

DOI: 10.19650/j.cnki.cjsi.J2311641

基于荷电状态差异的退役电池健康状态快速估计研究*

汪宇航, 黄海宏, 王海欣, 武旭

(合肥工业大学电气与自动化工程学院 合肥 230009)

摘要:随着新能源产业的迅速发展,大量动力电池面临退役回收后如何处理的问题。退役电池的二次利用场景需要根据健康状态(SOH)确定,然而不同退役电池的荷电状态不同,这使得快速估计SOH十分困难。为此,提出了一种基于荷电状态差异的退役电池的SOH快速获取策略。在本策略中,不同SOH退役电池的荷电状态差异被用于产生多种健康特征。同时,为了选取随机森林算法合适的超参数,遗传优化随机森林回归算法被提出应用于SOH的估计。通过验证,本文策略大幅降低了退役电池SOH的估计时间。并且通过多种避免测量时接触电阻和导线电阻策略,使得10节退役电池的健康状态估计误差低于3%。

关键词:退役电池;健康状态;快速;随机森林回归;频域

中图分类号: TH89 TM93 **文献标识码:** A **国家标准学科分类代码:** 470.40

Research on fast estimation of the state of health of retired batteries based on the state of charge differences

Wang Yuhang, Huang Haihong, Wang Haixin, Wu Xu

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

Abstract: With the rapid development of the new energy industry, how to deal with a large number of retired batteries is problem. The secondary utilization scenarios of retired batteries need to be determined based on the state of health (SOH). However, the traditional method of obtaining SOH is time-consuming and energy-consuming. Therefore, the study of fast SOH estimation is very meaningful. The unavailability of historical working condition information and the unknown state of charge at the time of detection make fast SOH estimation very difficult. For this reason, this article proposes a fast SOH acquisition strategy for retired batteries based on the difference in state of charges. In this article, the state of charge's differences of different SOH retired batteries are used to generate multiple health features. Meanwhile, to select suitable hyperparameters for the random forest algorithm, the genetic optimization random forest regression algorithm is proposed to be applied for SOH estimation. Through experiments, the proposed strategy substantially reduces the estimation time of SOH for retired batteries. Through multiple strategies to avoid contact resistance and wire resistance during measurement, the error of health state estimation of 10 retired batteries is lower than 3%.

Keywords: retired batteries; state of health; fast; random forest regression; frequency domain

0 引 言

电动汽车近些年发展迅猛,随之而来的问题是退役电池如何处理^[1-2]。锂电池具有高能量密度、安全、自放电率低等优点,被广泛应用于电动汽车、储能、应急电源等场合。一般,当电池的健康状态(state of health, SOH)

衰退至70%~80%时,这类电池将被退役回收^[3]。然而,实际中导致电池回收的原因有多种。车辆故障、部分电池损坏、储能系统损坏等都有可能导致的大量的电池退役。因此,回收获得退役电池的SOH多种多样。SOH是评估退役电池二次使用场景的重要依据^[4]。

SOH和内阻是退役电池分选的重要参考指标。然而,传统退役电池获取SOH的依赖长时间的充放电,这

严重影响电池的分选效率。现有的 SOH 估计方法绝大多数是围绕车载场景下研究的。作为电池在线管理系统运行的关键依据,SOH 的研究十分广泛。安时积分法是检测 SOH 最常用的方法,但是存在检测耗时和容易受到测量噪声影响的缺点。于是,基于模型的 SOH 估计方法被提出。基于等效电路模型的方法首先通过识别等效电路模型参数,然后依赖这些参数辅助 SOH 的估计。文献[5]在偏微分方程的基础上建立了一个改进的伪二维模型,能够有效提高等效电路的精确度。文献[6]基于内阻与 SOH 的关系建立了等效电路模型,并使用双扩展卡尔曼滤波算法结合等效电路模型对荷电状态(state of charge, SOC)和 SOH 进行在线联合估计。这类方法一般通过结合等效模型参数,利用自适应滤波结果提高 SOH 估计的精度^[7-9]。但是基于等效电路模型的 SOH 估计方法受到模型精度的影响,并且一般适用于车载在线场景,无法准确估计电池 SOH。

退役电池 SOH 可以通过完整充放电准确获取,但是需要耗费大量时间。所以退役电池 SOH 估计需要解决的问题是耗时,然而通过安时积分法和基于模型的 SOH 估计方法很难实现 SOH 的快速估计。数据驱动方法将电池视为黑盒子模型^[10],通过温度、电流、电压、阻抗等与 SOH 有关健康特征(healthy factor, HF)的衰退轨迹预估电池的 SOH。由于车载电池使用的环境、工况比较稳定,基于数据驱动的 SOH 估计方法能够取得较好的效果。基于数据驱动的 SOH 估计方法相比其他两种方法速度更快^[11-13],但是估计结果对测试数据集和算法十分敏感。一般,基于数据驱动 SOH 估计方法通过结合电池充放电过程中的 HF 和数据驱动算法实现 SOH 的估计,现有的研究主要围绕对数据驱动算法的优化和 HF 的选取两个角度展开。其中,数据驱动算法包括支持向量机^[14]、神经网络算法^[15]、高斯过程回归算法^[16]、长短期神经网络^[17]等。文献[18]基于高斯过程回归算法框架,考虑健康因子和容量衰减的整体关系和局部变化提出改进的高斯核函数提高估计精度和可靠性。文献[19]提出了一种新的基于数据预处理方法和卷积神经网络框架的 SOH 估计,通过数据的预处理降低运算负担并提高 SOH 估计效果。文献[20]从增量容量曲线中提取特征,然后提出利用随机森林回归用于电池容量估计,并取得了较好的效果。数据驱动算法使用时需要选取合适的超参数,这是本文选取遗传算法优化随机森林回归算法的原因。并且经过对比,遗传算法优化随机森林回归算法的 SOH 估计效果优于本文中的其他算法。SOH 估计精度不仅仅依赖于算法,还体现在合适的 HF。文献[21]提出了一种基于充电段的区间容量老化特征及其提取方法,然后结合数据驱动算法估计电池 SOH。然而基于充电曲线特征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。文献[22-23]从电化学阻抗谱中提取 HF,然后结合高斯过程回归算法估计电池的 SOH。但是在不同 SOC 下,电化学阻抗谱同样不同,这使得在无法直接利用电化学阻抗谱估计未知 SOC 退役电池的 SOH。同时,获取电化学阻抗谱的测试仪器也十分昂贵。文献[24]从弛豫电压曲线中提取 HF,然后利用机器学习方法构建电池 SOH 估计模型。同样的,不同 SOC 下电池弛豫电压曲线不同,这使得无法在未知 SOC 下利用弛豫电压曲线估计电池 SOH。因此,提出一种能够适用于未知 SOC 状态退役电池的分选方法十分有意义。

由于退役电池测试时是处于离线状态的,这意味着这些电池可以被任意形式的充放电获取 HF。但是由于测试时退役电池的 SOC 未知,而各种快速 SOH 的估计方案依赖于已知 SOC。在短时间内,准确获得 SOH 各异退役电池的 SOC 是十分困难的,这限制了上述方法在实际中的应用。因此,本文提出了一种适用于任意 SOC 的退役电池分选方案。同时,与车载电池 SOH 估计不同,退役电池历史状态是未知的。退役电池 SOH 的估计无法依赖电池的历史衰变轨迹实现。电池的老化会受到使用场景、使用习惯、以及环境的影响,造成电池容量衰退的原因多种多样。当电池长时间在快充工况下使用时,适用于慢充电的 HF 将不再适用^[25-26]。极端温度也对电池的衰退速度存在影响,过高和过低温度都会加快电池容量的衰减^[27-28]。同时,部分电池退役是由于车辆故障导致,这类电池一直处于正常的工作区间。现有的 SOH 估计方法往往都是针对特定在线电池的,这类电池拥有固定的 HF 衰变规律。然而,由于完全未知退役电池历史状态,仅仅依靠某一电池 HF 估计电池的 SOH 十分困难。电池容量衰退的原因不同,相应变化的 HF 也不同。仅仅依靠单一 HF 无法准确的估计 SOH。这也是本文提取电池多个不同状态下 HF 的原因之一。内阻和电压等 HF 的检测容易受到检测精度和外在因素的影响,如何降低干扰因素也是本文论述的话题之一。

本文主要贡献如下:

- 1) 根据退役电池的大致 SOC 对退役电池充满或放空,然后将其放电/充电相同的电量以造成不同 SOH 电池产生不同的放电深度便于获取估计 SOH 的 HF。
- 2) 电池特定时刻的电压、内阻以及静置电压频域分量被提出作为 SOH 估计的 HF。
- 3) 将遗传算法(genetic algorithm, GA)优化随机森林回归(random forest regression, RFR)算法应用于 SOH 的估计。

1 退役电池特征参数

SOH 是描述电池老化程度的一项重要指标。在退役

电池的二次利用分选中, SOH 决定着退役电池二次利用的场景。SOH 的定义一般有两种: 一种是剩余容量与新电池容量的比值, 用于描述电池容量的衰减程度; 一种是电池现有内阻与新电池内阻的比值, 用于描述电池内阻的增长幅度^[29]。本文选取的 SOH 的定义为前一种:

$$SOH = \frac{C_{residual}}{C_{new}} \quad (1)$$

其中, $C_{residual}$ 指电池现阶段的剩余容量, C_{new} 指新电池的额定容量。

1.1 大致 SOC 的快速确定

由于电池的各种参数会受到温度和 SOC 的影响, 所以应保持所有电池处于相同的 SOC。然而, 在无法获得退役电池的历史数据和 SOH 的情况下, 准确获取电池的 SOC 是一件十分困难的事。因此本文提出将电池充满或者放空以保持电池剩余 SOC 的一致。但是为了节约退役电池的分选时间, 快速判定电池适合充满或者放空是首先需要解决的问题。这意味着快速确定大致 SOC 是退役电池分选的第一步。然而磷酸铁锂电池开路电压与 SOC 的关系曲线存在明显的平台区, 这使得仅仅依靠开路电压无法快速获取电池的 SOC。如图 1 所示, 文献[30]将电池 5%~95% 之间的 SOC 分为 9 个不同的 SOC 区间, 并在此基础上提出了一种利用动态电压特征参数估计电池 SOC 对应区间的方法, 这种方法也是本文快速确定 SOC 的途径。

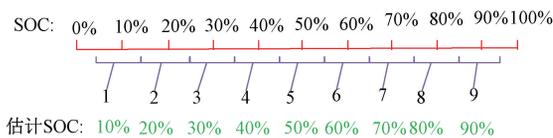
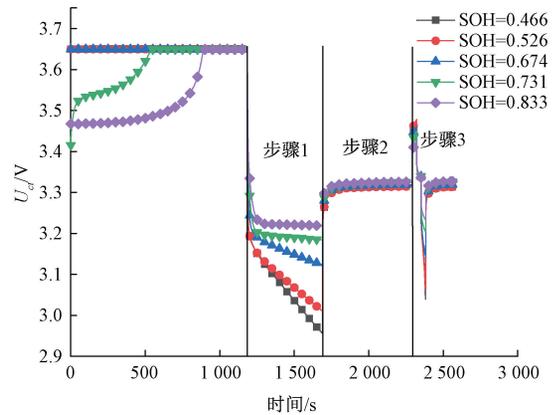


图 1 SOC 区间划分

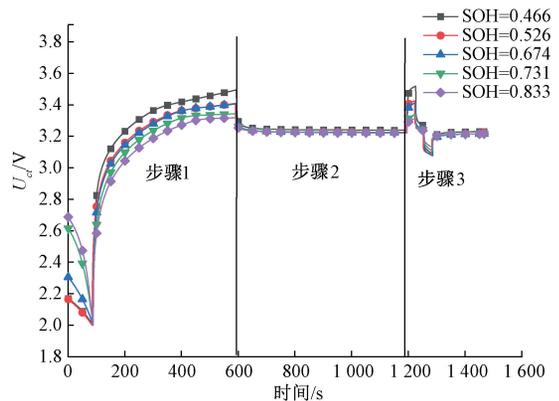
Fig. 1 Diagram of the SOC interval

首先, 随机选取一定数量的退役电池, 然后利用短时间的脉冲获取电池在不同 SOC 下静置、脉冲充电、脉冲放电时电压和内阻作为 SOC 估计特征。然后, 利用这些电池的特征参数训练支持向量机获得 SOC 估计模型。对于未知 SOC 的退役电池, 仅仅只需 90 s 的脉冲放电便可获得退役电池大致的 SOC。

如图 2 所示, 在获取退役电池的 SOC 之后, 若 SOC 低于 50%, 电池放电至截止电压; 若 SOC 高于 50%, 将电池充电至截止电压并恒压充电至电流直至电流跌落为 1 A。用于测试的退役电池将处于相同的基准线。如果对这些电池施加相同的充放电过程, 不同 SOH 电池对应的电压将不同。



(a) 退役电池充满后特征提取
(a) Extraction of features of retired batteries when they are full charged



(b) 退役电池放空后特征提取
(b) Extraction of features of retired batteries when they are full discharged

图 2 退役电池健康特征提取

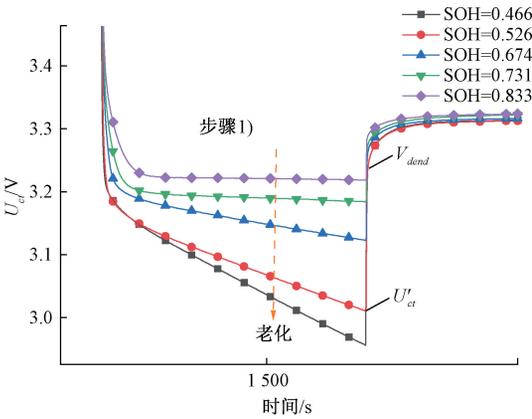
Fig. 2 Extraction of features of retired batteries

在退役电池充满或者放空后, 电池分别经历如下 3 个阶段:

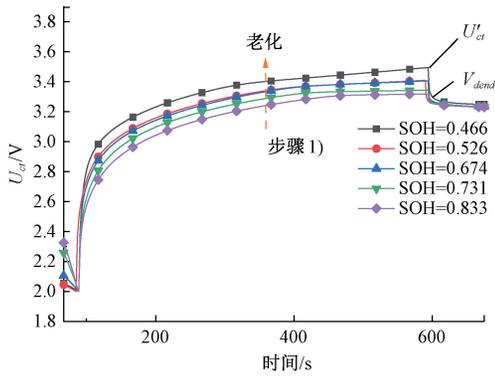
- 1) 如果判定为放空, 则充电 1/10 额定容量。如果判定为充满, 则放电 1/10 额定容量。
- 2) 静置 10 min, 观察电池的回压变化。
- 3) 动态电压过程, 检测电池内阻和 HF 电压。

1.2 充/放电阶段特征提取

在电池被充满后, 所有电池的 SOC 将保持一致。在满电状态, 本文将介绍如何利用廉价、易获得的充放电测试柜快速估计 SOH。如图 3 所示, 在放电相同的电量后, 不同 SOH 电池的放电深度将不同。SOH 越大的电池, 其放电深度越小, 相对应的剩余 SOC 和电池端电压越大。反之, SOH 越小的电池, 其放电深度越大, 相对应的剩余 SOC 和电池端电压越小。由于电池充放电时电压采样很容易受到接触电阻和导线电阻的影响, 因此本文提出通过计算欧姆内阻消除这种影响。如图 3 所示, 在放电阶段结束的时候, 不同 SOH 电池的端电压并未完全按照理想的情况变化。这是测试时导线电阻和接触内阻引起的, 这在实际检测中无法避免。如何消除导线电阻和接触电阻对电池采样中的影响是十分有意义的。



(a) 当判定为充满时, 电池端电压变化
(a) Change in battery terminal voltage when judged to be full charged



(b) 当判定为放空时, 电池端电压变化
(b) Change in battery terminal voltage when judged to be full discharged

图3 退役电池步骤1)中端电压变化

Fig. 3 The battery terminal voltage change in Step1)

图4描述的是Thevein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。当电池没有被充放电时,没有电流流过 R_0 ,电池的端电压等于开路电压 U_{ocv} 和 R_0 端电压之和。当电池被充放电时,由于 R_0 两端有电流流过,电池的端电压将受到导线电阻和接触电阻的影响。在实际中,导

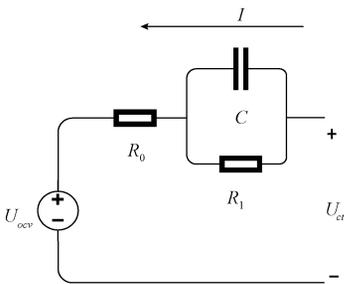


图4 Thevein 等效电路模型

Fig. 4 Thevein Equivalent Circuit Model

线电阻和接触电阻是不可控的,这会导致不同设备对电池充放电时检测的电池端电压存在差异,进而影响SOH的估计精度。

在经历步骤2)的静置过程后,电容 C 两端的电压通过电阻 R_1 被充分释放。在步骤3)中对电池进行短时间的脉冲放电,电流变化瞬间造成的电压变化是由 R_0 引起的。在获得 R_0 后,电池的端特征电压可以:

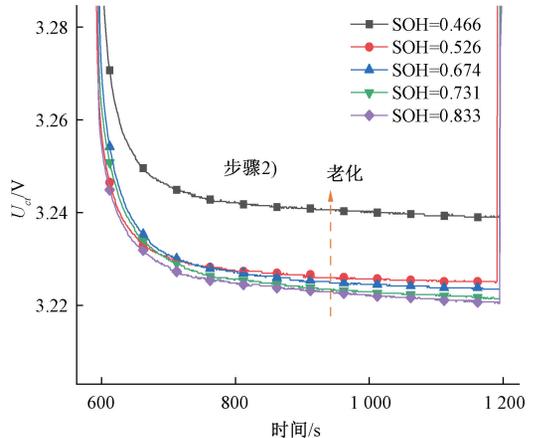
$$U_* = U'_{ct} - I \times R_0 \quad (2)$$

式中:当步骤1)为放电时, R_0 为 R_{0d} ;当步骤1)为充电时, R_0 为 R_{0c} 。通过式(2),电池端电压 U_{ct} 中受到不可控导线电阻和接触电阻影响的部分将被剔除。

由于不同SOC下,电池的欧姆电阻 R_0 存在微小差异。为了避免SOC对 R_0 值的影响, U'_{ct} 选取为步骤1)即将结束前1s的电池端电压值。 V_{dend} 选取为电池放电结束后1s的电池端电压,以避免接触电阻和导线电阻的影响。

1.3 静置阶段特征提取

如图5所示,众所周知,充电和放电会引起电子和离子在电极中的分布不平衡,这就是极化^[31]。极化会导致电极电位偏离平衡电位。在初始状态,然后慢慢达到一个稳定的值,这是由活化和浓度去极化引起的。如图5所示,当充放电过程停止时,电池的电压在弛豫过程中仍然变化。这可以理解为电极中的电荷再分配过程或所谓的去极化过程。当电池被充满后放电相同的容量,SOH越高电池的剩余SOC越高,相对应的电压越高。当电池被放空后充电相同的容量,SOH越低电池的剩余SOC越高,相对应的电压越高。这种SOC微弱差异造成了电池静置电压的差异。这种电压差异会随着静置时间的增加而逐渐稳定。静置阶段结束时的电压 V_0 与SOH呈现稳定相关性。因此本文选取静置阶段结束时的电压 V_0 作为SOH的HF之一。从静置过程可以看出,电池的静置电压变化与电池SOH有着很强的关联性。



(a) 当判定为放空时, 电池静置电压变化
(a) Change in resting voltage when judged to be full discharged

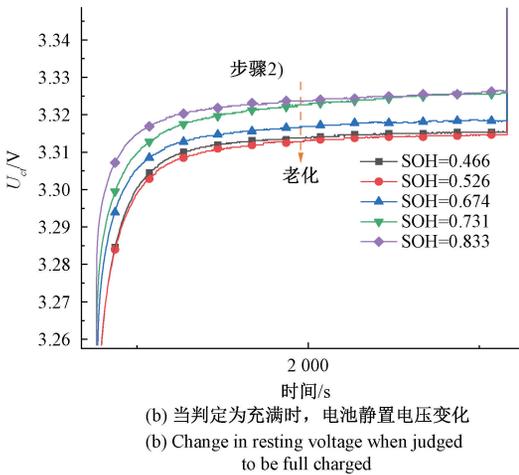


图 5 退役电池步骤 2) 中端电压变化

Fig. 5 The battery terminal voltage change in Step2)

弛豫效应是电池充放电过程中基本特性之一。电池在静置过程中电压的持续弛豫现象是由电池极化所引起的,通过研究电压的弛豫曲线,从而可以将电池的极化与电池的性能建立起关联。弛豫现象包含了离子和电子的流动信息,可以被用于评估 SOH。同时,为了进一步分析不同 SOH 退役电池,本文提取步骤 2) 过程中的静置电压频域信息。

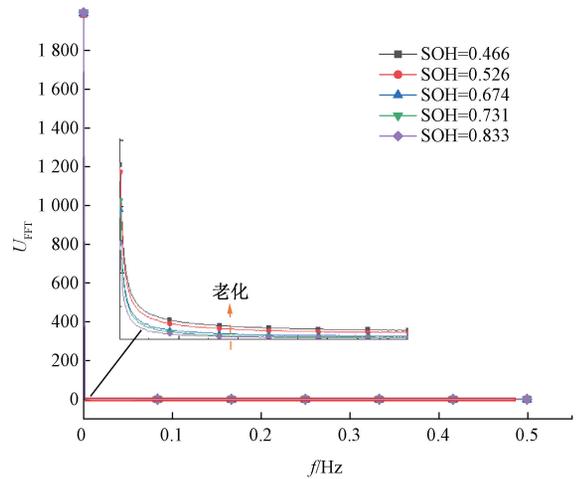
将步骤 2) 静置过程中的电压进行傅里叶分解后,电压的变化速度和趋势被进一步的分析。由于直流分量的相位为 0,直流分量的相位未在图 6 中绘制。如图 6 所示,将静置过程中电压分解后,可以看出 U_{FFT} 的交流分量随着电池的老化而逐渐增加同时,图 6(c) 和 (d) 中低频部分的相角 Pha_{FFT} 与 SOH 呈现出负相关的趋势,但这种负相关并不是严格成立的。 U_{FFT} 和 Pha_{FFT} 与 SOH 的相关性系数分析将在实验部分进一步描述。 U_{FFT} 和 Pha_{FFT} 与 SOH 的相关性被提出用于估计 SOH。图 6 中, U_{FFT} 后的交流分量 U_{FFT} 在两种策略下都随着 SOH 的增加而降低,但是两种策略的直流分量随 SOH 的变化不同,这将在实验与讨论部分描述。

1.4 动态电压特征提取

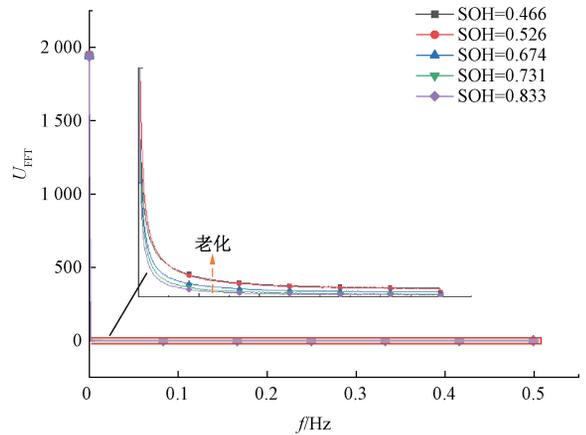
如图 7 所示,对电池依次进行 30 s 的充电、静置和放电。尽管这个过程耗费时间很短,但它包含着内阻以及 HF。内阻是评价 SOH 的重要指标之一。在电池得到充分的静置后,电阻测试结束。

电池欧姆电阻是指电流流过电池内部时受到的阻力,受到电极材料、电解液、隔膜等电池零件和接触电阻、导线电阻的影响。它与电池的尺寸、结构、连接方式等有

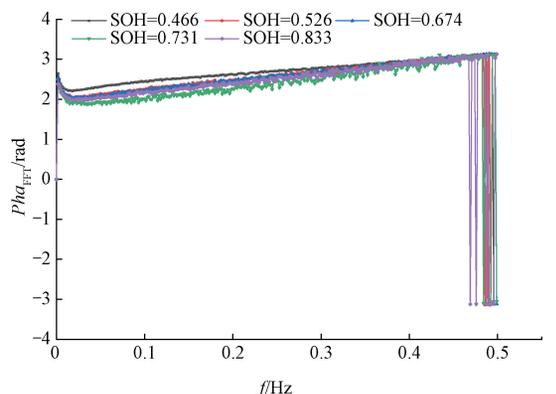
关,通常在温度恒定时比较稳定。在电流变化瞬间,电池端电压受到电池本身电阻、接触电阻、导线电阻的影响。由于接触电阻和导线电阻的不可控,因此本文未将 R_{oc} 、 R_{od} 作为本文的 HF。



(a) 当判定为充满时, U_{FFT} 随频率变化
(a) U_{FFT} versus frequency when judged to be full charged



(b) 当判定为放空时, U_{FFT} 随频率变化
(b) U_{FFT} versus frequency when judged to be full discharged



(c) 当判定为充满时, 相位随频率变化
(c) Phase versus frequency when judged to be full charged

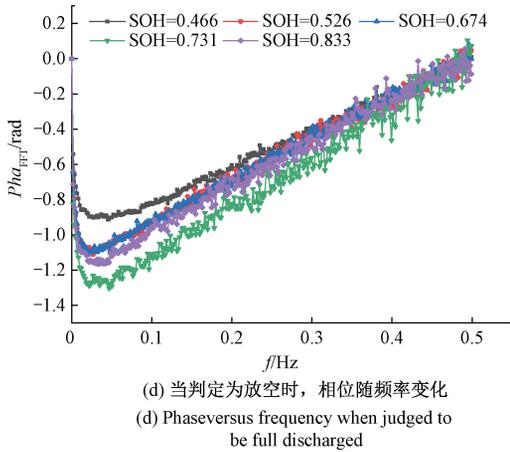
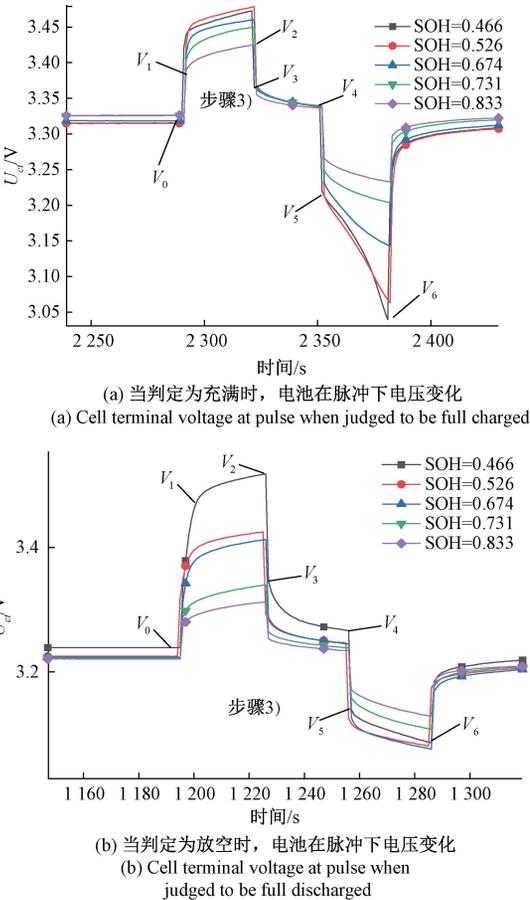
图6 U_{FFT} 和 Phase 随频率变化Fig. 6 U_{FFT} and Phase versus frequency

图7 退役电池在电流脉冲下的电压

Fig. 7 Cell terminal voltage at pulse

电池极化电阻是指电化学反应时由于极化现象引起的额外的阻力, 主要包括电化学极化和浓差极化两种。前者是指由于反应速率受限而导致反应物或产物在表面积累或消耗, 从而改变了表面上的平衡势差。后者是指

由于反应物或产物在空间分布不均匀而导致浓度梯度, 从而影响了扩散速率和反应速率。它们与反应条件、温度、充放电状态等有关, 通常随着影响极化水平的因素变动而变动。极化电阻 R_{lc} 和 R_{ld} 被认为与电池的老化状态有关。一般来说, 随着电池的使用极化电阻逐渐增加。

$$R_{oc} = \frac{V_1 - V_0}{I} \quad (3)$$

$$R_{lc} = \frac{V_2 - V_1}{I} \quad (4)$$

$$R_{od} = \frac{V_4 - V_5}{I} \quad (5)$$

$$R_{ld} = \frac{V_5 - V_6}{I} \quad (6)$$

2 退役电池 SOH 快速估计策略

HF 的获取是实现 SOH 快速估计的基础, 本文的 HF 获取策略能够适用任意 SOC 的退役电池。首先, 选取一定数量的退役电池作为 RFR 算法的训练集。在获取训练集的 HF 后, 利用训练集训练 RFR 算法获得 SOH 估计模型。此后, 在获取需要估计 SOH 退役电池的 HF 后, 仅需将 HF 输入训练好的 SOH 模型便可获得预估 SOH。本节分别介绍 HF 的获取策略以及 RFR 算法的实施步骤。

2.1 HF 获取策略

利用数据驱动的方法快速估计退役电池 SOH 时, 数据驱动所依赖的 HF 受到 SOC 的影响。而退役电池 SOC 很难被快速准确估计, 为此本文提出利用 SOC 差异下的电池电压、内阻中提取 HF。退役电池首先被快速判定大致的 SOC 区间, 然后根据 SOC 判定充满或放空。在被充满或放空后, 所有退役电池的荷电状态将会处于相同的基准。此后, 退役电池被放电/充电 10% 的额定容量, 不同 SOH 退役电池的 SOC 将存在差异, 这种差异会造成电池电压 V_0 、 V_{dend} 、 U_* 的不同。这些特征电压被视为估计电池 SOH 的 HF。此后, 退役电池被静置 10 min 以分析弛豫电压的变化趋势。为了进一步分析弛豫电压的变化, 本文将电池静置过程中的电压进行快速傅里叶分解获得幅值 U_{FFT} 和相角分量 Pha_{FFT} 。此后, 利用电流脉冲获得电池的极化内阻 R_{lc} 、 R_{ld} 。

在获得多种退役电池 HF 后, 如何提取这些 $HFx_i = \{R_{lc}, R_{ld}, V_0, V_{\text{dend}}, U_*, U_{\text{FFT}}, Pha_{\text{FFT}}\}$ ($i=1, 2, 3, \dots, N$) 与 SOH 之间的关联性是需要解决的另一个问题。由于造成电池 SOH 衰退的原因有很多, 如使用温度、放电倍率、过充过放次数以及电池制造时的缺陷等。这些因素与 SOH 之间的关系并不是一一对应的, 因此即使 SOH 相同的电池的 HF 也存在差异。这种不确定性造成了利用单一 HF 估计退役电池 SOH 十分困难。

2.2 遗传优化算法

随机森林回归是一种基于多个决策树的集成学习方法,它具有不需要做特征选择,可以自动评估 HF 重要性的优势。并且其在处理回归过程时,准确率高、抗拟合能力强。但是随机森林回归算法的实现需要选取合适的超参数。合适的超参数的选取过程十分复杂、费时。遗传优化算法是一种模拟自然进化过程寻找最优解的方法,能够解决超参数选取复杂的问题。

1) 初始化:生成初始候选解的种群。这可以通过随机或启发式方法来完成。

2) 评估:使用适应度函数评估每个候选解的适应度,该函数衡量解决优化问题的能力。

$$Fitness = RMSE =$$

$$\sqrt{\frac{1}{N} \sum_{i=1}^N (\text{SOH}_{real}(i) - \text{SOH}_{estimate}(i))^2} \quad (7)$$

3) 选择:根据适应度选择用于繁殖的父代。

4) 交叉:通过结合两个父代的遗传信息来创建后代。

5) 变异:对后代进行随机更改,以维持种群中的多样性。

6) 替换:用后代替换种群中适应度最低的个体。

7) 终止:重复步骤 2)~6),直到满足终止条件,如达到最大代数或达到满意的适应度水平。

2.3 随机森林回归算法

遗传算法优化随机森林回归算法(genetic algorithm-random forest regression, GA-RFR)是将 GA 算法用于优化 RFR 模型的超参数的方法,可以提高 RFR 模型的收敛速度和预测性能。随机森林模型是一种基于多个决策树进行投票或平均来进行分类或回归的集成学习方法。

RFR 算法的流程大致如下:

1) 从原始数据集中有放回地抽取多个子样本,每个子样本的大小和原始数据集相同;

2) 对每个子样本,构建一棵决策树,每次分裂节点时,从所有 HF 中随机选取一部分 HF 作为候选特征;

3) 对于新的输入数据,将其输入到每棵决策树中,得到多个回归结果;

4) 对多个回归结果取平均值作为最终的输出结果。

3 实验与讨论

为了验证本文选取 HF 参数是否能反映电池 SOH,本文选取了 510 节磷酸铁锂退役电池。这些退役电池的额定容量为 30 Ah,曾用于储能、电动汽车多种使用场景。为了避免温度对结果的影响,本文测试在 25°C 下进行。为了验证本文策略估计 SOH 的效果,本文需要分别获取 GA-RFR 算法的训练集和测试集。训练集由 500 节退役

电池分别在充满和放空两种策略下的 HF 构成,训练集的获取流程如下:

1) 将退役电池充满后,以 20 A 电流放电 10% 额定容量,静置 10 min,然后施加脉冲。

2) 依次获取 V_0 、 U'_{ct} 、 U_* 、 U_{FFT} 、 V_{end} 、 R_{ld} 、 R_{lc} 作为充满策略下的 HF。

3) 将退役电池放空后,以 20 A 电流充电 10% 额定容量,静置 10 min,然后施加如图 7 所示幅值为 20 A 的脉冲。

4) 依次获取 V_0 、 U'_{ct} 、 U_* 、 U_{FFT} 、 V_{dend} 、 R_{ld} 、 R_{lc} 作为放电策略下的 HF。

5) 在获取充满和放空两种策略下 HF 后,对退役电池完整充满放空两次以获取退役电池的准确 SOH。

6) 将以上两种策略下获得的 HF 及相应的 SOH 训练 GA-RFR 算法以获得 SOH 估计模型。

测试集从另外 10 节退役电池中获得,测试集获取流程如下:

1) 判断退役电池 SOC 的大致区间,若 SOC 大于 50% 时,利用充满策略获取 HF。将退役电池充满后,以 20 A 电流放电 10% 额定容量,静置 10 min,然后施加脉冲。若 SOC 小于 50% 时,利用放空策略获取 HF。将退役电池放空后,以 20 A 电流充电 10% 额定容量,静置 10 min,然后施加如图 7 所示幅值为 20 A 的脉冲。

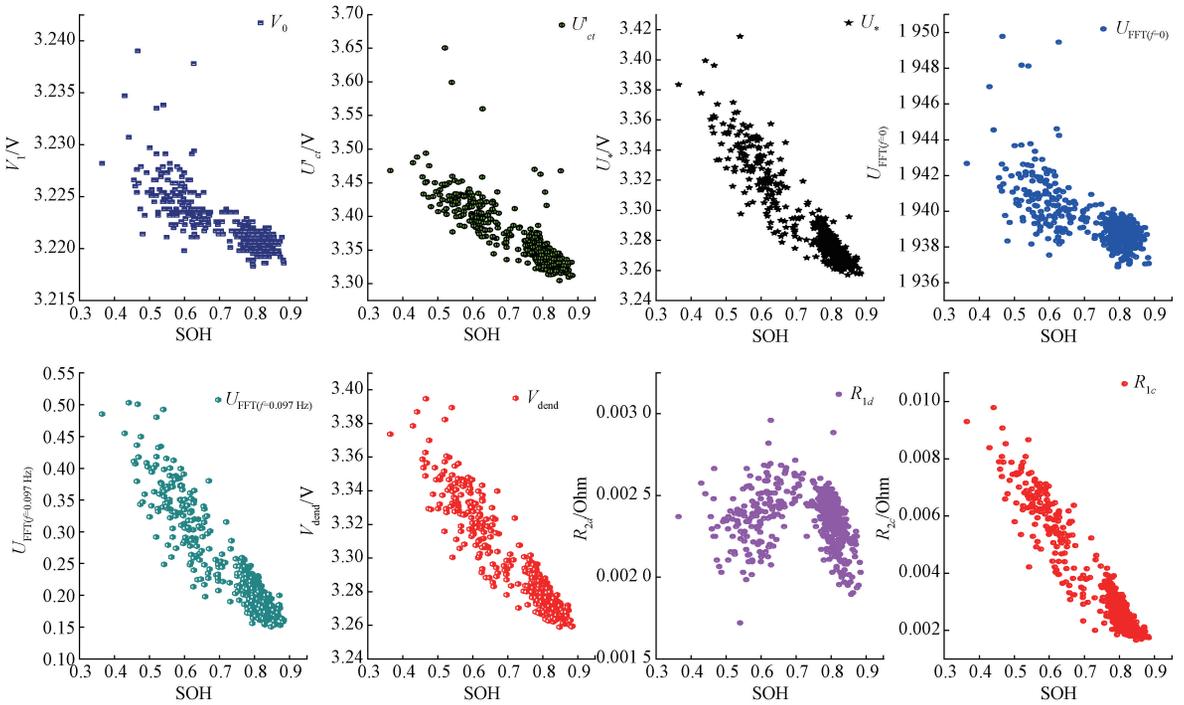
2) 将获得的 HF 导入相应策略下训练好的 SOH 估计模型中,获取相应的估计 SOH。

3.1 相关性分析

如图 8 所示,测试集中多种 HF 与 SOH 之间存在不同程度的相关性。但是由于不同退役电池使用场景不同,退役电池的各种 HF 与 SOH 之间并不是一一对应。这使得单独依赖某一 HF 参数估计电池的 SOH 十分困难。这是本文选择随机森林回归结合多种参数估计电池 SOH 的原因。其中, V_0 、 U_* 、 V_{dend} 、 $U_{FFT}(f=0)$ 与 SOH 的相关性是由于本文两种不同 SOH 估计策略造成不同 SOH 电池之间的 SOC 差异形成的。 $U_{FFT}(f=0)$ 描述的是静置阶段电压经过 FFT 分解后的直流分量,在放空策略下随电池 SOH 的增加而降低,在充满策略下随 SOH 的增加而增加。在判定为充满策略时,由于放电相同容量,SOH 越高的退役电池相应的 SOC 越高。当判定为放空策略时,类似的,SOH 越高的退役电池相应的 SOC 越低。

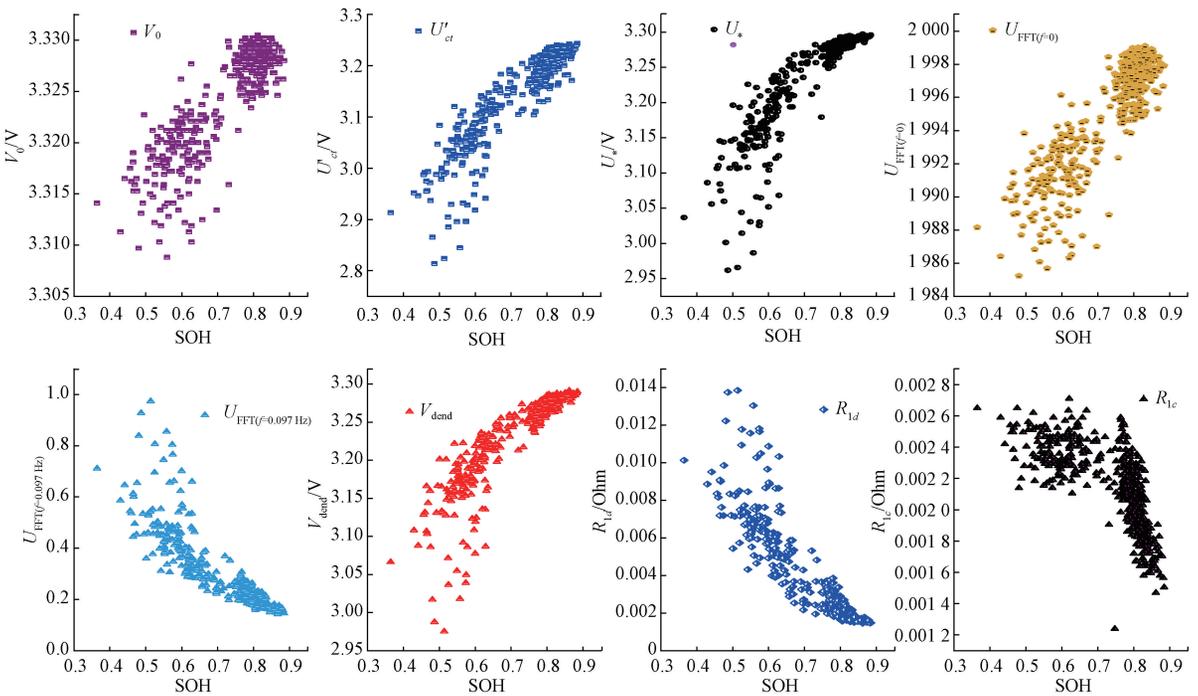
因此在图 8 中,当判定为放空策略时, V_0 、 U_* 、 V_{dend} 、 $U_{FFT}(f=0)$ 与 SOH 呈现出负相关性;当判定为充满策略时, V_0 、 U_* 、 V_{dend} 、 $U_{FFT}(f=0)$ 与 SOH 呈现出正相关性。但是实际上,由于不同的退役电池经历的历史工况不同, V_0 、 U_* 、 V_{dend} 、 $U_{FFT}(f=0)$ 与 SOH 并不是一一对应的。

R_{ld} 、 R_{lc} 描述的是电池的极化电阻,会随着电池的老化而逐渐增加。类似的,不同的历史工况造成 R_{ld} 、 R_{lc} 的



(a) 当判定为放空时, 不同SOH退役电池的HF值

(a) HF for different SOH retired cells when judged to be fully discharged



(b) 当判定为充满时, 不同SOH退役电池的HF值

(b) HF for different SOH retired cells when judged to be fully charged

图8 不同健康特征随SOH变化

Fig. 8 HF for different SOH retired cells

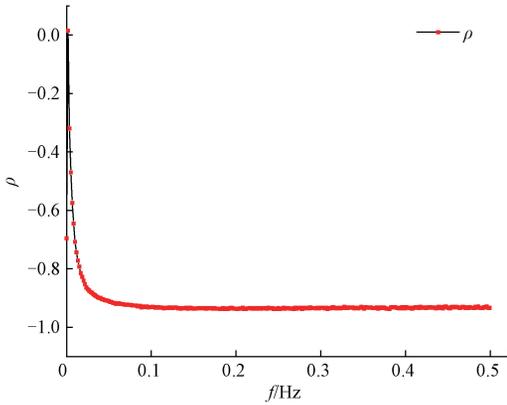
衰退速度存在差异, 这使得 R_{ld} 、 R_{lc} 与 SOH 之间同样不是一一对应的。如图 8(a) 所示, R_{ld} 仅仅在 SOH 在

0.7~0.8 与 SOH 呈现负相关性, 在 SOH < 0.7 后并未表现出严格的负相关性, 这是由于这些电池所经历的历史

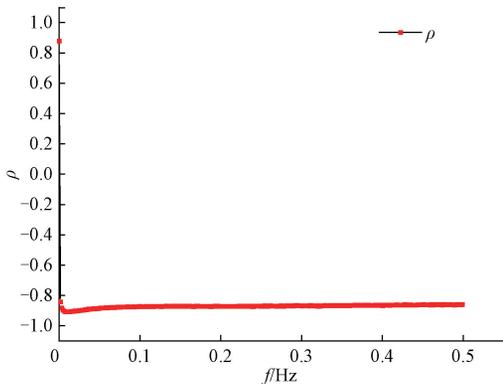
工况差异导致的,这也是退役电池 SOH 估计困难的原因。 U_{FFT} 描述的是迟滞电压的变化速度, U_{FFT} 交流部分在两种策略下均与 SOH 呈现负相关性,这表明 U_{FFT} 交流部分与电池老化程度有关。为了描述 U_{FFT} 交流部分与 SOH 的关系,本文绘制了频率为 $f=0.097 \text{ Hz}$ 的 U_{FFT} 与 SOH 的相关性。如图 8 所示,在两种分选策略下, $U_{\text{FFT}}(f=0.097 \text{ Hz})$ 均与 SOH 呈现出负相关性。其他频率下的 U_{FFT} 与电池 SOH 相关性程度利用相关系数 ρ 进行描述。

$$\rho(XY) = \frac{n \sum xy - \sum x \sum y}{\sqrt{(n \sum x^2 - (\sum x)^2)(n \sum y^2 - (\sum y)^2)}} \quad (8)$$

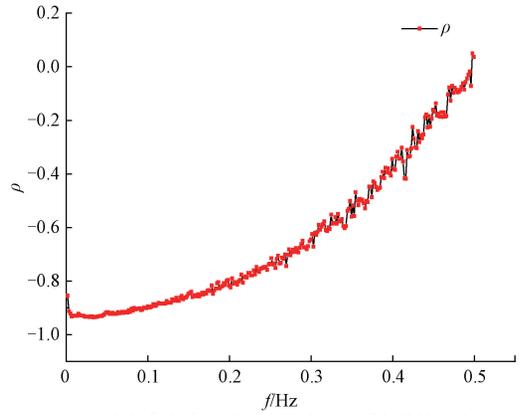
其中, x 表示退役电池的 SOH, y 表示相应的 HF, n 表示退役电池的数量。如图 9 所示,绝大多数 U_{FFT} 与 SOH 的 ρ 维持在 0.9 附近。同时,频率小于 0.1 Hz 时 Pha_{FFT} 与 SOH 之间的 ρ 同样维持在 0.9 附近。这验证了本文提出利用静置过程中频域信息估计电池 SOH 的可行性。



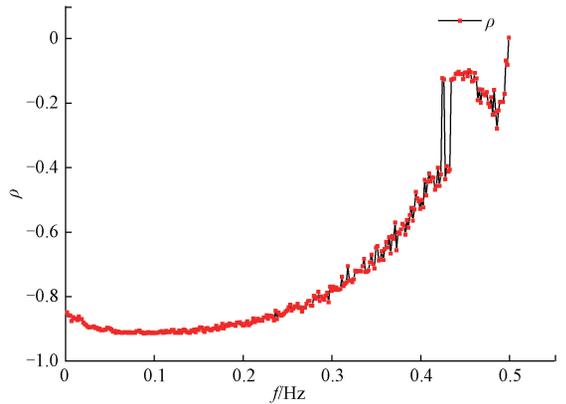
(a) 当判定为放空时, U_{FFT} 与 SOH 的相关性系数
(a) The correlation coefficients between U_{FFT} and SOH when judged to be discharged fully



(b) 当判定为充满时, U_{FFT} 与 SOH 的相关性系数
(b) The correlation coefficients between U_{FFT} and SOH when judged to be charged fully



(c) 当判定为放空时, Pha_{FFT} 与 SOH 的相关性系数
(c) The correlation coefficients between Pha_{FFT} and SOH when judged to be discharged fully



(d) 当判定为充满时, Pha_{FFT} 与 SOH 的相关性系数
(d) The correlation coefficients between Pha_{FFT} and SOH when judged to be charged fully

图 9 U_{FFT} 和 Pha_{FFT} 与 SOH 的相关性系数

Fig. 9 The correlation coefficients between $U_{\text{FFT}}/Pha_{\text{FFT}}$ and SOH

此外,为了定量分析各种 HF 与 SOH 的相关性,本文分别计算不同 HF 与电池 SOH 的相关性系数。如表 1 所示,本文选取的大部分 HF 与电池 SOH 之间呈现出相关性,但是同一 HF 参数的相关性系数在充满和放空两种策略下不同。从表 1 可以看出,相比端电压 U'_{ca} ,经过本文提出式的方案, U_* 与电池 SOH 之间的相关性有一定增加。

表 1 不同 HF 和 SOH 之间的相关性系数

Table 1 The correlation coefficients between different HF and SOH

估计策略	V_0	U'_{ca}	U_*	V_{dend}	R_{1d}	R_{1c}
放空策略	-0.80	-0.85	-0.93	-0.94	-0.06	-0.95
充满策略	0.87	0.90	0.91	0.89	-0.90	-0.72

3.2 单因素分析

为了验证随机森林回归算法的有效性,本文利用上述500节电池的单个HF分别对其进行训练,然后将训练好的模型估计SOH。为了便于定量描述SOH的估计效果,表2描述了利用随机森林回归算法单独使用某一个HF参数估计电池SOH的误差的均方根值RMSE。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SOH_{real} - SOH_{estimate})^2}{n}} \quad (9)$$

表2 使用单一HF估计电池的SOH时的误差RMSE值

Table 2 The RMSE values of the error in estimating the SOH using the single HF

估计策略	V_0	U'_{ct}	U_*	V_{dend}	R_{ld}	R_{lc}	U_{FFT}	Pha_{FFT}	结合
放空策略	0.025 0	0.033 0	0.028 0	0.025 0	0.101 0	0.028 7	0.016 4	0.238 7	0.015 6
充满策略	0.036 4	0.014 6	0.009 8	0.018 6	0.024 3	0.056 6	0.012 6	0.262 7	0.012 6

计算能力并不像车载计算机那么有限。这也是遗传优化算法能够在实际中应用的基础。

在建立退役电池SOH估计的随机森林回归模型时,能够参考和分析的数据仅仅只有训练集。所以遗传优化算法的自适应函数,即评估模型优劣的标准只能依赖训练集建立。遗传优化算法的自适应函数定义为训练后的随机森林回归模型估计训练集SOH误差的RMSE值。如图10所示,随着迭代次数的增加,随机森林回归算法估计训练集误差的RMSE逐渐降低,这验证了遗传优化算法的有效性。基于以上分析,不同HF与SOH的相关性是不同的。随机森林回归算法的优势在于能够评估不同HF的重要性程度,然后根据HF重要性程度判定其对最终SOH估计结果的贡献。

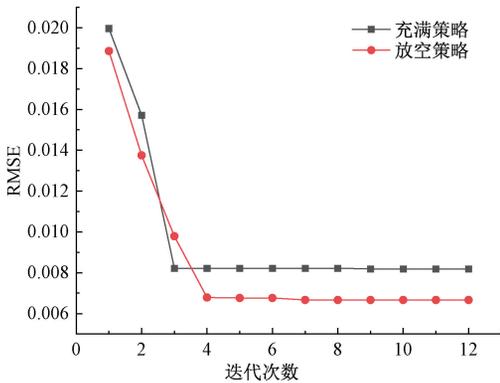


图10 遗传算法迭代趋势

Fig. 10 Genetic algorithm iteration trend graph

图11描述了不同HF的重要性程度。其中 HF_{1-5} 依次代表 V_0 、 U_* 、 V_{dend} 、 R_{ld} 、 R_{lc} , HF_{6-306} 表示不同频率下的 U_{FFT} , $HF_{307-607}$ 表示不同频率下的 Pha_{FFT} 。此外,为了验

其中, SOH_{real} 指的是真实SOH, $SOH_{estimate}$ 指的是估计的SOH, n 指的是选取的电池数量。如表2所示,单个因素估计电池SOH效果最好的是 R_{lc} 。但是相比多参数估计电池SOH, R_{lc} 估计效果略显逊色。这是由于退役电池历史状态多种多样造成的。这再次验证了本文提出利用随机森林回归算法估计电池SOH的优越性。

3.3 遗传优化随机森林回归算法效果验证

遗传优化算法是通过选取合适的超参数实现对随机森林回归预测效果改进的。当退役电池分选时,分选的

证提出的遗传优化随机森林回归算法在退役电池SOH估计精度的优越性。本文另外选取了10节不同SOH的退役电池,使用多种回归分析算法依赖本文提出的HF $\{R_{lc}, R_{ld}, V_0, V_{dend}, U_*, U_{FFT}, Pha_{FFT}\}$ 估计SOH。

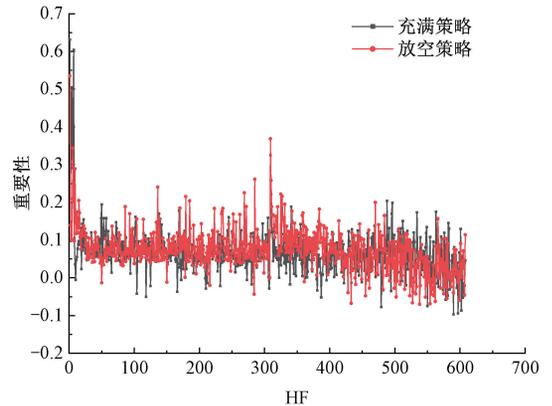
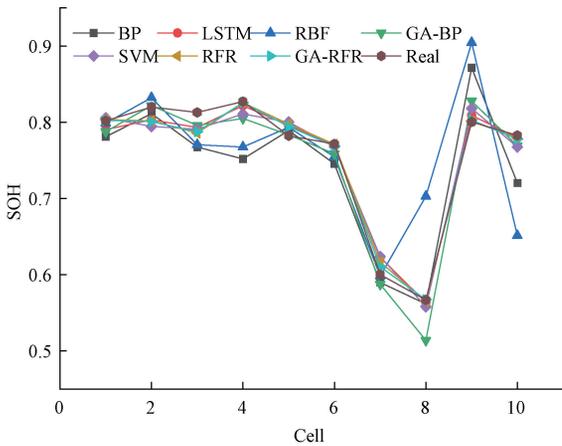


图11 不同健康特征的重要性程度

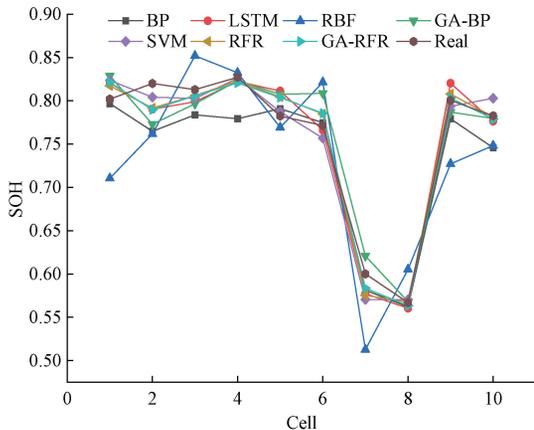
Fig. 11 Importance level of different health characteristics

如图12所示,大部分回归算法能利用本文提出的HF参数估计电池的大致SOH。但是由于回归算法的之间原理的差异,SOH的估计效果存在不同程度的差异。同时,在充满和放空两种策略下,SOH的估计效果有略微的差异。如表3所示,估计效果最好的是本文提出的GA-RFR算法。如图12(a)所示,在判定为充满策略时,GA-RFR算法估计SOH时 $Cell_3$ 误差最大,最大误差为2.5%;如图12(b)所示,在判定为放空策略时,GA-RFR算法估计SOH误差最大的为 $Cell_2$ 。 $Cell_2$ 的SOH估计误差为3%。这验证了本文方法在退役电池SOH估计上的有效性。



(a) 当判定为充满时, 不同回归算法估计 SOH

(a) The SOH estimation results for different regression algorithms when judged to be charged fully



(b) 当判定为放空时, 不同回归算法估计 SOH

(b) The SOH estimation results for different regression algorithms when judged to be discharged fully

图 12 不同回归算法估计 SOH 结果

Fig. 12 The SOH estimation results for different regression algorithms

3.4 SOH 估计时间对比

由于测试时退役电池的 SOC 未知, 现有方法在快速估计电池 SOH 时很难应用。电化学阻抗谱是通过向电池内部注入不同频率的交流信号获取电池内部阻抗的一种方法。电化学阻抗谱被认为与电池的老化状态有关, 可以用评估电池 SOH。然而电池在不同 SOC 下的阻抗存在不同, 这使得在未知退役电池 SOC 的条件下估计电池 SOH 十分困难。同样, 弛豫电压在快速估计电池 SOH 时也会面临类似的问题。容量增量法需要对电池以 C/20 (C 为充放电倍率) 充放电, 这个过程会耗费大量的时间。所以在电池分选时使用的方法依然是安时积分法, 即通过完整的充放电。因此, 本文与安时积分法耗时进行对比实验。

测试集中 10 节电池分别充满后随机放电至不同 SOC, 然后分别计算了安时积分法和本文方法在不同放电倍率下耗费的时间。如表 4 所示, Cell₁、Cell₂、Cell₃、Cell₄、Cell₅ 被放电至低于 50% 状态, Cell₆、Cell₇、Cell₈、Cell₉、Cell₁₀ 被放电至高于 50% SOC。在本文的分选策略中, Cell₁₋₅ 利用文献中获取的 SOC 小于 50% 应被放空后再获取 HF 参数, Cell₆₋₁₀ 应被充满后获取 HF 参数。由于退役电池的状态未知, 退役电池充满或放空电流一般小于 1C 以避免安全事故。本文提出的健康估计测量所消耗的时间包括以下部分: 充满/放空耗费的时间 (与电池初始 SOC 以及电流有关)、放电/充电 1/10 额定容量的时间 (8.6 min)、静置时间 (10 min)、动态电压获取耗费时间 (90 s)。

表 4 中, 分选时间分别在电池被允许 0.66C (20 A) 和 1C (30 A) 电流充满/放空条件下讨论。在电池被允许 0.66C 充放电时, 本文方法 SOH 的估计时间仅仅为安时积分法的 1/2。在电池被允许 1C 充放电时, 表 4 中

表 3 不同回归算法估计的 SOH 误差的 RMSE

Table 3 The RMSE of the SOH errors estimated by different regression algorithms

估计策略	LSTM	RBF	GA-BP	SVM	BP	GA-RFR	RFR
放空策略	0.018 2	0.056 3	0.024 2	0.015 5	0.029 1	0.013 9	0.015 6
充满策略	0.012 8	0.072 5	0.022 5	0.017 1	0.042 4	0.011 4	0.012 6

表 4 安时-积分法与所提方法的 SOH 估计时间对比

Table 4 The sorting times' comparison between ampere-time integration and method proposed

估计策略	Cell ₁	Cell ₂	Cell ₃	Cell ₄	Cell ₅	Cell ₆	Cell ₇	Cell ₈	Cell ₉	Cell ₁₀
初始 SOC/%	7	13	25	36	47	53	76	82	88	96
估计 SOC/%	10	10	30	40	40	60	70	80	90	>95
安时积分法 (0.66C, h)	2.32	2.30	2.13	2.03	1.80	1.83	1.25	1.12	1.46	1.34
本文方法 (0.66C, h)	0.38	0.46	0.60	0.75	0.85	0.97	0.64	0.57	0.56	0.47
安时积分法 (1C, h)	1.55	1.53	1.42	1.36	1.20	1.37	0.88	0.82	1.02	0.95
本文方法 (1C, h)	0.36	0.41	0.50	0.60	0.67	0.79	0.57	0.54	0.53	0.47

10节退役电池利用本文方法估计SOH耗时均不超过安时积分法耗时的60%,这表明本文方法大幅降低电池SOH的估计时间。同时,在本文获得电池SOH的过程中,电池内阻也同时获得,这种分选策略能够有效为电池二次利用分选时提供指导。

4 结 论

退役电池的历史状态多种多样,并且测试时退役电池的SOC未知,这使得退役电池SOH的快速估计十分困难。本文提出了一种适用于未知SOC退役电池的快速电池SOH方案,能够有效降低电池SOH的估计时间。并且针对电池SOH估计精度低,本文介绍了多种避免接触电阻和导线电阻影响检测结果的方案。同时,多种HF相结合的方法被提出,相比单因素估计历史状态多种多样的电池SOH,本文提出的GA-RFR估计电池SOH精度更高。在获取退役电池的SOH后,进一步的内短路、过充/放电故障诊断是下一步研究的方向。

参考文献

- [1] 武龙星, 庞辉, 晋佳敏, 等. 基于电化学模型的锂离子电池荷电状态估计方法综述[J]. 电工技术学报, 2022, 37(7): 1703-1725.
WU L X, PANG H, JIN J M, et al. A review of SOC estimation methods for lithium-ion batteries based on electrochemical model [J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1703-1725.
- [2] 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 J L, LI Y X, CHEN G, et al. Research on feature extraction and SOH evaluation methods for retired power battery[J]. Proceedings of the CSEE, 2022, 42(4): 1332-1347.
- [3] 颜宁, 李相俊, 钟瑶, 等. 基于静动态一致性的退役动力电池模组阶梯式筛选方法[J]. 中国电机工程学报, 2023, 43(5): 2060-2070.
YAN N, LI X J, ZHONG Y, et al. Stepwise screening method for retired power battery modules based on static-dynamic consistency [J]. Proceedings of the CSEE, 2023, 43(5): 2060-2070.
- [4] 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, DOI: 10.1016/j. est. 2021. 102866.
- [5] ZHANG X, LU J L, YUAN S F, et al. A novel method for identification of lithium-ion battery equivalent circuit model parameters considering electrochemical properties[J]. Journal of Power Sources, 2017, 345: 21-29.
- [6] FANG L L, LI J Q, PENG B, Online estimation and error analysis of both SOC and SOH of lithium-ion battery based on DEKF method [J]. Energy Procedia, 2019, 158: 3008-3013.
- [7] LI X Y, YUAN C G, WANG Z P, et al. Lithium battery state-of-health estimation and remaining useful lifetime prediction based on non-parametric aging model and particle filter algorithm [J]. eTransportation, 2022, DOI:10.1016/j. etran. 2022. 100156.
- [8] 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 W J, WANG H M. 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.
- [9] 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.
- [10] YU Q Q, XIONG R, YANG R X, et al. Online capacity estimation for lithium-ion batteries through joint estimation method [J]. Applied Energy, 2019, DOI: 10.1016/ j. apenergy. 2019. 113817.
- [11] WANG R, SONG CH Y, GAO M X, et al. Model-data fusion domain adaptation for battery state of health estimation with fewer data and simplified feature extractor [J]. Journal of Energy Storage, 2023, DOI: 10.1016/j. est. 2023. 106686.
- [12] HOQUE M A, NURMI P, KUMAR A, et al. Data driven analysis of lithium-ion battery internal resistance towards reliable state of health prediction [J]. Journal of Power Sources, 2021, DOI: 10.1016/j. jpowsour. 2021. 230519.

- [13] GUO Y F, HUANG K, YU X Y, et al. State-of-health estimation for lithium-ion batteries based on historical dependency of charging data and ensemble SVR [J]. *Electrochimica Acta*, 2022, DOI:10.1016/j.electacta.2022.140940.
- [14] TAN X J, ZHAN D, LYU P X, et al. Online state-of-health estimation of lithium-ion battery based on dynamic parameter identification at multi timescale and support vector regression [J]. *Journal of Power Sources*, 2021, DOI:10.1016/j.jpowsour.2020.229233.
- [15] 周才杰,汪玉洁,李凯铨,等.基于灰色关联度分析-长短期记忆神经网络的锂离子电池健康状态估计[J].*电工技术学报*,2022,37(23):6065-6073.
ZHOU C J, WANG Y J, LI K Q, et al. State of health estimation for lithium-ion battery based on gray correlation analysis and long short-term memory neural network [J]. *Transactions of China Electrotechnical Society*, 2022, 37(23):6065-6073.
- [16] LI X Y, WANG Z P, YAN J Y. Prognostic health condition for lithium battery using the partial incremental capacity and Gaussian process regression [J]. *Journal of Power Sources*, 2019, 421: 56-67.
- [17] 李林泽,张向文.基于组合频率阻抗特征的锂离子电池健康状态估算[J].*储能科学与技术*,2023,12(5):1705-1712.
LI L Z, ZHANG X W. SOH estimation for lithium-ion batteries based on combination of frequency impedance characteristics [J]. *Energy Storage Science and Technology*,2023,12(5):1705-1712.
- [18] 车云弘,邓忠伟,李佳承,等.基于数据驱动的电池系统泛化 SOH 估计方法 [J]. *机械工程学报*, 2022, 58(24):253-263.
CHE Y H, DENG ZH W, LI J CH, et al. Generalized data-driven soh estimation method for battery systems [J]. *Journal of Mechanical Engineering*, 2022, 58(24):253-263.
- [19] GU X Y, SEE K W, LI P H, et al. A novel state-of-health estimation for the lithium-ion battery using a convolutional neural network and transformer model [J]. *Energy*, 2023, DOI:10.1016/j.energy.2022.125501.
- [20] LI Y, ZOU CH F, BERECIBAR M, et al. Random forest regression for online capacity estimation of lithium-ion batteries [J]. *Applied Energy*, 2018, 232: 197-210.
- [21] LI R ZH, HONG J CH, ZHANG H Q, et al. Data-driven battery state of health estimation based on interval capacity for real-world electric vehicles [J]. *Energy*, 2022, DOI:10.1016/j.energy.2022.124771.
- [22] SU X J, SUN B X, WANG J 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, DOI: 10.1016/j.apenergy.2022.119516.
- [23] OBREGON J, HAN Y, HO CH W, et al. Convolutional autoencoder-based SOH estimation of lithium-ion batteries using electrochemical impedance spectroscopy [J]. *Journal of Energy Storage*, 2023, DOI:10.1016/j.est.2023.106680.
- [24] ZHU J G, WANG Y X, HUANG Y, et al. Data-driven capacity estimation of commercial lithium-ion batteries from voltage relaxation [J]. *Nat Commun*, 2022, 13(1): 2261.
- [25] ZHOU R M, ZHU R, HUANG CH G, et al. State of health estimation for fast-charging lithium-ion battery based on incremental capacity analysis [J]. *Journal of Energy Storage*, 2022, DOI: 10.1016/j.est.2022.104560.
- [26] LIN X K, HAO X G, LIU Z Y, et al. Health conscious fast charging of li-ion batteries via a single particle model with aging mechanisms [J]. *Journal of Power Sources*, 2018, 400: 305-16.
- [27] LIU J Z, LIU X T. An improved method of state of health prediction for lithium batteries considering different temperature [J]. *Journal of Energy Storage*, 2023, DOI: 10.1016/j.est.2023.107028.
- [28] CHEN ZH, ZHAO H Q, ZHANG Y J, 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, DOI: 10.1016/j.jpowsour.2021.230892.
- [29] 骆凡,黄海宏,王海欣.基于电化学阻抗谱的退役动力电池荷电状态和健康状态快速预测 [J]. *仪器仪表学报*, 2021, 42(9): 172-180.
LUO F, HUANG H H, WANG H X. Rapid prediction of the state of charge and state of health of decommissioned power batteries based on electrochemical impedance

spectroscopy[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 172-180.

- [30] WANG Y H, HUANG H H, WANG H X. A new method for fast state of charge estimation using retired battery parameters[J]. Journal of Energy Storage, 2022, DOI: 10.1016/j.est.2022.105621.
- [31] QIAN K, HUANG B H, RAN A H, et al. State-of-health (SOH) evaluation on lithium-ion battery by simulating the voltage relaxation curves [J]. Electrochimica Acta, 2019, 303: 183-191.

作者简介



汪宇航, 2019 年于合肥工业大学获得学士学位, 现为合肥工业大学博士研究生, 主要研究方向为退役电池状态评估。

E-mail: 1298764646@qq.com

Wang Yuhang received his B. Sc. degree

from Hefei University of Technology in 2019. Currently, he is a Ph. D. candidate at Hefei University of Technology, and his main research interests are fast state assessment of retired batteries.



黄海宏 (通信作者), 分别于 1996 年和 1999 年获合肥工业大学学士和硕士学位, 2011 年从中国科学院合肥物质科学研究院获得博士学位, 现为合肥工业大学教授, 主要研究方向为电力电子技术和自动控制。

E-mail: hhaihong741@126.com

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