

DOI: 10.19650/j.cnki.cjsi.J2312076

基于脉冲电压频域特征和内阻的退役 电池快速初步分选策略*

汪宇航, 黄海宏, 王海欣

(合肥工业大学电气与自动化工程学院 合肥 230009)

摘要:随着新能源产业的发展,越来越多的退役电池如何处理成为了一个急需解决的问题。磷酸铁锂电池由于高能量密度及安全性的优点被广泛应用于汽车及储能场合,是现有退役电池中的主流之一。退役磷酸铁锂电池的二次利用场景是根据电池的健康状态、内阻等状态进行评估的,但是这个过程耗费大量的时间。本文提出利用脉冲过程电压的频域特征作为估计健康状态的健康特征,然后利用随机森林回归算法实现了健康状态的快速估计,这极大的缩短了退役磷酸铁锂电池分选的时间。在此基础上,本文提出利用基于高斯分布的异常参数识别方法评估异常内阻退役磷酸铁锂电池。通过实验验证,选取的15节磷酸铁锂电池中健康状态估计的最大误差为6%,且能够有效的筛除内阻与SOH不匹配的退役磷酸铁锂电池。

关键词: 退役电池; 健康状态; 快速分选; 脉冲电压

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

Fast preliminary sorting strategy for retired batteries based on pulse voltage frequency domain features and internal resistance

Wang Yuhang, Huang Haihong, Wang Haixin

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

Abstract: With the development of the new energy industry, how to deal with more and more retired batteries has become an urgent problem. Lithium iron phosphate batteries are widely used in automotive and energy storage scenarios due to the advantages of high energy density and safety. It is one of the mainstreams of existing retired batteries. The secondary utilization scenario of retired LiFePO₄ batteries is evaluated based on the health status of the battery, internal resistance, and other states. But, this process consumes a lot of time. In this article, we propose to use the frequency domain characteristics of the voltage during the pulse process as the health features for estimating the health state. Then, the random forest regression algorithm is used to achieve a fast estimation of the health state, which greatly shortens the time for the sorting of decommissioned batteries. On this basis, this article proposes the use of an abnormal parameter identification method based on Gaussian distribution to evaluate the abnormal internal resistance of retired lithium iron phosphate batteries. Through experimental evaluation, the maximum error of health state estimation in the selected 15 LiFePO₄ batteries is 6%, and the proposed method can effectively screen out the retired LiFePO₄ batteries whose internal resistance does not match with SOH.

Keywords: retired batteries; state of health; fast sorting; pulse voltage

0 引言

随着新能源产业的发展,电池在人类的生产生活中逐渐发挥着越来越重要的作用^[1-2]。当电池使用寿命达到极限后,如果没有得到较好的处理,将会对环境造成非

常大的危害^[3]。如何处理退役电池成为重要话题。退役电池的二次使用场景是根据电池的剩余容量、内阻、外观等状态进行评估的。虽然一般电池的健康状态(state of health, SOH)衰退至70~80%时^[4],这类电池被视为应该退役。但是实际中,车辆故障、安全事故等都会造成整车电池的退役,所以退役电池中存在大量可以二次使用的

收稿日期: 2023-10-26 Received Date: 2023-10-26

* 基金项目: 安徽省科技重大专项(18030901064)资助

电池。在退役电池的初步分选阶段,大致 SOH 便能判定退役电池的二次使用场景。判定退役电池是否需要拆解报废不需准确获取 SOH;路灯之类的单体使用场景对退役电池 SOH 准确估计的要求也并不高。如何将不同 SOH 和内阻的退役电池分选出来是十分值得研究的主题。

磷酸铁锂(LiFePO_4 , LFP)电池具有高能量密度、安全可靠的优点,是现有退役电池中的主流。LFP 电池是以 LPF 作为正极电池的统称,本文针对 LFP 电池展开研究。SOH 是评估退役 LFP 电池分选场景的重要指标,现阶段针对退役 LFP 电池的 SOH 研究较少,大多数 LFP 电池 SOH 的研究是针对在线场景的。一般针对 LFP 电池在线估计的研究可以被分为如下 3 种:1) 基于等效模型的 SOH 估计^[5-7]; 2) 基于自适应滤波算法的 SOH 估计^[8-9]; 3) 基于数据驱动的 SOH 估计^[10-12]。其中,等效模型包括电化学模型、等效电路模型、数学模型。基于等效模型的 SOH 估计方法通过模型参数或模型元件模拟电池的老化和故障机制。然而,经历的历史工况不同导致电池老化的机制也不同,这使得 LFP 电池的建模十分困难。在线场景中,自适应滤波算法被提出用于提高 SOH 实时估计精度。常见的自适应滤波算法包括卡尔曼滤波^[13-14]、粒子滤波^[15-16]等。但是基于自适应滤波的 SOH 估计方法一般适用于在线场景,无法实现 SOH 的快速估计。基于数据驱动的 SOH 估计方法将电池视为黑盒模型^[17-18],将选定的健康特征(health features, HF)输入数据驱动算法中训练 SOH 估计模型,然后根据 HF 的变化趋势估计 SOH。基于数据驱动的方法不需要考虑复杂的 LFP 电池内部机理,仅仅需要选择合适的 HF 和估计算法。因此,本文利用数据驱动方法估计退役 LFP 电池 SOH。

现阶段基于数据驱动的 SOH 估计研究大多数针对在线场景,HF 需要从大量的历史数据中获取。基于数据驱动方法的 HF 通过电化学阻抗谱、温度、增量容量曲线等方法获取。电化学阻抗谱一般通过向电池注入交流电流或交流电压获取,是一种诊断电池内部物理和化学状态的手段。文献[19-20]提出了从电化学阻抗谱中提取 LFP 电池 HF,然后利用数据驱动算法实现 SOH 的估计。电化学阻抗谱获取时间一般在几分钟到几十分钟之间,被视为一种快速 SOH 估计的方法。但是电化学阻抗谱检测设备十分昂贵且电化学阻抗谱在不同 SOC 下不同。而 LFP 电池的 SOC 无法通过开路电压(open circuit voltage, OCV)快速获取,这限制了利用电化学阻抗谱估计 SOH 的应用推广。文献[21]提出了一种基于遗忘因子递推总最小二乘并结合温度校正的锂离子动力电池 SOH 估计方法,但是这依赖于长时间的电池温度数据。而退役 LFP 电池分选时,历史运行数据是未知的且电池

温度容易受到测试环境的影响。文献[22]通过增量容量曲线分析和集成电路峰面积分析,研究了电池的老化机制,然后结合回归算法实现了 SOH 的估计。但是增量容量曲线依赖于完整的充放电过程,这限制了其在退役 LFP 电池快速分选上的应用。文献[23]提出一种基于恒流充电过程中等电压间隔充电持续时间的 HF 提取方法,该方法从电池管理系统中获取连续充电持续时间能有效表征 LFP 电池的老化特性。但是退役 LFP 电池 SOH 估计时,退役 LFP 电池的历史数据无法获取,这造成基于数据驱动的 SOH 估计方法无法直接应用于退役 LFP 电池 SOH 估计。因此,如果利用数据驱动的方法解决退役 LFP 电池分选耗时的问题,现有的 HF 提取方法很难直接被用于退役 LFP 电池 SOH 的快速估计。

现阶段针对退役 LFP 电池 SOH 估计的研究很少,且在线 SOH 估计算法无法直接用于退役 LFP 电池快速 SOH。在线 SOH 估计一般以历史数据为基础,但是退役 LFP 电池估计 SOH 时历史数据是未知的,且不同退役 LFP 电池经历的历史工况不同。退役 LFP 电池 SOH 估计的测试是在离线情况下进行的,这意味着退役 LFP 电池可以被任意形式的充放电。除了 SOH 估计精度,在退役 LFP 电池的分选过程中,耗时是需要考虑的重要因素。退役 LFP 电池的大致 SOH 决定着其二次使用的场景,但是依赖于昂贵的设备或长时间的充放电获取退役 LFP 电池 SOH 会使得退役 LFP 电池分选承担昂贵的成本。因此,提出一种快速廉价的退役 LFP 电池 SOH 估计方案能够降低退役 LFP 电池初步分选的时间和经济成本。

内阻与退役 LFP 电池使用时的功率状态、发热以及潜在故障有关,是评估退役 LFP 电池老化程度的另一重要指标。在模组中,单体电池的功率状态劣势会被逐级放大,从而影响整体汽车驾驶时的动力体验^[24]。功率状态差是由于在经受相同的电流放电时,电池内阻越大,电池的端电压越低,相应的功率状态会更低。在电池的老化过程中,SOH 会逐渐降低且内阻会不断增加。高剩余容量、大内阻的退役 LFP 电池虽然能够提供较长时间的续航,但是它的库伦效率和功率状态一般较差。库伦效率低是由于充放电时能量被以热量的形式消散了。这也意味着大内阻电池在使用过程中容易过热从而引发安全事故。同时,当内阻老化程度严重高于 SOH 衰退程度,退役 LFP 电池经历过异常工况和故障的风险越高。因此,退役 LFP 电池内阻和 SOH 的匹配程度值得研究。

为了解决退役 LFP 电池初步分选耗时长的问题,本文提出了将脉冲过程中电压的频域特征作为估计 SOH 的 45 个 HF,具有获取耗时短且易获得的优点。然后,本文提取 280 节电池获取其在不同荷电状态(state of charge, SOC)下的 HF,利用随机森林回归(random forest regression, RFR)算法训练 SOH 估计模型。在此基础上,

本文提出利用基于高斯分布的异常参数识别方法评估异常内阻退役 LFP 电池,此方法可以筛除内阻与 SOH 不匹配的退役电芯,有助于完善退役 LFP 电池分选的评估体系。

本文贡献如下:提出了基于脉冲电压频域特征的退役 LFP 电池 SOH 快速估计策略,能够快速实现退役 LFP 电池的快速初步分选;基于高斯分布的异常参数识别方法提出了异常内阻退役 LFP 电池的筛选方案,能够有效评估退役 LFP 电池内阻与 SOH 的匹配程度。

1 特征提取

本文所提退役电池分选策略可以应用于退役 LFP 电池的初步分选,可以在很短的时间快速获得退役 LFP 电池的大致 SOH 和内阻状态。HF 会受到 SOC 的影响,但是测试时退役 LFP 电池的 SOC 是未知的。如图 1 所示,当 LFP 电池 SOC<5% 或>95% 时可以从 OCV 中判定电池大致 SOC。当电池 SOC 处于 5% 与 95% 之间时,由于 LFP 电池的 OCV 存在平坦区间导致无法通过 OCV 直接判定电池 SOC。




图1 磷酸铁锂电池 OCV 与 SOC 关系曲线

Fig. 1 Open circuit voltage vs. SOC curve for LiFePO4

如图 2 所示,文献[25]将 5%~95% SOC 分为 9 个 SOC 区间,然后提出从短时动态电压提取特征快速估计电池的大致 SOC 区间。当 LFP 电池真实 SOC 介于 5%~15% 时,本文利用文献[25]方案估计的 LFP 电池大致 SOC 为 10%。在获取退役 LFP 电池 SOC 的基础上,本文提出利用基于脉冲电压频域特征的退役 LFP 电池 SOH 快速估计策略和退役 LFP 电池异常内阻评估方案。在 LFP 电池受到电流脉冲时,电压的变化幅度会随着电池的老化而逐渐变大。在正向脉冲、静置、负向脉冲下,电池电压的变化趋势和速度不同,本节分别分析了 3 种过程中电压变化与电池老化的相关性。本文提出从脉冲电压中提取 HF,作为数据驱动 SOH 估计算法的输入。此外,为了全面评估退役 LFP 电池的老化状态,介绍了

用于评估退役 LFP 电池内阻老化程度与 SOH 匹配性的内阻获取方案以及原因。




图2 SOC 区间划分示意图

Fig. 2 Diagram of SOC interval division

由于退役 LFP 电池的测试是在离线状态下进行的,这意味着可以在保证安全的条件下对退役 LFP 电池施加任意形式的激励。在电池接近满电或者放空时,电池在被施加脉冲激励后容易经历过充或者过放,这会对电池内部造成损害。因此,本文的电流脉冲需要当退役 LFP 电池 SOC 介于 5%~95% 时施加。当 SOC<5% 时,应充电 10% 的额定容量,并静置 10 min 后施加脉冲过程。同理,当 SOC>95% 时,应放电 10% 的额定容量,并静置 10 min 后施加脉冲过程。

1.1 退役健康特征提取

本文提出对退役 LFP 电池施加电流激励获取 HF,然后结合 RFR 算法实现退役 LFP 电池 SOH 的快速估计。如图 3 所示,在正向脉冲施加的初始瞬间,电池的电压快速增加,这个过程被认为与电池材料、极耳、隔膜电阻以及各部件之间的连接方式有关。然后在正向脉冲施加的 30 s 内,电池电压缓慢增加,这个过程与电池内部的电子和离子运动时受到的阻力相关。如图 3 所示,当正向脉冲停止瞬间,电池电压由于电流的消失瞬间跌落。静置过程中的 30 s 内,电池内部离子和电子缓慢趋于稳定状态,电池电压缓慢降低。类似的,当电池被施加负向脉冲瞬间,电池的电压快速降低。此后,电池在负向脉冲的 30 s 内,电池的电压缓慢变化。

$$X(k) = \sum_{n=0}^{N-1} x(n) W_N^{kn}, k_f \in [0, N-1] \quad (1)$$

$$W_N = e^{-\frac{2\pi}{N}} \quad (2)$$

式中: $x(n)$ 为 N 点有限长序列,傅里叶变换用于分析时域信号中的频域成分,即从时域信号 $x(n)$ 得到频域信号 $X(k)$ 。本文时域信号 $x(n)$ 分别为图 3 中 30 s 脉冲充电、30 s 静置、30 s 脉冲放电 3 个过程的电压差信号。随着电池的老化,固体电解质膜逐渐增厚,正负极的活性物质不断被消耗,这会造成电荷活动时的阻力增加。在受到相同电流的激励下,电子和离子运动时受到的阻力增加在电池电压上显示出来的便是电池电压的变化幅度增大。本文将图 3 中动态电压进行傅里叶分解,分析动态电压在不同频率下的变化幅值,然后依赖动态电压频域幅值与 SOH 之间的关联性建立 SOH 估计模型。




图3 HF提取示意图

Fig. 3 Diagram of the health feature extraction

正向脉冲、静置过程以及负向脉冲过程中电池端电压与OCV差值进行傅里叶分解后的不同频率下的电压幅值如图4所示,随着频率的增加,其对应的电压分量不断降低。但由于0 Hz的电压幅值分量与电池端电压有关,0 Hz的电压幅值不适合作为估计退役LFP电池的HF。图3中电池在负向脉冲的30 s内电压偏离OCV幅度相比正向脉冲、静置阶段更大,这也使得图4中负向脉冲交流电压幅值 U_{FFT} 大于正向脉冲、静置阶段对应的 U_{FFT} 。由于静置阶段电池电压变化幅度最小,图4中静置电压的交流分量也最小。




图4 不同过程HF与频率关系

Fig. 4 Relationship between different process HF and frequency

本文将正向脉冲、静置、负向脉冲过程中的交流电压幅值分量 U_{FFT} 依次编号为 HF_{1-15} 、 HF_{16-30} 、 HF_{31-45} 。类似的,正向脉冲和静置阶段的HF随SOH变化,且负向脉冲HF随SOH变化十分明显。脉冲电压中提取的HF如图5所示,其中Num表示HF的编号。在经过30 s的正向脉冲后,电池内部的电子和离子的分布受到扰动。在将动态电压进行傅里叶分解后,本文能够分析不同频率下的HF随着电池的老龄化的趋势。充电和放电会导致电

极中电子和离子的分布不平衡,在施加相同的正向脉冲后,随着电池的老龄化,极化和去极化过程中的电压变化幅度增加,导致图5中 U_{FFT} 会随之增加。在扰动停止后,电池在没有外部驱动力的情况下通过缓慢的扩散过程来解决电子和离子分布不平衡。老龄化程度越高的电池在正向脉冲下电压变化幅度越大,导致扩散过程时电压恢复速度越快,图5中 U_{FFT} 越大。类似的,在30 s的负向脉冲后, U_{FFT} 随电池老龄化而增加。




图5 脉冲电压中提取的HF

Fig. 5 The HF selected in pulse voltage

因此,本文提出提取图3过程中脉冲充电、静置、脉冲放电过程中的频域信息,用于估计电池的SOH。正向脉冲、静置以及负向脉冲分别描述电池内部离子、电子应对不同扰动时的反应不同,这造成不同电压分量随SOH的变化不同。本文HF是通过90 s的脉冲过程获取的,具有易获得、快速的优势。但是,不同HF与电池SOH有不同程度的相关性。并且由于不同退役LFP电池历史工况不同,无法确保所有电池的HF满足SOH越低,相应的HF越大。这意味着如果仅仅依赖单一频率下的特征 HF_{1-45} 估计电池SOH会存在精度低的风险。这是本文利用多组参数共同估计电池的SOH的原因。

1.2 退役电池内阻获取

在退役LFP电池分选过程中,退役LFP电池异常内阻的评估十分有意义。对于同一节电池,电池的SOH会随着电池的老龄化逐渐降低,而内阻会随着电池的老龄化而逐渐增加。然而,导致不同的退役LFP电池容量和内阻衰变的原因并不相同。不合理的使用例如过放、过充、在高温、低温环境下使用会加速电池的老龄化。此外,部分电池退役的原因是由于例如撞击、泡水之类的安全事故。这些意外事故都会造成部分退役LFP电池的容量与内阻的衰退程度并不匹配,所以部分退役LFP电池具有高SOH、大内阻的特征。如果退役LFP电池剩余容量与内阻老化程度差异过大,这类电池在此前使用时可能经历过极端工况,存在潜在的安全风险。

常见的等效电路模型包括 Thevenin 模型、RC 模型、PNGV 模型和 Rint 模型。其中, Thevenin 模型由于其简单性和高精度而得到了广泛的应用。Thevenin 模型如图 6 所示, 由欧姆内阻 R_0 、极化电容 C 和极化电阻 R_1 组成。 R_0 与电池材料、极耳、隔膜电阻以及各部件之间的连接方式有关。 R_0 包含电池的接触电阻和导线电阻, 这使得 R_0 很容易受到不可控因素的影响。 R_1 是电池内部各种抑制电子和离子运动的阻碍因素引起的, 与 SOH 相关。在退役 LFP 电池分选时, 同样的电流被施加在电池两端时, 极化电阻的值是稳定的。所有电阻依然是从图 6 的脉冲过程中获得的, 脉冲过程只需 90 s, 包括充电 30 s、静止 30 s 和放电 30 s。欧姆电阻 R_{0c} 、 R_{0d} 以及极化电阻 R_{1c} 、 R_{1d} 的计算如下:

$$R_{0c} = \frac{V_1 - V_0}{I} \quad (3)$$

$$R_{1c} = \frac{V_2 - V_1}{I} \quad (4)$$

$$R_{0d} = \frac{V_4 - V_5}{I} \quad (5)$$

$$R_{1d} = \frac{V_5 - V_6}{I} \quad (6)$$




图 6 Thevenin 模型

Fig. 6 Thevenin model

Thevenin 模型只能提供内阻的值, 但是不能描述内阻的老化程度。现有的基于电阻老化程度评估方案中, 内阻与容量衰退程度的匹配性无法被直观的展现出来, 无法判定退役 LFP 电池内阻的增加是由于正常使用老化还是经历了异常工况。因此, 本文提出了退役 LFP 电池异常内阻评估方案。

2 退役电池快速分选方案

本文的 HF 和内阻从 90 s 的脉冲过程中获取, 这个过程易于实现, 能够有效节约退役 LFP 电池初步分选的时间和人力成本。离线状态下, 计算机能够提供充足的计算能力, 便于数据驱动算法的实现。退役 LFP 电池测试时 SOC 未知, 本文将 SOC 划分区间, 然后快速估计电

池大致 SOC。本文选取多节不同 SOH 电池, 然后提取多种 HF 作为训练集合共同训练 RFR 模型从而提高电池 SOH 估计精度。在获取退役 LFP 电池的 HF 以及内阻后, 本文介绍如何实现退役 LFP 电池 SOH 快速估计以及退役 LFP 电池异常内阻评估。

2.1 RFR 算法

RFR 是一种基于决策树的集成学习算法, 能够结合多个参数共同估计电池 SOH。在提取脉冲过程中 45 个 HF 后, 本文首先利用多节退役 LFP 电池的 SOH 和 HF 作为随机森林算法训练集 $\{HF_1, HF_2, \dots, HF_{45}, SOH\}$ 。在随机森林中, 每棵决策树随机选取一部分样本子集进行独立训练。在训练过程中, 利用训练集不断对决策树进行优化最终趋于收敛。然后, 随机森林通过将多个决策树的 SOH 预测结果进行平均或加权平均, 从而得到最终的 SOH 估计结果。RFR 算法的实现步骤如下。

1) 使用 Bagging 方法随机选择初始训练集。然后构造 k 个样本的子集。

2) 使用随机子空间方法, 从所有属性中随机选择一些特征, 并进行节点拆分, 构建单个回归决策树。

3) 重复步骤 1) 和 2) 以构建多元回归决策树, 并做出每棵树都生长到最大程度, 形成一片森林。

4) 将测试集 $\{HF_1, HF_2, \dots, HF_{45}\}$ 输入训练好的 RFR 模型后, 多个决策树分别输出对应的 SOH 估计值, 最终的预测结果是所有回归决策树的预测结果的平均值。

2.2 退役电池异常内阻评估

在完成退役 LFP 电池 SOH 的估计后, 如何判定内阻与容量衰退程度的匹配性成为下一个需要解决的问题。为了描述异常内阻现象, SOC = 90% 时, 295 节退役 LFP 电池欧姆内阻 R_{0d} 与 SOH 之间的关联性如图 7 所示, 圆形的退役 LFP 电池内阻明显超出正常电池范围, 可以通过内阻值被判定为异常电池。然而, 五角星标志的退役 LFP 电池虽然 SOH 接近 0.8, 但是其内阻却大于绝大部分 SOH 在 0.8 附近的退役 LFP 电池。但五角星标志的退役 LFP 电池内阻并未大幅超过正常电池, 依靠内阻值很难判断是否属于异常电池。图 7(b) 为 SOH = 80% ($\pm 3\%$) 时, 样本电池 R_{0d} 的分布。绝大多数电池集中在 0.005Ω 附近, 但是存在少量电池不同程度的大于大多数电池范围。此时, 判断内阻是否与 SOH 相匹配十分有意义。

基于高斯分布的异常值检测识别方法利用统计学原理分析数据点在数据集分布中的位置, 对于累积概率过高或过低的电池被判定为异常值。如图 7 所示, 由于绝大多数的电池都是在常规工况下运行后退役, 所以绝大多数 SOH 相同的退役 LFP 电池内阻趋于接近。但是有一小部分电池退役是由于经历了异常工况例如过充过




图7 退役电池异常内阻示意图

Fig. 7 Diagram for screening cells with abnormal internal resistance

放,这类电池内阻和SOH的衰退轨迹与大多数电池不同,这类电池内阻累积概率会接近1或者0。退役LFP电池经历的工况是随机的,所以退役LFP电池参数分布是随机的,可以被近似为高斯分布。基于以上分析,本文提出利用基于高斯分布的异常值识别方法评估电池内阻与SOH的匹配性。

在获得SOH和SOC的估计值后,统计SOH介于 $SOH-deta$ 与 $SOH+deta$ 之间的所有电池在对应SOC下的内阻参数,本文 $deta$ 值选取为3%。正态分布的期望值 μ 决定了高斯分布的位置,标准差 σ 决定了高斯分布的幅度。高斯分布具有以下特点:样本内阻 $x=\mu$ 发生的概率最高,样本内阻 x 越偏离 μ 事件发生的概率越低。当测试样本内阻 x 距离期望值 μ 越接近时,代表在此SOH下内阻 x 的常见程度越高,SOH与内阻的老化程度越匹配。

$$f(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (7)$$

累积分布函数是指随机变量 $X \leq x$ 的概率。累积概率能够描述测试样本内阻在对应退役电池SOH位置存在的概率。累积概率接近1或者0表示样本内阻严重偏离 μ ,代表样本电池内阻与SOH的匹配程度很低。

$$F(x; \mu, \sigma) = \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^x \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) dx \quad (8)$$

$$\mu = \frac{1}{m} \sum_{i=0}^m x^{(i)} \quad (9)$$

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m (x^{(i)} - \mu)(x^{(i)} - \mu)^T \quad (10)$$

式中: μ 代表样本的内阻平均值;标准差 σ 代表样本内阻的离散程度。

最后,计算选取测试样本内阻累积概率是否低于阈

值从而判定电池内阻是否异常。

本文的退役LFP电池快速分选方案如图8所示。




图8 退役电池快速分选流程

Fig. 8 Flow chart for rapid sorting of retired batteries

1) 当 $SOC < 5\%$ 时,应充电10%的额定容量,并静置10 min后施加脉冲过程。同理,当 $SOC > 95\%$ 时,应放电10%的额定容量,并静置10 min后施加脉冲过程。当SOC介于 $5\% \sim 95\%$ 时,直接对退役LFP电池施加短时间的脉冲,记录相应的电池电压变化。

2) 将脉冲过程中获取的SOC特征输入训练后支持向量机模型,获得电池的大致SOC区间。

3) 提取电池脉冲过程中不同频率下的HF,将其输入训练好的RFR模型中,获得退役LFP电池的大致SOH。

4) 在获得退役LFP电池的SOH后,利用高斯分布异常值检测算法识别电池内阻的老化程度。

5) 在电池SOH和内阻老化程度都完成评估后,按照指定需求对退役LFP电池进行分选。

3 实验与讨论

为了避免温度对实验结果的影响,本文测试过程环境温度维持在 $25^\circ\text{C} (\pm 2^\circ\text{C})$ 。如图9所示,本文所选取的电池为LFP电池,额定容量为30 Ah。为了验证本文提出方法的有效性,将选取的295节退役LFP电池,分为训练集合和测试集合两类。训练集合被用于训练SOC和SOH估计模型,测试集合被用于验证训练好的SOH模型是否能有效估计电池的SOH。

295节退役LFP电池HF数据集的获取方式如下。

1) 将未知状态下的退役LFP电池充满后,以 0.5 C



图9 电池测试平台

Fig. 9 Battery test and experiment platform

电流放电至截止电压下限。计算放电过程中电池所释放出来的电量作为电池的容量,再次将退役 LFP 电池充满。

2) 在获取电池的剩余容量后,以 0.5 C 电流将退役 LFP 电池释放 10% SOC,静置 10 min 后施加脉冲。

3) 重复步骤 2),直至电池 SOC = 10%。

4) 重复步骤 1),直至所有退役 LFP 电池特征提取结束。

随机选取 280 节退役 LFP 电池共 $9 \times 280 = 2520$ 组数据,作为本文的训练集合,剩余的 15 节退役 LFP 电池作为本文的测试集合。为了验证本文提出的退役 LFP 电池快速分选方案的有效性,本文分别从 HF 与 SOH 的相关性分析、SOH 快速估计和异常内阻电池评估三种角度展开论述。

3.1 相关性分析

实际上,本文提出的多种 HF 与电池 SOH 呈现出类似线性的关系。为了定量分析各种 FP 与 SOH 之间的相关性,本文分别计算了不同特性与 SOH 的相关系数 ρ (式(11))。静置阶段和正脉冲阶段 HF 与 SOH 的相关系数对电池 SOC 十分敏感,这是由于电池在不同 SOC 下电压的变化速度存在差异。而正脉冲阶段的 HF 随频率的增加呈现出先降低后增加的趋势。如图 10 所示,不同的 HF 与 SOH 的相关系数绝对值不同。脉冲过程中负脉冲阶段提取出的 HF 与 SOH 的相关性接近 0.9,这表明本文提出的 HF 与 SOH 有很强的相关性。实际上,退役 LFP 电池历史工况的差异导致不能保证所有 HF 都维持确定的相关性,所以本文采取 RFR 算法结合多种 HF 共同估计电池的 SOH。

$$\rho(XY) = \frac{n \sum xy - \sum x \sum y}{\sqrt{(n \sum x^2 - (\sum x)^2)(n \sum y^2 - (\sum y)^2)}} \quad (11)$$

式中: n 表示样本数量; x 和 y 分别表示 FP 和 SOH 的值。

3.2 电池 SOH 快速估计

本文利用 280 节退役 LFP 电池作为训练集,依次训




图10 不同 SOC 下 HF 与 SOH 相关性系数

Fig. 10 Correlation coefficients between HF and SOH at different SOC

练 9 个不同 SOC 区间下 RFR 模型。在判定退役 LFP 电池的大致 SOC 后,本文提取退役 LFP 电池 HF 输入训练好的 RFR 模型获取 SOH 估计值。

由于施加激励后电池两端的电压与电池 SOC 关系紧密,而本文仅仅能获取电池的大致 SOC 区间,这使得无法直接利用电池端电压作为电池 SOH 估计参数。电池的极化过程和弛豫过程被认为与电池的 SOH 有关^[26-28]。同时,在阻抗的频域分析中,有研究表明电化学阻抗与电池固体电解质界面膜的生长、电荷转移电阻的增加和扩散系数的增加相关^[29-30],这是造成电池在老化过程中其内电子和离子运动受到阻力逐渐增大的原因。退役 LFP 电池在不同 SOC 下的 HF 如图 11 所示,正向脉冲和静置阶段的 HF 受到 SOC 的影响较小,而负向脉冲明显受到 SOC 的影响,这是由于极化过程中不同 SOC 电池中离子和电子对外界扰动的反应速度存在差异。由图 11 可以看出, U_{FFT} 随着 SOH 的降低呈现增加趋势,验证了本文选取脉冲过程电压的频域幅值作为 HF 的正确性。但是, U_{FFT} 在不同 SOC 下的数值存在不同程度的差异,这验证了本文判定 SOC 大致区间的必要性。

1) 不同 SOC 下的 SOH 估计效果为了验证本文 SOH 估计方法的精度,总共选取 26 节退役 LFP 电池作为训练集。其中 15 节退役 LFP 电池在上文中已经提及,这些电池被完整充放电获取准确容量后,以 10% SOC 为间隔提取对应 SOC 下的 HF,然后利用训练好的 RFR 模型获取对应的 SOH。如图 12 所示,本文提出的 HF 能够估计多种 SOC 下的退役 LFP 电池大致 SOH。在 90 s 中,本文方法获取的退役 LFP 电池大致 SOH 可以作为判断此退役 LFP 电池二次利用的应用场景。例如,SOH 在 70% 以下的退役 LFP 电池可以被视为应拆解回收;SOH 在 70% ~ 80% 的退役 LFP 电池可以被应用于路灯、小型应急电源等场景;而 $SOH > 80\%$ 的电池可以被应用于储能、低速




图 11 不同 SOC 下 HF 示意图

Fig. 11 Diagram of HF at different SOC

电动车等复杂场景。对于拆解应用场景,SOH 的估计不需要获得准确值。

此外,为了验证本文方法在任意 SOC 下的 SOH 估计结果,本文另外选取了 11 节退役 LFP 电池采取以下过程随机放电后获取 HF。

(1) 将它们完整充放电两次获得准确的剩余容量,计算相应的 SOH。然后,将每节退役 LFP 电池充满后。

(2) 随机放电一定时间后静置 1 h,施加脉冲(图 3),重复 8 次。

在本文的 SOH 估计策略中,准确的 SOC 无法在 90 s 的时间内获得。本文采取的策略是先判断 SOC 的大致区间,然后利用对应 SOC 区间训练集训练 RFR 模型,最后将测量获得的 HF 输入训练好的 RFR 模型获取估计的 SOH 值。如表 1 所示,Cell₁₆ 的 SOH 估计误差最大为 6%。并且绝大多数情况下,电池 SOH 的估计误差在 3% 以内,这再次验证了本文提出的脉冲过程电压频域特征能够估计电池的 SOH。在判断退役 LFP 电池使用场景的初步分选中,由于本文提出的方法可以被应用于未知 SOC 退役 LFP 电池,本文方案能够节约大量的分选时间和人力成本。




图 12 不同 SOC 下的 SOH 快速估计结果

Fig. 12 Fast SOH estimation results at different SOC

表 1 随机 SOC 下的 SOH 快速估计结果

Table 1 Fast estimation results of SOH under random SOC

真实 SOH	状态	SOH 估计结果							
Cell ₁₆ -0.59	SOC	0.83	0.74	0.65	0.56	0.48	0.39	0.30	0.22
	估计 SOH	0.64	0.64	0.62	0.61	0.60	0.62	0.61	0.62
Cell ₁₇ -0.58	SOC	0.78	0.67	0.56	0.45	0.34	0.23	0.12	0.01
	估计 SOH	0.62	0.61	0.60	0.59	0.61	0.62	0.60	0.60
Cell ₁₈ -0.75	SOC	0.96	0.94	0.92	0.90	0.88	0.86	0.84	0.82
	估计 SOH	0.76	0.76	0.76	0.75	0.74	0.75	0.76	0.77
Cell ₁₉ -0.78	SOC	0.84	0.76	0.68	0.60	0.52	0.44	0.36	0.28
	估计 SOH	0.81	0.79	0.81	0.82	0.81	0.82	0.81	0.79
Cell ₂₀ -0.77	SOC	0.86	0.80	0.73	0.66	0.59	0.52	0.45	0.39
	估计 SOH	0.78	0.78	0.78	0.78	0.80	0.80	0.79	0.79
Cell ₂₁ -0.81	SOC	0.90	0.85	0.80	0.75	0.71	0.66	0.61	0.56
	估计 SOH	0.82	0.81	0.81	0.81	0.81	0.82	0.82	0.82
Cell ₂₂ -0.81	SOC	0.92	0.88	0.84	0.80	0.75	0.71	0.67	0.63
	估计 SOH	0.79	0.79	0.79	0.78	0.79	0.79	0.79	0.81
Cell ₂₃ -0.82	SOC	0.82	0.73	0.64	0.55	0.46	0.37	0.28	0.19
	估计 SOH	0.80	0.80	0.81	0.82	0.81	0.81	0.82	0.81
Cell ₂₄ -0.70	SOC	0.80	0.70	0.60	0.50	0.40	0.32	0.21	0.11
	估计 SOH	0.70	0.76	0.75	0.73	0.73	0.76	0.76	0.74
Cell ₂₅ -0.81	SOC	0.85	0.78	0.70	0.63	0.55	0.48	0.41	0.33
	估计 SOH	0.80	0.80	0.80	0.81	0.81	0.81	0.81	0.81
Cell ₂₆ -0.82	SOC	0.78	0.68	0.57	0.46	0.35	0.24	0.13	0.03
	估计 SOH	0.81	0.80	0.82	0.82	0.82	0.82	0.82	0.83

2) 不同回归算法 SOH 估计效果

为了验证 RFR 算法的优越性,本文利用 $SOC = 70\%$ 训练集数据训练 6 种不同的回归预测模型,并利用 15 节退役 LFP 电池验证 SOH 估计的准确性。如图 13 所示,这 6 种回归预测算法均能够实现 SOH 的大致估计。这验证了本文提出利用脉冲过程频域特性实现 SOH 大致估计的可行性。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SOH_{\text{real}} - SOH_{\text{estimate}})^2}{n}} \quad (12)$$

式中: SOH_{real} 指的是真实 SOH; SOH_{estimate} 指的是估计 SOH; n 指的是选取的电池数量。如表 2 所示,不同回归算法 SOH 估计的 RMSE 存在差别,其中效果最好的方法为 RFR,这验证了本文选取 RFR 算法作为 SOH 估计模型的优越性。

3.3 异常内阻退役电池评估

不同 SOC 和 SOH 下电池的内阻不同,因此异常内阻退役 LFP 电池的评估需要基于特定的 SOC 和 SOH。上




图 13 不同回归算法 SOH 估计结果

Fig. 13 SOH estimation results for different regression algorithms

文已经描述了退役 LFP 电池大致 SOC 和 SOH 的获取方法,本节介绍如何计算此退役 LFP 电池内阻在对应 SOH 和 SOC 下所处的位置。

表 2 不同回归算法 SOH 估计结果 RMSE

Table 2 RMSE of SOH estimation results for different regression algorithms

算法	长短期神经网络	卷积神经网络	遗传优化神经网络	支持向量机	神经网络	随机森林回归
误差	0.026 9	0.030 8	0.041 0	0.033 5	0.053 6	0.024 1

如图 14 所示,电池 R_o 和 R_i 都同时受到 SOC 和 SOH 的影响。如果在未知 SOC 和 SOH 的情况下,不同退役 LFP 电池之间的内阻对比将无法评估退役 LFP 电池的真实状态。当 SOC 一定时,电池内阻随 SOH 的降低而呈现增加趋势。类似的,内阻与 SOC 存在紧密的关联性。如图 14 所示,电池欧姆电阻和极化电阻都同时受到 SOC 和 SOH 的影响。如果在未知 SOC 和 SOH 的情况下,不同退役 LFP 电池之间的内阻对比将无法评估退役 LFP 电池的真实状态。当 SOC 一定时,内阻随 SOH 的降低而呈现增加趋势。但 SOH 低并不代表内阻一定大;反之,SOH 高不代表内阻一定小。这是由于不同电池经历的历史工况不同造成的。

本文选取 6 节退役 LFP 电池验证本文提出的异常内阻电池的有效性,对应 SOH 和 SOC 如表 3 所示,其中 Cell₂₀ 和 Cell₂₁ 的欧姆内阻远大于正常电池。





图 14 电池内阻与 SOH、SOC 关系

Fig. 14 Battery internal resistance versus SOH and SOC

6 节退役 LFP 电池内阻的异常程度评估按如下步骤进行:

- (1) 在获得 SOH 和 SOC 的估计值后,统计 SOH 介于 $SOH-3\%$ 与 $SOH+3\%$ 之间的所有电池在对应 SOC 下的内阻参数。
- (2) 分别计算 4 种内阻参数的均值以及方差。
- (3) 分别计算 6 节电池内阻分布的累积概率(表 4)。
- (4) 依据计算的累积概率值判断内阻的异常程度。

表 3 中,Cell₁₉ 和 Cell₂₀ 的真实和估计 SOH 接近; Cell₂₁、Cell₂₂ 以及 Cell₂₃ 真实和估计 SOH 接近;Cell₂₄ 的 SOH 明显低于其他电池。表 3 仅仅能看出 Cell₂₀ 和 Cell₂₁ 的欧姆内阻 R_{oc} 和 R_{od} 较大,但不能看出是否超出了正常范围。而表 4 中相应电阻的累积概率为 99.99%。这表明当 SOH 处于 77% ($80\% - 3\% = 77\%$) 与 83%

表 3 不同退役 LFP 电池内阻和对应 SOH、SOC

Table 3 Internal resistance and corresponding SOH and SOC of different retired LFP batteries

状态	真实 SOH	估计 SOH	SOC	R_{0c}/Ω	R_{0d}/Ω	R_{1c}/Ω	R_{1d}/Ω
Cell ₁₉	0.78	0.81	0.68	0.004 18	0.005 01	0.002 510	0.004 71
Cell ₂₀	0.77	0.8	0.52	0.007 64	0.008 63	0.002 780	0.005 06
Cell ₂₁	0.81	0.82	0.56	0.010 84	0.011 10	0.001 830	0.004 79
Cell ₂₂	0.81	0.79	0.67	0.004 50	0.005 37	0.002 650	0.005 16
Cell ₂₃	0.82	0.81	0.46	0.003 66	0.003 875	0.002 295	0.002 39
Cell ₂₄	0.70	0.73	0.4	0.005 33	0.006 09	0.002 775	0.004 51

表 4 不同退役 LFP 电池内阻累积概率

Table 4 Probability of accumulation of internal resistance of different retired LFP batteries

累积概率	R_{0c}	R_{0d}	R_{1c}	R_{1d}
Cell ₁₉	0.655 2	0.713 1	0.833 9	0.984 9
Cell ₂₀	0.999 9	0.999 9	0.975 6	0.811 9
Cell ₂₁	0.999 9	0.999 9	0.001 9	0.888 6
Cell ₂₂	0.669 3	0.720 5	0.924 5	0.961 1
Cell ₂₃	0.396 8	0.200 4	0.190 1	0.173 6
Cell ₂₄	0.854 2	0.891 6	0.513 8	0.200 1

(80%+3%=83%)之间时,仅有0.01%的电池内阻大于此值。

在测量正确的情况下,大电阻高SOH的电池可能经历过极端使用场景如碰撞、过充、过放等。这表明此电池内阻检测出现异常或电池存在故障,需要再次确认。从表3可以看到,Cell₂₃和Cell₂₄的极化电阻 R_{1d} 值相差很大,但是无法从表3中判断Cell₂₃和Cell₂₄极化电阻 R_{1d} 是否处于正常区间。从表4可以看出,在SOC和SOH的退役LFP电池中,相比大多数对应SOC和SOH的退役LFP电池,Cell₂₃和Cell₂₄的极化电阻 R_{1d} 均较小。表3中,Cell₁₉和Cell₂₄的极化电阻 R_{1d} 接近。而从表4可以看出,Cell₁₉的极化内阻 R_{1d} 大于98.49%的SOH在78%(81%-3%=78%)与84%(81%+3%=84%)之间、SOC=70%下的退役LFP电池。

在退役LFP电池二次利用时,考虑到生产成本的原因,退役LFP电池应该按内阻值的大小以及常见程度进行分选。当退役LFP电池内阻累积概率越大,表明此退役LFP电池在对应SOC和SOH退役LFP电池中内阻值越大。当退役LFP电池内阻累积概率接近50%,表明此退役LFP电池与大多数对应SOC和SOH的退役LFP电池内阻值接近。当此退役LFP电池内阻累积概率接近100%时,退役LFP电池内阻远大于绝大多数相同SOH退役LFP电池,此类电池可能经历过异常工况或者测量

失误,可以再见检测判断是否视为异常电芯。当此退役LFP电池内阻累积概率接近0%时,此退役LFP电池内阻远小于绝大多数相同SOH退役LFP电池时,可以被视为对应SOH下的小内阻电芯。这验证了本文提出的异常电阻识别方案能够筛选内阻与SOH不匹配的退役LFP电池。

4 结 论

针对退役电池分选时的耗时问题,本文提出了基于脉冲电压频域特征的退役电池SOH快速估计策略,能够实现退役LFP电池的快速初步分选的耗时问题。本文分析了脉冲电压频域幅值与电池SOH的相关性,然后提出利用随机森林算法结合多种特征实现了退役LFP电池SOH的快速估计。并在此基础上,提出利用基于高斯分布的异常参数识别方法评估异常内阻退役LFP电池,此方法可以筛除内阻与SOH不匹配的退役LFP电池,有助于完善退役LFP电池分选的评估体系。本文的SOH估计方案能估计退役LFP电池的大致SOH,为退役LFP电池二次利用场合的判定提供依据。因此,进一步的提供退役LFP电池故障诊断以及寿命估计是未来的研究方向。

参考文献

[1] 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.
[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] XIN L, HUANG Y F, GU H H, et al. Turning waste into wealth: A systematic review on echelon utilization and material recycling of retired lithium-ion batteries[J]. Energy Storage Materials, 2021, 40: 96-123.
- [4] 马速良, 李建林, 李雅欣, 等. 面向电池梯次利用筛选需求的定制化聚类优化方法[J]. 中国电机工程学报, 2022, 42(17): 6208-6220.
- MA S L, LI J L, LI Y X, et al. Customized clustering optimization method for battery reutilization screening requirements [J]. Proceedings of the CSEE, 2022, 42 (17): 6208-6220.
- [5] 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.
- [6] STREB M, ANDERSSON M, KLASS V L, et al. Investigating re-parametrization of electrochemical model-based battery management using real-world driving data[J]. eTransportation, 2023, 16(3): 100231.
- [7] 印学浩, 宋宇晨, 刘旺, 等. 基于多时间尺度的锂离子电池状态联合估计[J]. 仪器仪表学报, 2018, 39(8): 118-126.
- YIN X H, SONG Y CH, LIU W, et al. Multi-scale state joint estimation for lithium-ion battery [J]. Chinese Journal of Scientific Instrument, 2018, 39 (8): 118-126.
- [8] QIAO J L, WANG SH L, YU CH M, et al. A chaotic firefly-particle filtering method of dynamic migration modeling for the state-of-charge and state-of-health co-estimation of a lithium-ion battery performance [J]. Energy, 2023, DOI:10.1016/j.energy.2022.126164.
- [9] BI Y L, YIN Y L, CHOE S Y. Online state of health and aging parameter estimation using a physics-based life model with a particle filter [J]. Journal of Power Sources, 2020, DOI: 10.1016/j.jpowsour.2020.228655.
- [10] XIE Y X, WANG SH L, ZHANG G X, et al. Optimized multi-hidden layer long short-term memory modeling and suboptimal fading extended Kalman filtering strategies for the synthetic state of charge estimation of lithium-ion batteries[J]. Applied Energy, 2023, 336(6): 120866.
- [11] MUSSI M, LUIGI P, MARCELLO R, et al. An online state of health estimation method for lithium-ion batteries based on time partitioning and data-driven model identification [J]. Journal of Energy Storage, 2022, 55(8): 105467.
- [12] KHALEGHI S, MD S H, DANIAL K, et al. Developing an online data-driven approach for prognostics and health management of lithium-ion batteries [J]. Applied Energy, 2022, 308(4): 118348.
- [13] XIE Y X, WANG SH L, ZHANG G X, et al. Optimized multi-hidden layer long short-term memory modeling and suboptimal fading extended Kalman filtering strategies for the synthetic state of charge estimation of lithium-ion batteries[J]. Applied Energy, 2023, 336(6): 120866.
- [14] MA L L, XU Y H, ZHANG H G, 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(1): 104904.
- [15] QIU X H, WU W X, WANG SH F. Remaining useful life prediction of lithium-ion battery based on improved cuckoo search particle filter and a novel state of charge estimation method[J]. Journal of Power Sources, 2020, DOI:10.1016/j.jpowsour.2020.227700.
- [16] PU R, WANG SH L, HUANG J H, et al. Novel co-estimation strategy based on forgetting factor dual particle filter algorithm for the state of charge and state of health of the lithium-ion battery [J]. International Journal of Energy Research, 2021, 46(2): 1094-107.
- [17] 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, 257(1): 124771.
- [18] PAN W J, CHEN Q, ZHU M T, et al. A data-driven fuzzy information granulation approach for battery state of health forecasting[J]. Journal of Power Sources, 2020, DOI:10.1016/j.jpowsour.2020.228716.
- [19] JIANG B, ZHU J G, WANG X Y, et al. A comparative study of different features extracted from electrochemical impedance spectroscopy in state of health estimation for lithium-ion batteries [J]. Applied Energy, 2022, 322(4): 119502.
- [20] GALEOTTI M, CINÀ L, GIAMMANCO C, et al. Performance analysis and SOH (state of health) evaluation of lithium polymer batteries through electrochemical impedance spectroscopy [J]. Energy, 2015, 89: 678-686.
- [21] WU M, WANG L, WU J. State of health estimation of the LiFePO₄ power battery based on the forgetting factor recursive Total Least Squares and the temperature correction[J]. Energy, 2023, 282(44): 128437.

- [22] 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, 51(4):104560.
- [23] CHEN J, HU Y, ZHU Q, et al. A novel battery health indicator and PSO-LSSVR for LiFePO₄ battery SOH estimation during constant current charging[J]. *Energy*, 2023, 282(2):128782.
- [24] RAMIREZ-MEYERS K, RAWN B, WHITACRE J F. A statistical assessment of the state-of-health of LiFePO₄ cells harvested from a hybrid-electric vehicle battery pack[J]. *Journal of Energy Storage*, 2023, 59:106472.
- [25] 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, 55(4):105621.
- [26] BAGHDADI I, BRIAT O, GYAN P, et al. State of health assessment for lithium batteries based on voltage-time relaxation measure[J]. *Electrochimica Acta*, 2016, 194: 461-472.
- [27] 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.
- [28] STEFAN S, BAUER M, PETZL M, et al. Voltage relaxation and impedance spectroscopy as in-operando methods for the detection of lithium plating on graphitic anodes in commercial lithium-ion cells [J]. *Journal of Power Sources*, 2016, 304: 170-180.
- [29] JOSUE O, HAN Y R, Chang W H, et al. Convolutional autoencoder-based SOH estimation of lithium-ion batteries using electrochemical impedance spectroscopy [J].

Journal of Energy Storage, 2023, 60:106680.

- [30] CHANG C, WANG S J, TAO C, et al. An improvement of equivalent circuit model for state of health estimation of lithium-ion batteries based on mid-frequency and low-frequency electrochemical impedance spectroscopy [J]. *Measurement*, 2022, 202(5):111795.

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.

Now he is a Ph.D. candidate at Hefei University of Technology. His main research interests are fast state assessment of retired batteries.



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, 2011 年于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 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 main research interests include power electronics and automation.