

DOI: 10.3901/JME.2022.17.096

# 基于递推最小二乘法的锂电池内短路 全寿命周期辨识\*

何 晋 马睿飞 蔡琦琳 范学良 赵威风 邓业林  
(苏州大学轨道交通学院 苏州 215131)

**摘要:** 锂电池内短路发展到后期阶段会引发热失控造成严重安全问题,因此必须在前中期识别内短路。当前检测内短路的常见方式是利用同一电池组内电芯间电压等参数的一致性,通过比较成组电芯间性能差异,筛选出异常电芯。然而对于退役电池等已经老化的电池组,其成组结构很可能已被打乱,且电芯间本已存在性能分化,无法使用该方法。为此,锂电池极化内阻被选作独立识别电芯内短路的标志性参数,而带遗忘因子的递推最小二乘法被用于在线辨识内短路前后极化内阻变化以在全寿命周期内识别内短路。针对电池老化影响辨识结果精度的问题,首先通过选择合适的遗忘因子与采样频率来优化该算法以适应老化对模型的影响。然后利用优化后的算法进行电池表面温度仿真模拟,进一步验证该算法的精度。最后设计内短路实验,验证该算法识别内短路的能力。结果表明,当遗忘因子为0.95,数据采样间隔为1s时,该算法适应老化的能力最强,利用其进行电池表面温度估计的误差在2%以内。在内短路发展到后期阶段前,电池健康状态(SOH)为80%的电池极化内阻均值增加达到45%及以上,可以有效地识别内短路。

**关键词:** 内短路; 全寿命周期; 参数辨识; 最小二乘法; 温度估计

**中图分类号:** TM912

## Life Cycle Identification of Internal Short Circuits of Lithium-ion Battery Based on Recursive Least Square Method

HE Jin MA Ruifei CAI Qilin FAN Xueliang ZHAO Weifeng DENG Yelin  
(School of Rail Transportation, Soochow University, Suzhou 215131)

**Abstract:** Internal short circuits(ISCs) of Li-ion batteries in the later stages can lead to thermal runaway and cause serious safety problems, so it is important to identify ISCs in the early or middle stage. The common way to detect ISCs is to use the consistency of voltage and other parameters between cells in the same battery pack, and abnormal cells are screened out by comparing performance of cells within a battery pack. However, for battery packs that have been aged, such as retired batteries, the pack structure is likely to be disrupted. Moreover, there is already a performance differentiation between the cells. So This method is not suitable for ageing batteries. Therefore, the polarization resistance is chosen as an independent landmark parameter for identifying ISCs in the cells, while recursive least squares with a forgetting factor is used to identify polarization resistance online to identify ISCs in the whole life cycle. To address the problem that battery ageing affects the accuracy of the identification results, the algorithm is first optimised to suit the effects of ageing on the model by selecting an appropriate forgetting factor and sampling frequency. The optimised algorithm is then used to simulate the surface temperature of the cells to further verify the accuracy of the algorithm. Finally, an ISC experiment is designed to verify the ability of the algorithm to identify ISC. The results show that when the forgetting factor is 0.95 and the data sampling interval is 1s, the algorithm has the strongest ability to adapt to aging. And that the error in battery surface temperature estimation is within 2%. The mean increase in polarization resistance for state of health(SOH) of 80% reaches 45% and above before

\* 国家自然科学基金(51905361)、中国博士后科学基金(2021M702391)和江苏省博士后科学基金(2021K358C)资助项目。20210719 收到初稿, 20220105 收到修改稿

the ISC develops to a later stage, indicating that it can effectively identify ISC.

**Key words:** internal short circuit; life cycle; parameter identification; least square method; temperature prediction

## 0 前言

近年来, 电池技术与电池管理系统地发展促进了锂电池在电动汽车、智能电网等领域广泛应用。然而锂电池热失控事故却频频发生, 严重制约了锂电池相关行业发展<sup>[1]</sup>。多位学者<sup>[2-3]</sup>指出热失控的主要诱因之一是电池正负极隔膜损伤引起内短路(Internal short circuit, ISC)。北京丰台区造成 2 名消防员死亡的“4.16”储能电站安全事故的分析报告中也认定电芯内短路是该事故核心原因。因此, 必须发展全生命周期内对电芯内短路监控的有效方法。

为了方便对内短路进行监测, 等效内短路电阻(ISC equivalent resistance,  $R_{isc}$ )被引入以反应内短路严重程度。电池正常工作时,  $R_{isc}$  相当大, 内短路电流极小可忽略<sup>[4]</sup>。而当电池发生内短路时,  $R_{isc}$  会随着内短路加剧而减小。当  $R_{isc} < 0.1 \Omega$  时, 内短路处于后期阶段, 此时电池端电压明显下降, 内短路可被快速准确地识别, 但电池温度会急剧上升, 预留安全时间极短, 易造成热失控, 因此必须在此之前识别内短路。然而前中期内短路具有很强的隐蔽性, 电压、温度等特性参数变化小较难识别。

当前常见的内短路检测手段是通过比较同一组串电芯间电压等参数的相对差异来判定内短路是否发生<sup>[5]</sup>。由于此方法依赖于参数一致性, 故常用于对出厂参数相同的新电池组进行内短路检测。而一些老化电池如退役电池, 其成组结构往往已被拆解打散, 难以找到一致性比较的参考对象; 此外, 与新电池不同, 出厂参数相同的老化电池也可能会有较为明显的性能分化<sup>[6]</sup>。因此亟需寻找一个具有高灵敏度且可以独立识别电池内短路的参数。冯旭宁等<sup>[7]</sup>利用热电耦合的电化学仿真模型对内短路进行探究, 发现当内短路发生时, 电池的极化内阻有明显地增加, 但该研究主要针对新电池且并没有对其进行现场实验验证。NEOLLE 等<sup>[8]</sup>指出极化内阻可以反映电池的动态特性, 当内短路时锂离子迅速嵌入电极材料, 造成电解液锂离子的浓度骤降, 极大的影响其动态特性, 从而引发极化内阻改变。

基于当前文献分析, 本研究拟将极化内阻视为检测内短路的指标, 通过参数辨识的方法判断其识

别不同老化状态电池内短路的能力, 并利用内短路实验加以验证。已有较多的研究探讨如何获取电池的内阻等参数, 如李伟等<sup>[9]</sup>采用混合脉冲功率特性测试(Hybrid pulse power characteristic, HPPC)所得电流与电压, 结合电池模型, 利用曲线拟合的方法辨识出内阻等参数值。何洪文等<sup>[10]</sup>利用带遗忘因子的递推最小二乘法(Forgetting factor recursive least square, FFRLS)进行在线参数辨识与建模, 并基于辨识的参数, 在动态工况下对动力电池荷电状态(State of charge, SOC)估计。这些参数辨识工作都卓有成效, 得到了精度高、误差小的结果。但目前研究集中在对新电池的辨识, 而电池在使用过程中会不可避免地发生老化, 有研究指出, 辨识结果会随着电池老化发生偏移, 导致算法精度下降<sup>[11-12]</sup>。因此, 还需进一步研究在电芯老化进程中对内阻参数辨识方法的优化, 实现全寿命周期内的可靠性。

为实现电池安全管理, 有效监测内短路, 该研究将首先建立合适的电池模型, 并在此基础上利用 FFRLS 算法对电池进行全寿命周期的参数辨识, 并探究不同遗忘因子与采样频率对于老化电池辨识的适应度以优化算法。在此基础上, 考虑到温度与电阻之间的紧密关系, 利用在线辨识的参数对电池表面温度进行估计, 进一步检验算法的可行性。最后, 对不同老化状态电池进行内短路实验, 并探究在线辨识极化内阻的方法识别内短路的能力。

## 1 电池模型与参数辨识

### 1.1 等效电路模型

常见的动力电池模型有等效电路模型、电化学模型与数据驱动模型等<sup>[13-15]</sup>。考虑到实际, 应在满足精度条件下尽可能简化电池模型, 故选用等效电路模型中的 Thevenin 模型对电池进行建模<sup>[16]</sup>, 如图 1 所示, 可以表示为

$$\begin{cases} \dot{U}_p = \frac{I_L}{C_p} - \frac{U_p}{R_p C_p} \\ U_t = U_{oc} - U_p - I_L R_0 \end{cases} \quad (1)$$

式中,  $U_{oc}$ ,  $U_t$  与  $U_p$  表示电池开路电压, 端电压与极化电压,  $R_0$ ,  $R_p$  与  $C_p$  分别为电池欧姆内阻, 极化内阻与极化电容,  $I_L$  表示电流的大小与方向。




图 1 Thevenin 模型

将式(1)进行拉普拉斯变换与双线性变化<sup>[10]</sup>, 可以把连续方程式(1)转化为离散方程式(2)

$$U_{t,k} = (1 - a_1)U_{oc,k} + a_1U_{t,k-1} + a_2I_{L,k} + a_3I_{L,k-1} \quad (2)$$

式中,  $a_1 = -\frac{T - 2R_p C_p}{T + 2R_p C_p}$ ,  $a_2 = -\frac{R_0 T + R_p T + 2R_0 R_p C_p}{T + 2R_p C_p}$ ,

$a_3 = -\frac{R_0 T + R_p T - 2R_0 R_p C_p}{T + 2R_p C_p}$ 。T 为采样间隔时间,

下角标 k 表示采样时刻。故可以定义

$$\begin{cases} y_k = U_{t,k} \\ \phi_k = [1 \ U_{t,k-1} \ I_{L,k} \ I_{L,k-1}] \\ \theta_k = [U_{oc,k} - a_1 U_{oc,k} \ a_1 \ a_2 \ a_3] \end{cases} \quad (3)$$

## 1.2 模型参数辨识

模型参数辨识是通过系统中已知的信息来推算未知参数。Thevenin 模型中  $R_0$ ,  $R_p$ ,  $C_p$  等参数不可直接测量, 需要通过可对直接测量的电流与电压等数据进行参数辨识来获取。

HPPC 测试工况采用连续的脉冲信号对锂电池进行充放电, 体现其不同荷电状态下的充放电特征, 其脉冲电压曲线常被用于模型参数辨识。SOC 为 50% 时, 脉冲电压曲线如图 2 所示。




图 2 HPPC 工况电压

图 2 中, AB 与 CD 阶段瞬间的电压变化是由欧姆内阻产生的, 所以等效电路中的  $R_0$  可以通过  $(U_A - U_B)/I_L$  或  $(U_C - U_D)/I_L$  来计算。DE 阶段为零输入响应, 可利用 Matlab 的 cftool 工具箱进行参数拟合得到电池的极化电阻  $R_p$ , 极化电容  $C_p$  等参数, 拟合函数如式(4)所示

$$U_t = U_{oc} - U_p = U_{oc} - I_L R_p \times \exp(-t / R_p C_p) \quad (4)$$

对于动态工况, 如城市道路循环工况(Urban dynamometer driving schedule, UDDS)与动态应力工况测试(Dynamic stress test, DST)等<sup>[17]</sup>, 进行参数辨识时常采用递推最小二乘法, 其易于快速收敛, 但存在参数饱和现象。一些学者<sup>[18-19]</sup>通过引入遗忘因子提出了 FFRLS 算法, 其基本计算方程如下

$$y_k = \phi_k \theta_k^T + e_{Ls,k} \quad (5)$$

式中,  $e_{Ls,k}$  为平稳零均值白噪声,  $y_k$ ,  $\phi_k$  与  $\theta_k$  为系统输出变量, 数据变量与参数变量。算法流程如下

$$K_{Ls,k} = P_{Ls,k-1} \phi_k^T [\phi_k P_{Ls,k-1} \phi_k^T + \mu]^{-1} \quad (6)$$

$$P_{Ls,k} = \mu^{-1} [I - K_{Ls,k} \phi_k] P_{Ls,k-1} \quad (7)$$

$$\theta_k = \theta_{k-1} + K_{Ls,k} [y_k - \phi_k \theta_{k-1}] \quad (8)$$

式中,  $\mu$  为遗忘因子, 取值范围为 0.95~1, 当  $\mu=1$  时, 退化为传统的递推最小二乘法。 $K_{Ls,k}$  为算法的增益;  $P_{Ls,k}$  为状态估计值的误差协方差矩阵,  $I$  为单位矩阵。基于 FFRLS 算法的在线参数辨识方法的结构示意图如图 3 所示。

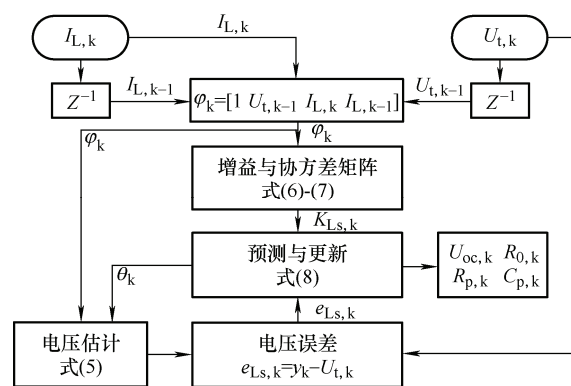


图 3 基于 FFRLS 的在线辨识算法

## 1.3 电池热模型

电池产热主要由焦耳热、极化热、反应热与副反应热组成<sup>[20]</sup>。由于副反应热对温度的影响可忽略不计, 故只考虑前三者。焦耳热是欧姆内阻产生的热量, 极化热是电极电位偏离平衡电位所产生的热量, 分别可以通过间接测定欧姆内阻  $R_0$  与极化内阻  $R_p$  来计算。反应热是电池在充放电过程中, 锂离子嵌入和脱出电极时发生化学反应所产生的热量。

$$q = q_0 + q_p + q_r = I_L^2 R_0 + I_L^2 R_p + I_L T_b \frac{dU_{oc}}{dT} \quad (9)$$

式中,  $q$ ,  $q_0$ ,  $q_p$  与  $q_r$  分别为电池在单位时间内产生的总热量, 焦耳热与极化热与反应热, 单位均为 W;

$T_b$  为电池表面温度, 单位为 K;  $dU_{oc}/dT$  为熵热系数, 单位为 V/K, 可通过文献[21]中的实验获得, 图 4 为  $dU_{oc}/dT$  与 SOC 的关系。




图 4 熵热系数与 SOC 的关系

至于 SOC, 可以通过安时积分法<sup>[22]</sup>计算。

$$SOC_t = SOC_0 - \frac{1}{3600} \times \int_0^t I_L dt \quad (10)$$

式中,  $SOC_0$  为初始 SOC 值,  $SOC_t$  为  $t$  时刻 SOC 值。

电池与环境之间的热交换主要是热传导和热对流。根据热力学定律, 可得到热平衡方程式。

$$qT - hA(T_b - T_a) = cm(T_b - T_0) \quad (11)$$

式中,  $h$  为电池与周围环境之间的换热系数,  $h$  约为  $25 \text{ W}/(\text{m}^2 \cdot \text{K})$ ;  $A$  为电池侧表面积, 单位为  $\text{m}^2$ ;  $c$  为电池比热容, 约为  $1000 \text{ J}/(\text{kg} \cdot \text{K})$ ;  $m$  为电池质量, 单位为  $\text{kg}$ ;  $T_a$  与  $T_0$  分别为环境温度和电池表面初始温度, 单位为 K。通过将式(9)与式(11)联立即可求出电池表面温度  $T_b$ 。综上所述, 本文探究了基于递推最小二乘法的锂电池内短路全寿命周期辨识方法, 流程如图 5 所示。

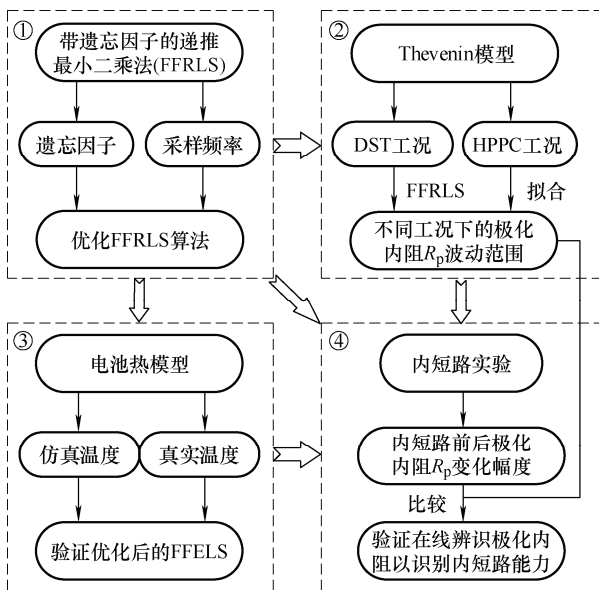


图 5 基于 FFRLS 的锂电池内短路全寿命周期辨识流程图

## 2 实验与结果

### 2.1 实验设置

锂电池性能测试选用武汉蓝电电池测试系统 CT6001A, 该测试平台的最大输出电流与电压分别为 30 A 和 5 V, 精度均为  $\pm [0.05\% \text{RD}(\text{读数}) + 0.05\% \text{FS}(\text{满度})]$ 。实验时, 每一秒记录一次数据, 并保持环境温度为  $25^\circ\text{C}$ 。电池选用“三星 18650 20R”锂离子电池, 其形状为圆柱形, 直径 18 mm, 高 65 mm, 质量 45 mg, 标称容量为 2 Ah, 电池的充电截止电压为 4.2 V, 放电截止电压为 2.5 V。

为对锂电池在全寿命周期内进行研究, 对 4 节相同的“三星 18650 20R”电池以 3 A 充电, 21 A 放电, 分别循环不同次数, 使其达到不同的老化状态, 其按照循环次数由少到多依次标记为  $B_1$ ,  $B_2$ ,  $B_3$  与  $B_4$ 。

对不同老化状态的电池进行最大可用容量测试。将电池以恒流恒压方式充满电, 静置一段时间后再以 1.5 A 放电至截止电压, 电池电压和容量的变化曲线如图 6 所示。重复以上步骤三次求放电容量均值, 若均值与测量值误差在 2% 以内, 则视该均





图 6 电池电压与容量变化曲线

值为最大可用容量。由图 6 可知,随着电池老化程度的增加,电池平台电压不断降低,放电时间不断缩减,电池最大可用放电容量不断减小。

电池健康状态(State of health, SOH)是电池从满充状态以一定的倍率放电至截止电压所放出的容量与其标称容量的比值,该比值反应了电池寿命状态。不同老化电池的最大可用容量与 SOH 如表 1 所示。

表 1 电池状态

电池	最大可用容量/(Ah)	SOH
B <sub>1</sub>	2.02	100%
B <sub>2</sub>	1.92	96%
B <sub>3</sub>	1.83	92%
B <sub>4</sub>	1.60	80%

## 2.2 HPPC 与 DST 实验

对不同老化状态电池进行 HPPC 测试。将电池以恒流恒压方式充满电后静置一段时间。以 1.5A 电流放电后静置,每当放电量为 10%SOC 时,加载如图 7a 所示电流工况,循环放电至截止电压。同样地,进行动态工况测试,本研究选用 DST 工况。将电池以恒流恒压方式充满电后静置一段时间,再加载如图 7b 所示的 DST 工况循环充放电至截止电压。图

7c~f 显示了 HPPC 与 DST 工况下欧姆和极化内阻辨识结果,对 DST 工况利用 FFRLS 算法进行辨识时,遗忘因子  $\mu=0.95$ ,时间间隔为 1 s,且 DST 工况与 HPPC 工况的平均电流相同,均为 1.5A。

由图 7c、7e 可看出,不同工况下欧姆内阻  $R_0$  的变化趋势相似。相同 SOH 情况下,当 SOC 处于 40%~100%时,  $R_0$  变化极小;当 SOC 低于 40%时,  $R_0$  急剧增加。另一方面,当 SOC 相同时,随着电池老化加深,电池的欧姆内阻增大。由此可见, SOC 与老化是影响电池欧姆内阻的主要因素,当电池处于放电末端或寿命末期时,由于电池内部活性物质,如电解液浓度以及电池温度等变化,欧姆内阻迅速增大。

由图 7d、7f 可看出,不同工况下极化内阻  $R_p$  的变化趋势也相似。当 SOH 相同时,相较于欧姆内阻,极化内阻的变化更为明显且活跃。以图 6c 和 6d 中 HPPC 工况下,各 SOC 下所辨识内阻与其均值之间波动范围为例,欧姆内阻的平均波动为 5%,而极化内阻为 16%。由此可见,当电池的电压、电流等内外在因素发生变化时,相较于欧姆内阻,极化内阻可以更为显著的反应变化,因此可以选择极化内阻作为识别电池内短路的标志量。

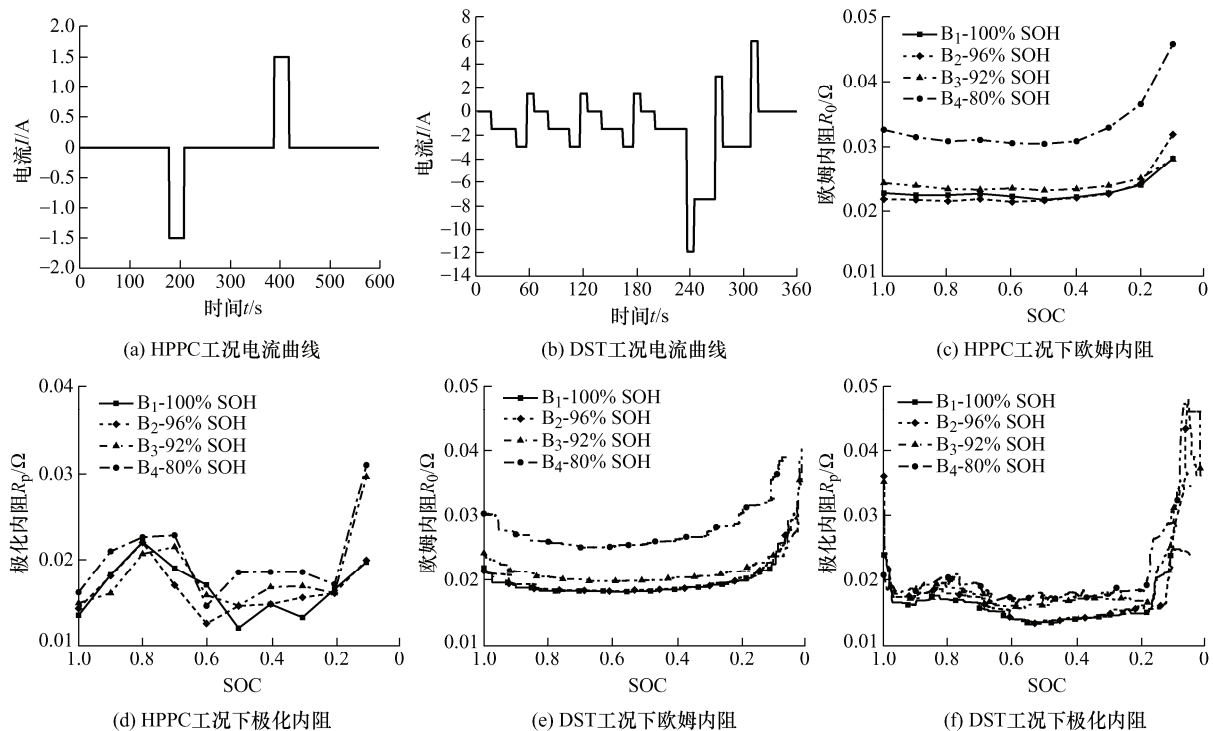


图 7 HPPC 与 DST 工况及辨识结果

## 2.3 内短路实验

为验证提出的模型与参数辨识算法识别内短路的能力,设计内短路实验加以验证。考虑到针刺、

挤压等内短路实验会对电池造成不可逆损失,故采用内短路替代实验。本文选择可控的外短路实验来代替内短路,其操作简单,易于实现,实验电路如



图 8 所示<sup>[23]</sup>。该方法通过将特定电阻与电池并联来模拟内短路, 该特定电阻被视为等效内短路电阻  $R_{isc}$ , 且可以利用开关  $S$  来用控制内短路的开停。




图 8 内短路替代实验

以图 8 方式连接电路, 对不同老化程度的电池加载 DST 工况从 4 V 开始放电, 共进行 3 个 DST 工况循环(1 080 s), 当第二个 DST 循环结束时(720 s)闭合开关  $S$  触发内短路, 分别设置内短路等效电阻  $R_{isc}$  为 0.5  $\Omega$ , 1  $\Omega$  与 10  $\Omega$ 。

图 9 显示了利用 FFRLS 算法所辨识的在不同老化程度下的电池发生不同级别内短路前后极化内阻的变化情况。由图可以看出, 当内短路发生后,  $R_{isc}$  为 0.5 或 1  $\Omega$  时, 极化内阻  $R_p$  急剧上升, 而当  $R_{isc}$  为 10  $\Omega$  时, 极化内阻  $R_p$  几乎没有变化。比较内短路发生前后各 360 s 内(两个完整的 DST 循环)极化内阻与欧姆内阻平均值的变化幅度, 如表 2 所示。对于极化内阻来说, 当  $R_{isc}$  为 0.5  $\Omega$ (1  $\Omega$ ) 时,  $B_1$ ,  $B_2$ ,  $B_3$  与  $B_4$  的极化内阻  $R_p$  分别变化了 82%, 53%, 84% 与 131%(29%, 37%, 41% 与 45%), 变化幅度较为明显。而对于欧姆内阻来说, 无论  $R_{isc}$  大小, 内短路前后欧姆内阻  $R_0$  的变化幅度均在 2%~6% 之间, 变化幅度较小。由此可知, 内短路的发生可通过极化内阻的突变来反映。

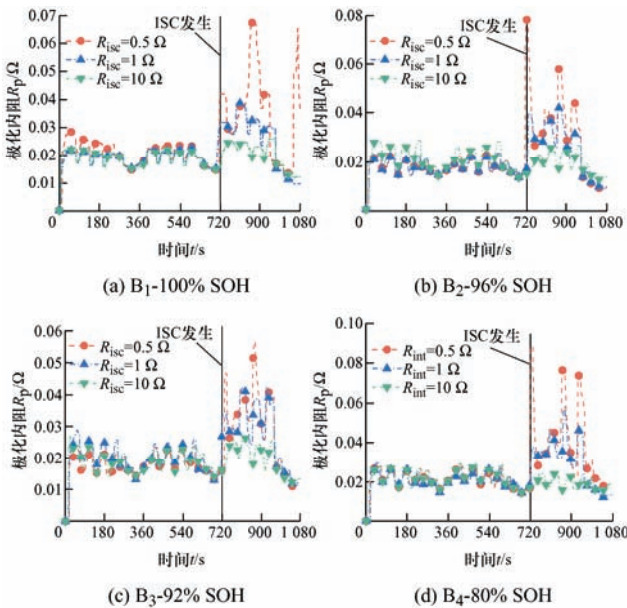


图 9 内短路前后极化内阻变化

表 2 内短路前后内阻均值变化幅度

等效内短路电阻 $R_{isc}/\Omega$	极化内阻 $R_p$			欧姆内阻 $R_0$		
	0.5	1	10	0.5	1	10
$B_1$ -100%SOH	82%	29%	3%	6%	5%	3%
$B_2$ -96%SOH	53%	37%	6%	5%	4%	2%
$B_3$ -92%SOH	84%	41%	4%	5%	5%	2%
$B_4$ -80%SOH	131%	45%	2%	5%	5%	2%

### 3 讨论与分析

#### 3.1 遗忘因子与间隔频率对参数辨识的影响

为了对 FFRLS 算法进行优化, 利用控制变量的方法, 对不同遗忘因子与取样间隔频率下, 在线辨识所得电池模型参数仿真端电压与实验所测真实端电压进行比较。以  $B_4$  为例, 不同遗忘因子下仿真端电压与真实值如图 10 所示。




图 10 不同遗忘因子下电池端电压

由图 10 可知, 不同遗忘因子下, 端电压辨识结果均存在偏差, 为优化算法, 利用平均绝对误差 MAE(Mean absolute error) 和 均方根误差 RMSE(Root mean squared error) 来衡量算法精度<sup>[24]</sup>, 其计算公式如下所示。

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (13)$$

式中,  $x_i$  与  $\hat{x}_i$  分别表示真实值与估计值。不同遗忘因子算法仿真不同老化程度电池端电压的 MAE 与 RSME 如表 3 所示。

由表 3 可知, 当 SOH 相同时, 随着遗忘因子增大, MAE 与 RMSE 均在增大, 当  $\mu=0.95$  时, 算法精度最高。当遗忘因子相同时, 老化后算法精度有所下降, 当  $\mu=0.99$  时, SOH 由 100% 下降到 80% MAE

与 RMSE 分别增加了 38% 与 30%，而当  $\mu=0.95$  时对应增加为 38% 与 18%。由此可见，电池老化加剧时，内部化学反应更加剧烈，具有极强的非线性与复杂性，对在线辨识造成一定影响，但当遗忘因子  $\mu=0.95$  时，可以相对有效地适应老化对辨识的影响并提高精度。

表 3 不同遗忘因子下端电压误差

遗忘因子 $\mu$		0.95	0.97	0.99	1
B <sub>1</sub> -100%SOH	MAE/mV	0.481	0.585	0.925	1.464
	RMSE/mV	1.176	1.323	1.819	4.048
B <sub>2</sub> -96%SOH	MAE/mV	0.523	0.643	1.034	1.578
	RMSE/mV	1.398	1.684	2.568	5.536
B <sub>3</sub> -92%SOH	MAE/mV	0.786	0.988	1.444	2.052
	RMSE/mV	2.871	3.432	4.319	7.513
B <sub>4</sub> -80%SOH	MAE/mV	0.661	0.820	1.273	1.976
	RMSE/mV	1.384	1.652	2.361	5.590

同样的，考虑到采样频率对于模型参数辨识也存在一定影响，利用 MAE 与 RMSE 来评估不同采样间隔对于算法精度的影响，结果如表 4 所示。由于电池测试平台所可以记录的最小时间间隔为 1 s，故比较采样间隔为 1 s，2 s，4 s，8 s 下仿真端电压与实验所测端电压间误差。由表 4 可知，与遗忘因子对精度影响相似，老化也会使精度下降，但间隔时间对精度影响相较遗忘因子更小。当老化程度相同时，间隔时间越小，精度越高，故采样间隔取 1 s。

表 4 不同采样间隔下端电压误差

时间间隔/s		1	2	4	8
B <sub>1</sub> -100%SOH	MAE/mV	0.481	0.497	0.612	0.670
	RMSE/mV	1.176	1.501	2.023	2.746
B <sub>2</sub> -96%SOH	MAE/mV	0.523	0.543	0.650	0.731
	RMSE/mV	1.398	1.725	2.080	2.983
B <sub>3</sub> -92%SOH	MAE/mV	0.786	0.859	0.990	0.993
	RMSE/mV	2.871	3.865	5.066	5.913
B <sub>4</sub> -80%SOH	MAE/mV	0.661	0.698	0.813	0.909
	RMSE/mV	1.384	1.764	2.443	3.526

### 3.2 温度估计

由式(9)与(11)可知，电池内阻与电池温度之间存在着紧密联系，故可以通过模型辨识参数对电池

表面温度进行仿真，来进一步验证该算法的精度。以电池 B<sub>1</sub> 为例，实验所测真实表面温度与不同遗忘因子下电池表面温度仿真值如图 11 所示。从图 11 可看出，当  $\mu=1$  时，即利用传统 RLS 算法进行电池表面温度估计时，随着电池放电加深，误差不断增大；而  $\mu=0.95$  时，FFRLS 算法可较为准确反应实际温度。这可能是由于温度随时间变化缓慢，导致 RLS 算法从新数据中获得的信息量减少，而当  $\mu=0.95$  时，可以有效减少老数据，从新数据中获得更多信息，解决“数据饱和”问题。当  $\mu=0.95$  时，对不同 SOH 下电池表面温度估计时，仿真温度与实际温度极限误差均在 2% 以下。这进一步验证了该算法辨识极化内阻的可行性与精确度。




图 11 不同遗忘因子下电池表面温度

### 3.3 内短路识别能力探究

由内短路实验可知，内短路发生时会引起极化内阻突变，这表明极化内阻可作为标识内短路的独立参数。但若利用在线辨识极化内阻的方式监测内短路，仍需探究极化内阻识别内短路的能力。

对比图 7d 与 7f 可知，不同工况下，极化内阻的辨识结果存在一定偏差。这表明在不同工况下，通过模型参数辨识所得极化内阻会在一定的范围内波动。由于在日常使用过程中，电动汽车会面临许多复杂的工况，若在内短路发展到后期阶段 ( $R_{isc} < 0.1 \Omega$ ) 之前，极化内阻阻值的突变幅度仍小于由于工况变动所产生的极化内阻自身波动范围，则可能导致无法提前预警或者误报的情况。因此需要比较极化内阻突变幅度与其自身波动范围。

为了确定不同工况下极化内阻的波动范围，本研究选择 HPPC 与 DST 两种不同工况下，处于相同 SOC 下的内阻进行比较。为便于对比，求取间隔 10% SOC 处的内阻波动值，所得极化内阻在不同工况下的平均波动与极限波动范围如表 5 所示。

表 5 不同工况下极化内阻波动

电池	B <sub>1</sub> 100%SOH	B <sub>2</sub> 96%SOH	B <sub>3</sub> 92%SOH	B <sub>4</sub> 80%SOH
波动极限	20%	12%	15%	13%
波动均值	9%	5%	6%	5%

结合表 5 与表 2 可以看出, 当等效内短路电阻  $R_{isc}=10\ \Omega$  时, 内短路前后极化内阻  $R_p$  变化幅度与极化内阻自身在不同工况下波动均值相近, 远小于最大极限波动范围, 无法起到检测内短路的作用。但当  $R_{isc}$  为  $0.5\ \Omega$  或  $1\ \Omega$  时, 极化内阻突变幅度的最小值为 29%, 高于最大波动范围 20%。可以起到识别内短路的作用。因此, 该基于最小二乘法的锂电池全寿命周期参数辨识算法可通过辨识极化内阻的方式在内短路发展到后期阶段前有效识别内短路。

## 4 结论

本文首先建立了锂电池的 Thevenin 模型, 并在此基础上辨识得到了 HPPC 与 DST 工况下全寿命周期内锂电池的极化内阻等模型参数, 最后基于带遗忘因子的递推最小二乘法在线辨识锂电池极化内阻以实时监测内短路。得到以下结论。

(1) 欧姆内阻的大小主要受到 SOC 与老化程度的影响, 在放电末端与老化加剧时有明显增大; 极化内阻相较于欧姆内阻, 受到外部条件影响(如电流、电压等)时变化更为显著。

(2) 对 FFRLS 算法进行优化, 通过控制变量的方式比较仿真端电压与实测端电压间的 MAE 与 RMSE, 发现当遗忘因子  $\mu=0.95$ , 取样时间间隔为 1 s 时, FFRLS 算法的精度与对老化的适应性最高。

(3) 利用遗忘因子为 0.95 的 FFRLS 算法在线辨识所得内阻进行电池表面温度仿真, 不同老化状态电池仿真温度与实际温度极限误差均在 2% 以下, 进一步验证了算法的可行性。

(4) 通过比较极化内阻不同工况下自身波动范围与内短路前后极化内阻变化幅度, 证明该算法可以在内短路发展到后期阶段前成功检测到内短路。

## 参 考 文 献

- [1] 陈泽宇, 熊瑞, 孙逢春. 电动汽车电池安全事故分析与研究现状[J]. 机械工程学报, 2019, 55(24): 93-104.  
CHEN Zeyu, XIONG Rui, SUN Fengchun. Research status and analysis for battery safety accidents in electric vehicles[J]. Journal of Mechanical Engineering, 2019, 55(24): 93-104.
- [2] 朱晓庆, 王震坡, WANG Hsin, 等. 锂离子动力电池热失控与安全管理研究综述[J]. 机械工程学报, 2020, 56(14): 91-118.  
ZHU Xiaoqing, WANG Zhenpo, WANG Hsin, et al. Review of thermal runaway and safety management for lithium-ion traction batteries in electric vehicles[J]. Journal of Mechanical Engineering, 2020, 56(14): 91-118.
- [3] FENG X, REN D, HE X, et al. Mitigating thermal runaway of lithium-ion batteries[J]. Joule, 2020, 4(4): 743-770.
- [4] XIN L, JIN C, YI W, et al. Mechanism, modeling, detection, and prevention of the internal short circuit in lithium-ion batteries: Recent advances and perspectives[J]. Energy Storage Materials, 2021, 35: 470-499.
- [5] OUYANG M, ZHANG M, FENG X, et al. Internal short circuit detection for battery pack using equivalent parameter and consistency method[J]. Journal of Power Sources, 2015, 294: 272-283.
- [6] YANG C, WANG X, FANG Q, et al. An online SOC and capacity estimation method for aged lithium-ion battery pack considering cell inconsistency[J]. Journal of Energy Storage, 2020, 29: 101250.
- [7] FENG X, WENG C, OUYANG M, et al. Online internal short circuit detection for a large format lithium ion battery[J]. Applied Energy, 2016, 161: 168-180.
- [8] NOELLE D J, WANG M, LE A V, et al. Internal resistance and polarization dynamics of lithium-ion batteries upon internal shorting[J]. Applied Energy, 2018, 212: 796-808.
- [9] 李伟, 刘伟鬼, 邓业林. 基于扩展卡尔曼滤波的锂离子电池荷电状态估计[J]. 中国机械工程, 2020, 31(3): 321-327.  
LI Wei, LI Weiwei, DENG Yelin. SOC estimation for lithium-ion batteries based on EKF[J]. China Mechanical Engineering, 2020, 31(3): 321-327.
- [10] HE H, ZHANG X, XIONG R, et al. Online model-based estimation of state-of-charge and open-circuit voltage of lithium-ion batteries in electric vehicles[J]. Energy, 2012, 39(1): 310-318.
- [11] 李玥铎, 刘淑杰, 高斯博, 等. 基于维纳过程的锂离子电池剩余寿命预测[J]. 大连理工大学学报, 2017, 57(2): 126-132.  
LI Yuexin, LIU Shujie, GAO Sibao, et al. Prediction of



- lithium-ion battery's remaining useful life based on wiener process[J]. Journal of Dalian University of Technology, 2017, 57(2): 126-132.
- [12] CHEN X, CHU A, LI D, et al. Development of the cycling life model of Ni-MH power batteries for hybrid electric vehicles based on real-world operating conditions[J]. Journal of Energy Storage, 2021, 34: 101999.
- [13] WANG W, WANG J, TIAN J, et al. Application of digital twin in smart battery management systems[J]. Chinese Journal of Mechanical Engineering, 2021, 34(1): 1-19.
- [14] DENG Z, YANG L, DENG H, et al. Polynomial approximation pseudo-two-dimensional battery model for online application in embedded battery management system[J]. Energy, 2018, 142: 838-850.
- [15] DENG Z, HU X, LIN X, et al. Data-driven state of charge estimation for lithium-ion battery packs based on Gaussian process regression[J]. Energy, 2020, 205: 118000.
- [16] HU X, LI S, PENG H. A comparative study of equivalent circuit models for Li-ion batteries[J]. Journal of Power Sources, 2012, 198: 359-367.
- [17] TIAN J, XIONG R, SHEN W, et al. A comparative study of fractional order models on state of charge estimation for Lithium ion batteries[J]. Chinese Journal of Mechanical Engineering, 2020, 33(1): 1-15.
- [18] ZHANG S, GUO X, ZHANG X. An improved adaptive unscented Kalman filtering for state of charge online estimation of lithium-ion battery[J]. Journal of Energy Storage, 2020, 32: 101980.
- [19] OUYANG T, XU P, CHEN J, et al. Improved parameters identification and state of charge estimation for lithium-ion battery with real-time optimal forgetting factor[J]. Electrochimica Acta, 2020, 353: 136576.
- [20] CHOUDHARI V G, DHOBLE D A S, SATHE T M. A review on effect of heat generation and various thermal management systems for lithium ion battery used for electric vehicle[J]. Journal of Energy Storage, 2020, 32: 101729.
- [21] ZHANG J, HUANG J, LI Z, et al. Comparison and validation of methods for estimating heat generation rate of large-format lithium-ion batteries[J]. Journal of Thermal Analysis and Calorimetry, 2014, 117(1): 447-461.
- [22] YANG L, CAI Y, YANG Y, et al. Supervisory long-term prediction of state of available power for lithium-ion batteries in electric vehicles[J]. Applied Energy, 2020, 257: 114006.
- [23] ZHANG G, WEI X, TANG X, et al. Internal short circuit mechanisms, experimental approaches and detection methods of lithium-ion batteries for electric vehicles: A review[J]. Renewable and Sustainable Energy Reviews, 2021, 141: 110790.
- [24] 朱瑞, 段彬, 温法政, 等. 基于分布式最小二乘法的锂离子电池建模及参数辨识[J]. 机械工程学报, 2019, 55(20): 85-93.
- ZHU Rui, DUAN Bin, WEN Fazheng, et al. Lithium-ion battery modeling and parameter identification based on decentralized least squares method[J]. Journal of Mechanical Engineering, 2019, 55(20): 85-93.

作者简介: 何晋, 男, 1998 年生, 硕士研究生。主要研究方向为电池热管理, 模型在线辨识等。

E-mail: jhe0129@stu.suda.edu.cn

邓业林(通信作者), 男, 1984 年生, 副教授, 硕士研究生导师。主要研究方向为退役动力电池的梯次利用、动力电池可持续设计等。

E-mail: yelin.deng@suda.edu.cn