state of health for lithium-ion batteries based on fractional-order model with multi-innovations unscented Kalman filter method [ J ]. Journal of Energy Storage, 2022, 52: 104904.

[ 12 ] LI R, HONG J, ZHANG H, et al. Data-driven battery state of health estimation based on interval capacity for real-world electric vehicles [ J ]. Energy, 2022, 257: 124771.

[ 13 ] LUO Y F, LU K Y. An online state of health estimation technique for lithium-ion battery using artificial neural network and linear interpolation [ J ]. Journal of Energy Storage, 2022, 52: 105062.

- [14] ANG E Y M, PAW Y C. Efficient linear predictive model with short term features for lithium-ion batteries state of health estimation[J]. *Journal of Energy Storage*, 2021, 44: 103409.
- [15] DRISCOLL L, DE LA TORRE S, GOMEZ-RUIZ J A. Feature-based lithium-ion battery state of health estimation with artificial neural networks[J]. *Journal of Energy Storage*, 2022, 50: 104584.
- [16] LI Q, LI D, ZHAO K, et al. State of health estimation of lithium-ion battery based on improved ant lion optimization and support vector regression[J]. *Journal of Energy Storage*, 2022, 50: 104215.
- [17] 陈熙源, 戈明明, 姚志婷, 等. 雨雪天气下的激光雷达滤波算法研究[J]. *仪器仪表学报*, 2023, 44(7): 172-181.  
CHEN X Y, GE M M, YAO ZH T, et al. Research on Lidar filtering algorithm for rainy and snowy weather[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(7): 172-181.
- [18] 张忠平, 李森, 刘伟雄, 等. 基于快速密度峰值聚类离群因子的离群点检测算法[J]. *通信学报*, 2022, 43(10): 186-195.  
ZHANG ZH P, LI S, LIU W X, et al. Outlier detection algorithm based on fast density peak clustering outlier factor[J]. *Journal on Communications*, 2022, 43(10): 186-195.
- [19] 张函, 钱权, 武星. 面向材料数据的主动回归学习方法[J]. *工程科学学报*, 2023, 45(7): 1232-1237.  
ZHANG H, QIAN Q, WU X, et al. Active regression learning method for material data[J]. *Chinese Journal of Engineering*, 2023, 45(7): 1232-1237.
- [20] CHEN Z, ZHAO H, ZHANG Y, et al. State of health estimation for lithium-ion batteries based on temperature prediction and gated recurrent unit neural network[J]. *Journal of Power Sources*, 2022, 521: 230892.
- [21] SU X, SUN B, WANG J, et al. Fast capacity estimation for lithium-ion battery based on online identification of low-frequency electrochemical impedance spectroscopy and Gaussian process regression [J]. *Applied Energy*, 2022, 322: 119516.
- [22] ZHANG Y, LIU Y, WANG J, et al. State-of-health estimation for lithium-ion batteries by combining model-based incremental capacity analysis with support vector regression[J]. *Energy*, 2022, 239: 121986.
- [23] LI R, HONG J, ZHANG H, et al. Data-driven battery state of health estimation based on interval capacity for real-world electric vehicles [J]. *Energy*, 2022, 257: 124771.

### 作者简介



黄海宏(通信作者),分别在1996年和1999年于合肥工业大学获得学士学位和硕士学位,于2011年获中国科学院合肥物质科学研究院博士学位,现为合肥工业大学教授,主要研究方向为电力电子技术和电池检测。  
E-mail: hhaihong741@126.com

**Huang Haihong** (Corresponding author) received his B. Sc. degree and M. Sc. degree from Hefei University of Technology in 1996 and 1999 respectively, and Ph. D. degree from Hefei Institutes of Physics Science, Chinese Academy of Sciences in 2011. Now he is a professor in Hefei University of Technology. His research interests include power electronics and automation.



刘鑫,2014年于合肥工业大学获得硕士学位,现为合肥工业大学博士研究生,主要研究方向为智能电网安全稳定与可靠性。  
E-mail: hfutlx@hotmail.com

**Liu Xin** received his M. Sc. degree from Hefei University of Technology in 2014. Now he is a Ph. D. candidate at Hefei University of Technology. His main research interests include the safety, stability and reliability of smart grids.