

# 控制与决策

Control and Decision

## 基于全新等效电路模型的电池关键状态在线联合估计器

刘芳, 邵晨, 苏卫星, 刘阳

引用本文:

刘芳, 邵晨, 苏卫星, 刘阳. 基于全新等效电路模型的电池关键状态在线联合估计器[J]. *控制与决策*, 2023, 38(6): 1620–1628.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1812>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 双线性状态空间系统的状态观测器设计

State observers for bilinear state–space systems

控制与决策. 2023, 38(1): 274–280 <https://doi.org/10.13195/j.kzyjc.2021.0732>

#### 基于自然梯度提升的空间物体轨道状态预测误差不确定性估计方法

Uncertainty estimation approach in orbital prediction error of space objects based on natural gradient boosting

控制与决策. 2022, 37(12): 3289–3296 <https://doi.org/10.13195/j.kzyjc.2021.0720>

#### 自适应快速弱敏无迹Kalman滤波算法

Adaptive fast desensitized unscented Kalman filter algorithm

控制与决策. 2022, 37(2): 506–512 <https://doi.org/10.13195/j.kzyjc.2020.1086>

#### 基于HI-DD-AdaBoost.RT的锂离子动力电池SOH预测

Prediction of Li-ion battery SOH based on HI-DD-AdaBoost.RT

控制与决策. 2021, 36(3): 686–692 <https://doi.org/10.13195/j.kzyjc.2019.0764>

#### 含有分数阶有色关联噪声的分数阶系统的卡尔曼滤波器设计

Design of Kalman filter for fractional–order systems with correlated fractional–order colored noises

控制与决策. 2021, 36(7): 1672–1678 <https://doi.org/10.13195/j.kzyjc.2019.1418>

# 基于全新等效电路模型的电池关键状态在线联合估计器

刘芳<sup>1</sup>, 邵晨<sup>1</sup>, 苏卫星<sup>1†</sup>, 刘阳<sup>2</sup>

(1. 天津工业大学 天津市自主智能技术与系统重点实验室, 天津 300387;

2. 华晨宝马汽车有限公司 整车开发部, 沈阳 110098)

**摘要:** 针对电池三大关键状态(State of Charge-SOC、State of Health-SOH、State of Power-SOP)之间相互耦合的关系,同时考虑到其估计精度受到电池时变的内部参数等因素影响的问题,提出一种基于自回归等效电路模型(auto regression equivalent circuit model, AR-ECM)的电池关键状态在线联合估计算法.该方法提出基于AR模型的全新电池ECM,给出同时表征SOC、SOH和电池内部压降的状态空间方程以及区别化参数更新策略.在此基础上,考虑状态方程容易发生不正定的问题,提出采用平方根无迹卡尔曼滤波(square root unscent kalman filter, SR-UKF)算法实现电池状态的联合估计.该算法的优势在于真正实现了电池关键状态以及ECM参数的联合估计,更符合实际工程应用需求.仿真验证表明,在噪声干扰环境下,该联合估计器能够得到较高的精确度和稳定性.

**关键词:** 电池; 等效电路模型; 联合估计; 荷电状态; 健康状态; 功率状态; SR-UKF

中图分类号: TM912

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1812

**引用格式:** 刘芳,邵晨,苏卫星,等.基于全新等效电路模型的电池关键状态在线联合估计器[J].控制与决策,2023,38(6):1620-1628.

## Online joint estimator of battery key states based on a new equivalent circuit model

LIU Fang<sup>1</sup>, SHAO Chen<sup>1</sup>, SU Wei-xing<sup>1†</sup>, LIU Yang<sup>2</sup>

(1. Tianjin Key Laboratory of Autonomous Intelligence Technology and Systems, Tiangong University, Tianjin 300387, China; 2. BBT-E-6 Complete Vehicle, BMW Brilliance Automotive Ltd., Shenyang 110098, China)

**Abstract:** Aiming at the coupling relationship between the three key states of battery (state of charge-SOC, state of health-SOH, state of power-SOP), and considering that their estimation accuracy is affected by the time-varying internal parameters of battery and other factors, an online joint estimation algorithm of battery key states based on autoregressive equivalent circuit model (AR-ECM) is proposed. The method proposes a new battery ECM based on the AR model, and gives the state space equation that characterizes the SOC, SOH and internal voltage drop of the battery simultaneously, as well as the differentiated parameter updating strategy. Based on this, considering the problem that the state equation is prone to non-positive definiteness, the square root unscented Kalman filter (SR-UKF) algorithm is used to achieve the joint estimation of the battery states. The advantage of this algorithm is that it truly achieves the joint estimation of the key battery states and ECM parameters, which is more in line with the practical engineering application requirements. The simulation verification shows that the joint estimator can obtain high accuracy and stability under noise disturbance.

**Keywords:** battery; equivalent circuit model; joint estimation; state of charge; state of health; state of power; SR-UKF

## 0 引言

锂离子电池由于其能量密度高、循环寿命长等优点<sup>[1-2]</sup>,在电动汽车等领域得到广泛应用.其关键状态:荷电状态(SOC)、健康状态(SOH)和功率状态(SOP)的精确估计对电动汽车精确管理至关重要.

目前,对电池关键状态估计的研究可分成两类:

无模型方法和基于模型的方法.在无模型方法中,对于SOC的估计有开路电压法和安时积分法<sup>[3]</sup>等.该类方法易于实现,但易产生累计误差且无法消除<sup>[4]</sup>.对于SOH的估计,无模型方法有差分电压法<sup>[5]</sup>、增量容量法<sup>[6]</sup>等,其根据电池老化过程中的外在电气特征变化估计电池的老化,但电池生产工艺带来一

收稿日期: 2021-10-21; 录用日期: 2022-03-04.

基金项目: 国家重点研发计划项目(2021YFB2501800); 天津市研究生科研创新项目(2021YJSS065); 国家自然科学基金项目(61802280, 61806143, 61772365, 41772123); 天津市自然科学基金项目(18JQNJC77200).

责任编辑: 孙宗耀.

†通讯作者. E-mail: suweixing@tiangong.edu.cn.

致性差等问题直接影响此类算法的估算精度<sup>[7]</sup>. 对于 SOP 的估计鲜有无模型方法, 大多基于精确的电池模型计算得到. 基于电池模型的电池关键状态估计是目前主流的研究思路, 如滤波族方法<sup>[8]</sup>, 其闭环自矫正环节无需精确的状态初值<sup>[9-10]</sup>, 但此类方法的估算精度对电池模型精度极为敏感. 目前, 同样有许多研究人员致力于电池模型问题的研究, 如  $n$  阶 RC 等效电路模型 (nRC-ECM)<sup>[11]</sup>. 文献 [12] 指出, 当  $n$  值取 1 时, AIC 准则 (akaike information criterion) 指征电池 ECM 最佳, 但对于电动汽车这类充放电随机的应用而言, 1 阶 RC-ECM 精度并不理想. 近年来, 一种新的电池 ECM——自回归模型得到应用, 该 ECM 将电池内部压降用 AR 模型模拟, 不需要传统 nRC-ECM ( $n = 1, 2, \dots$ ) 中对  $n$  值的设定. 文献 [7] 使用 AR 模型与 UKF 算法对温度表征进行修正, 但仅实现了 SOH 估计, 未给出多状态的电池状态方程, 且 AR 模型中未将电池内阻部分提出来, 其合理性有待商榷.

ECM、SOC、SOH 及 SOP 的精度相互耦合, 针对单一问题的研究并不符合实际需求. 目前, 也有一些研究人员提出联合估计, 但大多仅针对其中两者进行联合估计: 如文献 [1] 提出一种基于双扩展卡尔曼滤波器的锂离子电池 SOC 和 SOH 联合估计方法; 文献 [13] 提出一种数据驱动的 SOC 和 SOP 联合估计器.

基于现有电池关键状态估计问题的研究现状, 本文首先提出一种全新的等效电路模型, 该 ECM 能够高精度模拟电池随机充放电的瞬态电气动态特性, 适合电动车一类充放电随机、电流和电压均剧烈波动的应用. 基于此 ECM, 进一步给出能够表征 SOC、SOH 和电池动态参数的电池状态空间方程以及模型参数在线辨识算法, 最终实现基于 SR-UKF 算法的电池关键状态在线联合估计.

## 1 基于 AR 模型的全新电池等效电路模型

### 1.1 基于 AR 模型的 ECM 电池结构

所提出的全新 ECM 的电路原理如图 1 所示. 其中:  $U_n$  为电池内部压降,  $R$  为电池内部欧姆内阻,  $U_{AR}$  为电池内部极化电压,  $U_{OCV}$  为开路电压,  $U_d$  为端电压. 依据图 1, 各电压之间关系为

$$U_d(k) = U_{OCV}(k) - RI(k) - U_{AR}(k). \quad (1)$$

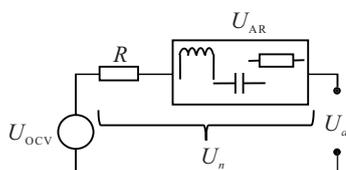


图 1 基于 AR 模型的 ECM 原理

其中:  $U_d(k)$ 、 $U_{OCV}(k)$ 、 $U_{AR}(k)$  分别为  $k$  时刻电池端电压、开路电压及内部极化电压;  $I(k)$  为  $k$  时刻电流. 定义充电为负, 放电为正, 考虑电池极化压降与电流变化紧密相关, 提出利用以电流为输入的 AR 模型对其拟合. 该 AR 模型为

$$U_{AR}(k) = \sum_{i=1}^p a_i I(k-i). \quad (2)$$

其中:  $p$  为模型阶次,  $a_i (i = 1, 2, \dots, p)$  为 AR 模型系数. 式 (1) 改写为

$$U_d(k) = U_{OCV}(k) - RI(k) - \sum_{i=1}^p a_i I(k-i). \quad (3)$$

式 (3) 即为所提出的 AR-ECM 表达式.

### 1.2 AR-ECM 状态空间方程

由式 (3) 可知,  $- (RI(k) + \sum_{i=1}^p a_i I(k-i))$  表征  $k$  时刻电池内部压降, 则  $k+1$  时刻内部压降为

$$U_n(k+1) = RI(k+1) + \sum_{i=1}^p a_i I(k+1-i). \quad (4)$$

$k$  时刻表达式为

$$U_n(k) = RI(k) + \sum_{i=1}^p a_i I(k-i). \quad (5)$$

由式 (4) 和 (5) 可得到基于图 1 电池内部压降  $U_n$  的递归表达式为

$$\begin{aligned} U_n(k+1) &= U_n(k) + R[I(k+1) - I(k)] + \\ &\quad \sum_{i=1}^p a_i [I(k+1-i) - I(k-i)] = \\ &U_n(k) + \sum_{i=0}^p a_i \Delta I(k+1-i). \end{aligned} \quad (6)$$

其中:  $\Delta I(k+1-i) = I(k+1-i) - I(k-i)$ ;  $i=0$  时,  $a_0$  为欧姆内阻,  $a_0 = R$ ;  $a_i (i = 1, 2, \dots, p)$  为极化电压的 AR 模型系数.

考虑到反映电池老化的 SOH 为长期渐变状态, 可以认为前后两采样时刻 SOH 保持不变, 即

$$L_{SOH}(k+1) = L_{SOH}(k). \quad (7)$$

依据库伦积分法给出电池 SOC 的递归表达式为

$$L_{SOC}(k+1) = L_{SOC}(k) - \frac{\eta \Delta t I(k)}{L_{SOH}(k) C_n}. \quad (8)$$

其中:  $\Delta t$  为采样周期,  $C_n$  为电池标称容量,  $\eta$  为与温度、充放电倍率有关的系数.

利用式 (6)~(8), 得到状态空间方程

$$\begin{cases} L_{SOH}(k+1) = L_{SOH}(k), \\ L_{SOC}(k+1) = L_{SOC}(k) - \frac{\eta \Delta t I(k)}{L_{SOH}(k) C_n}, \\ U_n(k+1) = \\ U_n(k) + \sum_{i=0}^p a_i [I(k+1-i) - I(k-i)]. \end{cases} \quad (9)$$

其中: 状态变量  $x(k) = [L_{SOH}(k) \ L_{SOC}(k) \ U_n(k)]^T$ , 控制变量  $u(k) = [I(k+1), I(k), \dots, I(k+1-p)]^T$ . 选取端电压为观测变量, 可得观测方程

$$U_d(k) = Gx(k) + U_{OCV}(L_{SOC}(k)) + v_k. \quad (10)$$

其中:  $G = [0 \ 0 \ -1]$ ;  $v_k$  为观测噪声, 其协方差为  $C$ ; 开路电压可表示为荷电状态的函数<sup>[14]</sup>

$$U_{OCV}(L_{SOC}(k)) = k_0 + \frac{k_1}{L_{SOC}(k)} + k_2 L_{SOC}(k) + k_3 \ln(L_{SOC}(k)) + k_4 \ln(1 - L_{SOC}(k)), \quad (11)$$

$k_0, k_1, \dots, k_4$  为待辨识参数.

给出 AR-ECM 完整状态方程为

$$\begin{cases} x(k+1) = f(x(k), u(k)) + w_k, \\ U_d(k) = h(x(k), u(k)) + v_k. \end{cases} \quad (12)$$

其中:  $w_k$  为系统噪声, 协方差为  $Q$ ;  $f(\cdot), h(\cdot)$  分别为式 (9)、(10) 状态变量  $x(k)$  和控制量  $u(k)$  的非线性函数关系.

### 1.3 区别化模型参数辨识策略

式 (12) 的待辨识参数有以下两类: 一是式 (11) 系数  $k_0 \sim k_4$ ; 二是式 (6) 中 AR 模型系数  $a_i (i = 0, 1, \dots, p)$ . 分析两类参数变化规律: 一般认为  $U_{OCV}$  仅与电池老化有关, 即  $U_{OCV}$  与 SOC 函数关系在一次充放电循环或邻近的几次充放电循环内保持不变, 因此认为  $k_0 \sim k_4$  为慢时变参数; 而电池内部压降相关参数会随温度等因素变化, 即在一次充放电循环中不断变化, 因此认为参数  $a_i (i = 0, 1, \dots, p)$  为快时变参数. 两类参数采用不同更新策略, 尽量降低复杂度, 提高实时性. 区别化参数辨识策略如图 2 所示.

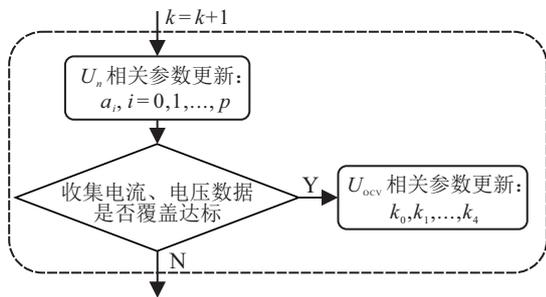


图 2 区别化模型参数辨识策略

图 2 中, “收集电流、电压数据是否覆盖达标” 计算如下: 收集电压覆盖范围

$$\Delta U_d = |U_d(1) - U_d(k)|. \quad (13)$$

判断规则如下:

$$\begin{cases} \Delta U_d \geq \Delta U_{set}, \text{ 达标;} \\ \Delta U_d < \Delta U_{set}, \text{ 不达标.} \end{cases} \quad (14)$$

其中:  $\Delta U_{set}$  为设定的电压跨度范围, 一般认为  $\Delta U_{set} \geq 0.85 \times (U_{max} - U_{min})$ ,  $U_{max}$  和  $U_{min}$  分别为电池充放电截止电压.

#### 1.3.1 $U_{OCV}$ 相关参数更新

锂电池在满电或无电附近曲线较陡峭, 中间较平缓, 因此  $k_0 \sim k_4$  应在数据覆盖一定程度时才能准确辨识, 以马里兰大学实验室一款锂电池 A123 为例 (参数见表 1), 其辨识结果如图 3 所示.

表 1 A123 电池参数

类型	标称电压 (V)	标称容量 (Ah)	充/放电截止电压 (V)	最大放电电流 (A)
LiFePO <sub>4</sub>	3.3	1.1	3.6/2.0	30

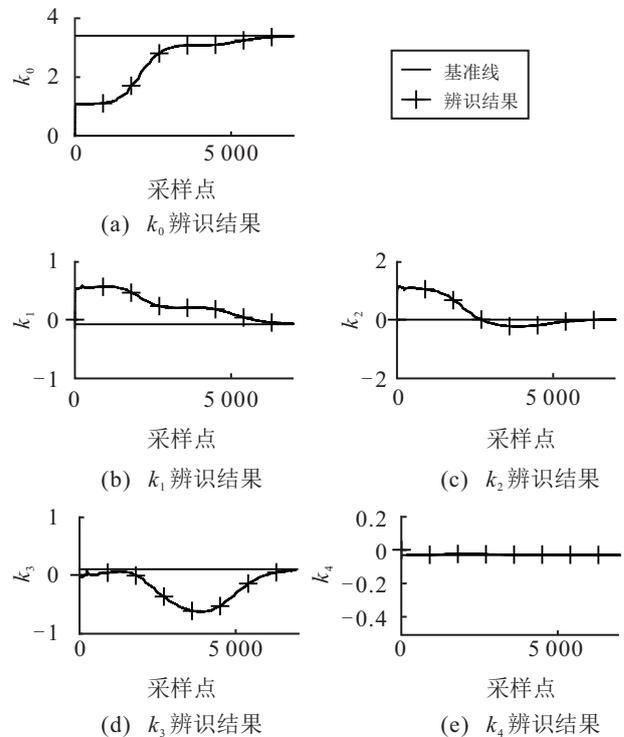


图 3  $U_{OCV}$  函数相关参数辨识结果

图 3 中, + 号直线为采集的电流、电压数据实时辨识参数值. 实线为完整电流、电压数据计算得到的结果, 为准确值, 结果如表 2 所示.

表 2  $k_0 \sim k_4$  真实值

$k_0$	$k_1$	$k_2$	$k_3$	$k_4$
3.406	-0.1568	2.069e-05	0.09775	-0.03187

由图 3 可见, 除  $k_4$  外,  $k_0 \sim k_3$  的在线辨识结果都仅在末期才趋近于真实值, 这也从一个侧面证实: 参数  $k_0 \sim k_4$  必须在数据量覆盖范围足够大时, 才能得到较为准确的结果.

### 1.3.2 电池内部压降 $U_n$ 参数辨识

电池内部压降主要由电流变化决定,且受温度等因素影响,需要在线实时辨识,由式(5)可知,其为线性函数,因此可选择参数辨识算法较多,如递归最小二乘算法(RLS)<sup>[10]</sup>等.本文同样以A123电池为例,给出AR模型系数辨识结果如图4所示.

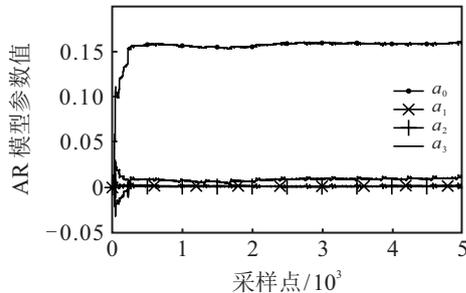


图4  $U_n$  相关系数辨识结果

由图4可知,AR模型阶次 $p = 3$ ,经过短暂调节,参数 $a_i (i = 0, 1, \dots, p)$ 趋于稳定.对比图3可见: $a_i (i = 0, 1, \dots, p)$ 短期内趋于稳定,可用部分数据辨识;而 $k_0, \dots, k_4$ 无法在短期内趋于稳定,需要数据覆盖范围足够大.因此,所提出的区别化模型参数辨识策略(图2)是必要且合理的.

## 2 电池关键状态联合估计器

### 2.1 基于SR-UKF算法的AR-ECM状态方程求解

由式(9)可知,状态变量中隐变量数较多,常规滤波算法求解由于舍入误差等因素<sup>[15]</sup>易出现状态误差协方差矩阵不正定问题,从而导致结果发散.考虑数值稳定及计算复杂度,本文采用SR-UKF算法求解.

SR-UKF算法<sup>[16]</sup>以Cholesky分解因数的形式传播和更新状态误差协方差的平方根,保证协方差矩阵的半正定性和状态在线估计的数值稳定性,从而克服滤波结果发散,步骤如下.

step 1: 状态值初始化 $\hat{x}_0 = E(x_0)$ ,  $x_0$ 表示初始时刻随机给出的状态变量的初始值.

step 2: Cholesky分解为

$$S_0 = \text{chol}\{E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T]\}.$$

其中:  $\text{chol}(\cdot)$ 为Cholesky分解运算,  $S_0$ 为状态误差协方差矩阵的Cholesky因子.

step 3: 构造Sigma点集

$$\begin{cases} x_{k-1}^i = \hat{x}_{k-1}, i = 0; \\ x_{k-1}^i = \hat{x}_{k-1} + \sqrt{(n+\lambda)}S_{k-1|k-1}, i = 1 \sim n; \\ x_{k-1}^i = \hat{x}_{k-1} - \sqrt{(n+\lambda)}S_{k-1|k-1}, i = n+1 \sim 2n. \end{cases} \quad (15)$$

其中: $x_{k-1}^i$ 为 $k-1$ 时刻第 $i$ 个Sigma点; $n$ 为状态维

数; $\lambda = \alpha^2(n + \kappa) - n$ ,  $\kappa$ 为比例因子,通常取0或 $3 - n$ ,  $\alpha$ 反映Sigma点围绕均值的偏离情况; $S_{k-1|k-1}$ 为 $k-1$ 时刻状态误差协方差矩阵的Cholesky因子.

step 4: 状态一步预测

$$x_{k|k-1}^i = f(x_{k-1|k-1}^i, u_{k-1}), \quad (16)$$

$$\hat{x}_k^- = \sum_{i=0}^{2n} w_m^i x_{k|k-1}^i, \quad (17)$$

$$S_{k|k-1}^- = \text{qr}\{\sqrt{w_c^{1:2n}}(x_{k|k-1}^{1:2n} - \hat{x}_k^-), \sqrt{Q}\}. \quad (18)$$

$$S_{k|k-1} = \text{cholupdate}\{S_{k|k-1}^-, x_{k|k-1}^0 - \hat{x}_k^-, w_c^0\}. \quad (19)$$

其中: $x_{k|k-1}^i$ 为 $x_{k-1}^i$ 的一步估计值; $\hat{x}_k^-$ 为 $x_{k|k-1}^i$ 的加权状态估计, $i = 1, \dots, 2n$ ;  $\text{qr}(\cdot)$ 为QR分解函数; $w_m$ 、 $w_c$ 分别为均值权和方差权,有

$$\begin{cases} w_m^0 = \lambda/(n + \lambda), \\ w_c^0 = \lambda/(n + \lambda) + (1 - \alpha^2 + \beta); \end{cases} \quad (20)$$

$$\begin{cases} w_m^i = 1/2(n + \lambda), \\ w_c^i = 1/2(n + \lambda). \end{cases} \quad (21)$$

step 5: 观测估计值计算

$$y_{k|k-1}^i = h(x_{k|k-1}^i, u_k), \quad (22)$$

$$\hat{y}_k^- = \sum_{i=0}^{2n} w_m^i y_{k|k-1}^i, \quad (23)$$

$$S_{y_k}^- = \text{qr}\{\sqrt{w_c^{1:2n}}(y_{k|k-1}^{1:2n} - \hat{y}_k^-), \sqrt{C}\}, \quad (24)$$

$$S_{y_k} = \text{cholupdate}\{S_{y_k}^-, y_{k|k-1}^0 - \hat{y}_k^-, w_c^0\}, \quad (25)$$

$$P_{x_k, y_k} = \sum_{i=0}^{2n} w_c^i (x_{k|k-1}^i - \hat{x}_k^-)(y_{k|k-1}^i - \hat{y}_k^-)^T. \quad (26)$$

其中: $y_{k|k-1}^i$ 为观测值的一步估计值, $i = 1, 2, \dots, 2n$ ;  $S_{y_k}$ 为观测误差协方差Cholesky因子; $P_{x_k, y_k}$ 为互协方差矩阵.

step 6: 状态修正

$$K_k = (P_{x_k, y_k} / S_{y_k}^T) / S_{y_k}, \quad (27)$$

$$\hat{x}_k = \hat{x}_k^- + K_k(y_k - \hat{y}_k^-), \quad (28)$$

$$U = K_k S_{y_k}, \quad (29)$$

$$S_{k|k} = \text{cholupdate}\{S_{k|k-1}, U, -1\}. \quad (30)$$

其中: $K_k$ 为卡尔曼增益, $\hat{x}_k$ 为修正后的状态值, $y_k$ 为观测向量, $S_{k|k}$ 为Cholesky因子.

### 2.2 基于AR-ECM的多因素限制下SOP估算

SOP分为短时和长时两类,短时充放电能力为单采样周期( $\Delta t$ )的充放电能力;长时充放电能力分为30 s、60 s、120 s等多采样周期内的充放电能力.

### 2.2.1 电压限制下的峰值电流估计

设 $k$ 时刻起,经过 $L(L=l\Delta t, l=1, 2, \dots)$ 时长的持续充放电后,AR-ECM模型应满足

$$U_d(k+L) = U_{OCV}(L_{SOC}(k+L)) - U_n(k+L), \quad (31)$$

其为电流 $I$ 的非线性函数.泰勒级数展开如下:

$$U_d(k+L) = U_{OCV}(L_{SOC}(k)) - L \frac{\eta t \Delta t I(k+L)}{L_{SOH}(k+L)C_n} - U_n(k+L) =$$

$$\begin{cases} I_{\min}^{\text{chg},u}(k+L) = \frac{U_{OCV}(L_{SOC}(k)) - U_{\max} - U_n(k+L)}{\frac{\eta L \Delta t}{L_{SOH}(k+L)} \left( -\frac{k_1}{L_{SOC}(k)^2} + k_2 + \frac{k_3}{L_{SOC}(k)} - \frac{k_4}{1-L_{SOC}(k)} \right)}, \\ I_{\max}^{\text{dis},u}(k+L) = \frac{U_{OCV}(L_{SOC}(k)) - U_{\min} - U_n(k+L)}{\frac{\eta L \Delta t}{L_{SOH}(k+L)} \left( -\frac{k_1}{L_{SOC}(k)^2} + k_2 + \frac{k_3}{L_{SOC}(k)} - \frac{k_4}{1-L_{SOC}(k)} \right)}. \end{cases} \quad (33)$$

其中: $I_{\min}^{\text{chg},u}(k+L)$ 为最小充电电流, $I_{\max}^{\text{dis},u}(k+L)$ 为最大放电电流.

### 2.2.2 SOC限制下的峰值电流估计

设从时刻 $k$ 起,经过 $L$ 时长的持续充放电后,电池SOC应满足

$$L_{SOC}(k+L) = L_{SOC}(k) - \frac{L\Delta t\eta \cdot I(k+L)}{L_{SOH}(k+L)C_n}. \quad (34)$$

为了防止电池过充过放,SOC应在 $L_{\text{soc},\min} \leq L_{\text{soc}} \leq L_{\text{soc},\max}$ 范围内,得到SOC限制下 $L$ 时长内的持续充放电峰值电流为

$$\begin{cases} I_{\min}^{\text{chg},\text{soc}}(k+L) = \frac{L_{SOC}(k) - L_{\text{soc},\max}}{L\eta\Delta t/L_{SOH}(k+L)C_n}; \\ I_{\max}^{\text{dis},\text{soc}}(k+L) = \frac{L_{SOC}(k) - L_{\text{soc},\min}}{L\eta\Delta t/L_{SOH}(k+L)C_n}. \end{cases} \quad (35)$$

### 2.2.3 多因素限制下的SOP估计

考虑电压、SOC及设计标称电流 $[I_{\min}, I_{\max}]$ 限制,得到多因素限制下持续充放电峰值电流为

$$\begin{cases} I_{\min}^{\text{chg}} = \max(I_{\min}, I_{\min}^{\text{chg},\text{soc}}(k+L), I_{\min}^{\text{chg},u}(k+L)), \\ I_{\max}^{\text{dis}} = \min(I_{\max}, I_{\max}^{\text{dis},\text{soc}}(k+L), I_{\max}^{\text{dis},u}(k+L)). \end{cases} \quad (36)$$

进一步,得到多因素限制下的持续充放电峰值功率为

$$\begin{cases} P_{\min}^{\text{chg}} = \max(P_{\min}, U_d(k+L)I_{\min}^{\text{chg}}), \\ P_{\max}^{\text{dis}} = \min(P_{\max}, U_d(k+L)I_{\max}^{\text{dis}}). \end{cases} \quad (37)$$

其中 $P_{\min}$ 、 $P_{\max}$ 为电池设计标称功率限制.

将式(32)代入(37)可得到 $L$ 时长内多因素限制下的持续充放电峰值功率最终表达式为

$$P_{\min}^{\text{chg}} = \max\left(P_{\min}, \left(U_{OCV}(L_{SOC}(k)) - L \frac{\eta\Delta t I(k+L)}{L_{SOH}(k+L)C_n} - U_n(k+L)\right) I_{\min}^{\text{chg}}\right).$$

$$U_{OCV}(L_{SOC}(k)) - L \frac{\eta\Delta t I(k+L)}{L_{SOH}(k+L)C_n}.$$

$$\frac{\partial U_{OCV}}{\partial L_{SOC}} \Big|_{L_{\text{soc}}=L_{\text{soc}}(k)} - R_1\left(L_{SOC}(k), L \frac{\eta\Delta t I(k+L)}{L_{SOH}(k+L)C_n}\right) - U_n(k+L).$$

(32)

忽略一阶剩余项 $R_1(\cdot)$ ,根据 $U_{\min} < U_d < U_{\max}$ 得到电压限制下 $L$ 时长的持续充放电峰值电流

$$L \frac{\eta\Delta t I_{\min}^{\text{chg}}(k+L)}{L_{SOH}(k+L)C_n} \left( -\frac{k_1}{L_{SOC}(k)^2} + k_2 + \frac{k_3}{L_{SOC}(k)} - \frac{k_4}{1-L_{SOC}(k)} \right) - U_n(k+L) \Big) I_{\min}^{\text{chg}},$$

$$P_{\max}^{\text{dis}} = \min\left(P_{\max}, \left(U_{OCV}(L_{SOC}(k)) - L \frac{\eta\Delta t I_{\max}^{\text{dis}}(k+L)}{L_{SOH}(k+L)C_n} \left( -\frac{k_1}{L_{SOC}(k)^2} + k_2 + \frac{k_3}{L_{SOC}(k)} - \frac{k_4}{1-L_{SOC}(k)} \right) - U_n(k+L)\right) I_{\max}^{\text{dis}}\right). \quad (38)$$

## 2.3 基于AR-ECM的电池关键状态联合估计器

图5为完整的基于AR-ECM的电池关键状态联合估计器框架,该框架分为3个部分:

1) 模型初始化及参数更新.利用电压及电流数据区别化参数更新(见图2),形成三维状态空间方程.

2) 基于AR-ECM的SOH、SOC联合估计器.采用SR-UKF算法求解第1)部分的状态空间模型,实现SOH与SOC的联合估计.

3) SOP估计器.在第1)、2)部分基础上,实现电池长时及短时的峰值电流估算、SOP估计,最终实现基于AR-ECM的电池SOH、SOC、SOP联合估计.

## 3 实验验证与分析

### 3.1 实验数据

为了验证所提出算法的有效性和实用性,选取CALCE Battery Research Group开放数据集<sup>[17]</sup>中A123电池(规格如表1)在动态应力测试(DST)工况下的充放电数据进行验证.分AR-ECM精度验证比较,SOC、SOH比较验证以及长时、短时下的SOP验证3部分进行验证.

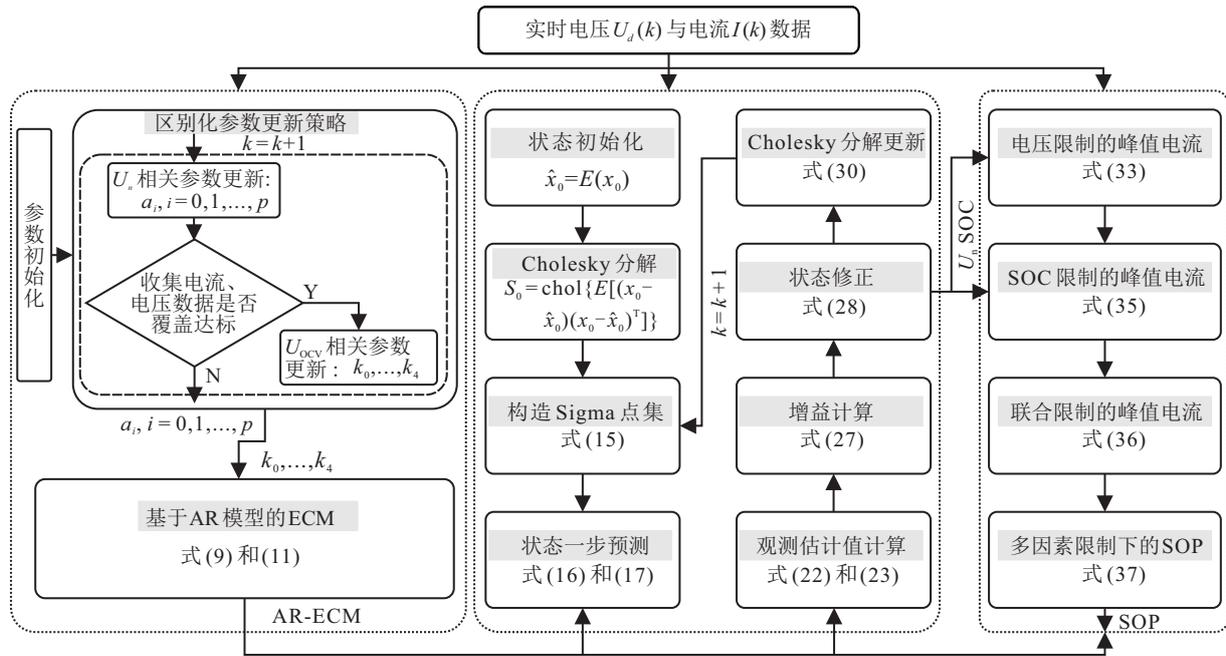


图5 基于AR-ECM的电池关键状态联合估计器框架

### 3.2 AR-ECM精度验证比较

将AR-ECM与1阶RC-ECM进行精度比较,为使验证更贴近实际,分别在电流、端电压上加入60dB白噪声,在噪声数据下对模型精度进行验证比较,结果如图6所示。

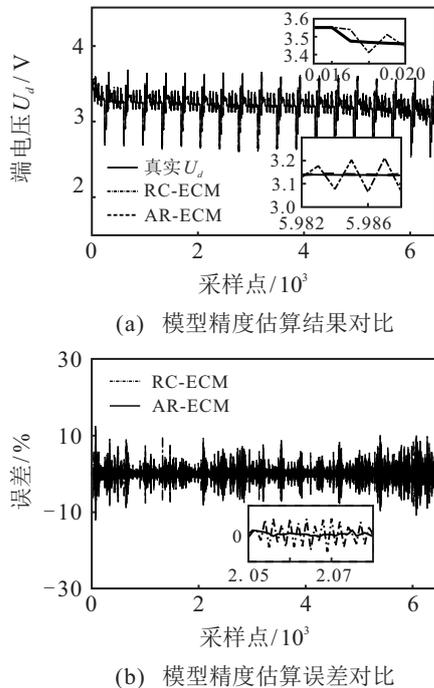


图6 噪声下AR-ECM与1阶RC-ECM精度对比结果

由图6可见,噪声环境下,AR-ECM与1阶RC-ECM精度均尚可,AR-ECM略高;但由局部放大图可见,在起始及结尾阶段,AR-ECM比1阶RC-ECM的精度更高,波动更小。分析其原因如下:放电起始及末期曲线斜率突变,由于AR-ECM具有较好的动态特

性,短时跟随能力较好,这也从侧面反映出AR-ECM更适合尖峰瞬态电流较多的应用场景。

### 3.3 SOC、SOH联合估算精度验证与比较

#### 3.3.1 SOC、SOH联合估算精度验证

在两类扰动下进行SOC、SOH估算有效性验证:

1) 白噪声扰动下的验证。在电流、端电压数据中分别加入50dB高斯白噪声,利用SR-UKF算法实现SOH、SOC联合估算。

2) 时变有色干扰下的验证。在电流、端电压中加入时变有色噪声扰动,时变有色干扰公式如下:

$$E_{cor}(t) = E_{whi}(t) + 0.5E_{whi}(t-1). \quad (39)$$

其中:  $E_{whi}(t)$  为白噪声,信噪比为50dB;  $E_{cor}(t)$  为时变有色干扰信号。

白噪声与有色扰动下的比较如图7和图8所示。White\_SOH、White\_SOC和Color\_SOH、Color\_SOC分别为白噪声扰动和有色扰动下的SOH、SOC估算结果,ErrSOH\_white、ErrSOC\_white和ErrSOH\_color、ErrSOC\_color为其估算误差。

由图7(a)和图8(a)的局部放大图可见,基于SR-UKF算法的修正,无论是高斯白噪声扰动还是时变有色扰动,均能控制在100个采样点内完成。由图7(b)可见,白噪声干扰下的误差经过波动调节后,能更接近于0基准线;但时变有色干扰下的误差始终偏离0基准线。分析其原因在于,扰动的时变性致使SR-UKF算法无法完成修正达到稳定状态,始终处于过渡过程,但两类扰动下,SR-UKF算法联合估计的SOH误差均在2%以内。同时可以看出:噪声扰动对

于电池状态估算精度的影响虽然可以适当抑制,但难以彻底消除.因此,在利用数据进行状态估算时,去噪是必要的.

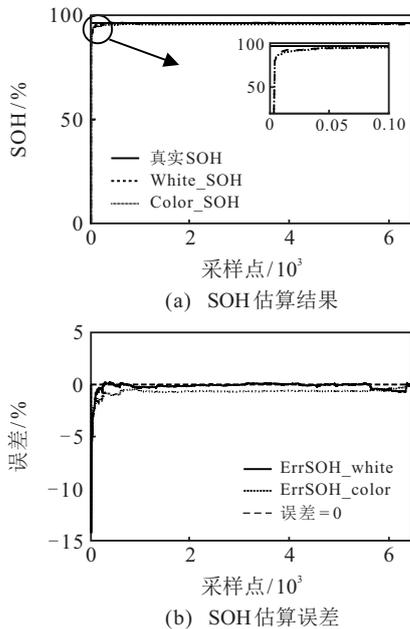


图7 噪声环境下基于AR-ECM的SOH估算

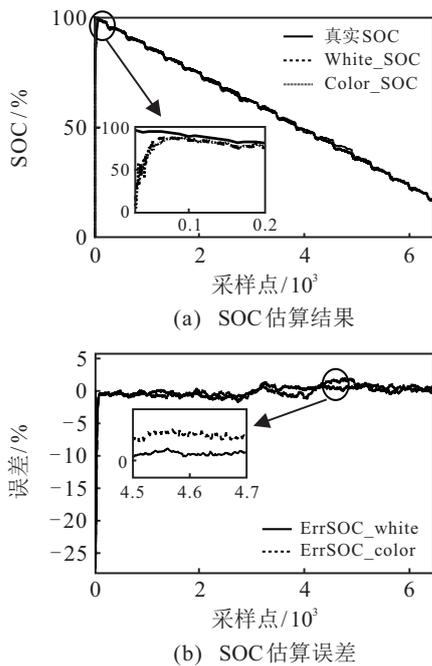


图8 噪声扰动环境下基于AR-ECM的SOC估算

图8在3000~5000处波动较大,尤其时变有色干扰下的误差波动更严重.分析其原因在于:此处为开路电压曲线的平台区域,对于电池模型精度要求极高,电压误差的微小波动将导致SOC估算误差的较大波动.在干扰环境下,大信噪比及时变有色扰动下,电池模型精度出现小幅波动,此范围的SOC估计值出现较大波动,但整体估算精度依然控制在3%以内,满足工程应用对于精度的要求.

### 3.3.2 SOC、SOH联合估算比较

将用于求解AR-ECM状态空间方程的SR-UKF算法与EKF算法进行比较,结果如表3所示

表3 SR-UKF与EKF求解状态空间方程精度对比

噪声环境	电池状态	算法	平均误差	均方根误差
高斯噪声干扰	SOC	SR-UKF	0.0048	0.0110
		EKF	0.0143	0.0180
	SOH	SR-UKF	0.0108	0.0113
		EKF	0.0182	0.0184
时变有色干扰	SOC	SR-UKF	0.0060	0.0125
		EKF	0.0104	0.0151
	SOH	SR-UKF	0.0123	0.0132
		EKF	0.0140	0.0135

由表3可知,基于SR-UKF算法的联合估计精度较基于EKF算法的联合估计精度略高.分析其原因在于,EKF算法是KF算法的扩展,其通过泰勒级数展开舍弃高阶项的方式将非线性状态方程转换为线性方程,此过程难免引入额外误差.而SR-UKF算法的核心思想是UKF,其基于随机采样原理,在非线性系统中具有更优的表现.

### 3.4 SOP估算结果验证与分析

SOP估算验证分析分为短时( $L = \Delta t$ )和长时( $L = 30s, 60s, 120s$ )两类,电池A123参数限制见表4.

表4 电池设计下的参数限制

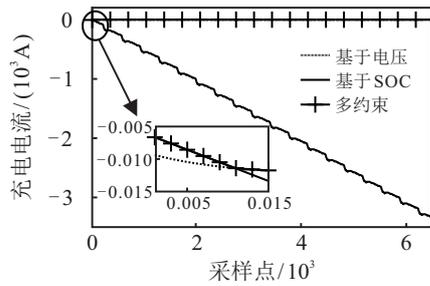
参数	最大值	最小值
SOC/%	15	100
电流 $I/A$	-30	30
电压 $U_d/V$	2	3.6

#### 3.4.1 多因素下短期SOP估计验证与比较

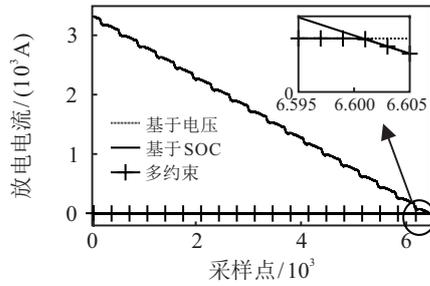
计算放电过程中单一限制下(电压、SOC)电池短时充放电峰值电流,并将其与多因素限制结果比较,如图9所示.由图9(a)的局部放大图可知:放电初期,多因素限制与SOC限制的充电峰值电流一致,而在10个采样周期后,多因素限制的充电峰值电流跟随电压限制的充电峰值电流.这说明满电时,对于电池短时峰值充电电流而言,更应考虑SOC限制,以防止电池过充.而在非满电时,更应考虑电压限制.同样由图9(b)局部放大图可知,在放电末期,放电峰值电流更应考虑SOC限制,以防止电池过放.

综上,多约束下的电池充放电电流能力计算应综合考虑SOC、电压及设计电流等多限制因素,才能更加精确.进一步,图10给出多因素限制下电池充放电峰值电流及峰值功率结果.

由图10(a)与(b)~(d)对比可知,峰值功率与峰值电流的变化趋势几乎一致,表明电池的充放电电流可以在一定程度上反应电池SOP状态.

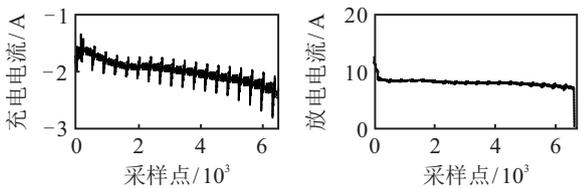


(a) 短时充电峰值电流对比

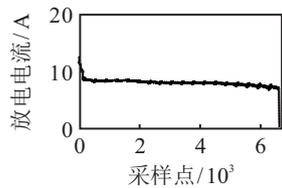


(b) 短时放电峰值电流对比

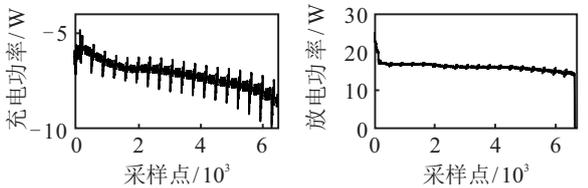
图9 短时充放电峰值电流比较结果



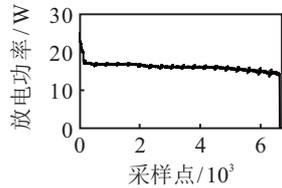
(a) 短时充电峰值电流



(b) 短时放电峰值电流

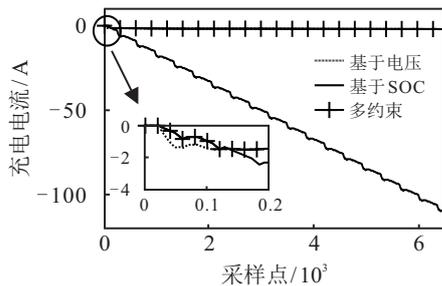


(c) 短时充电峰值功率

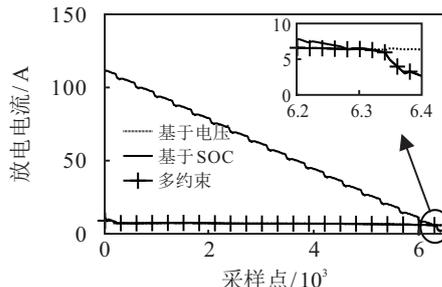


(d) 短时放电峰值功率

图10 多因素限制下短时充放电峰值能力计算结果



(a) 长时充电电流能力对比



(b) 长时放电电流能力对比

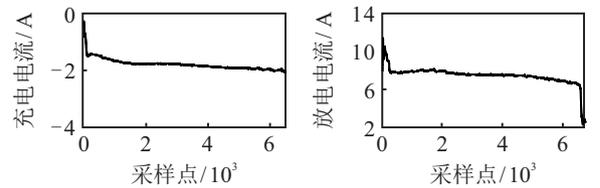
图11 长时充放电峰值电流比较结果

### 3.4.2 多因素下长期SOP估计验证与比较

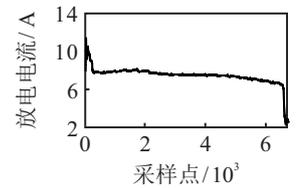
与短时 SOP 一致, 首先计算放电过程中单一限制下电池长时 ( $L = 30\text{ s}$ ) 充放电峰值电流值, 并将其与多因素限制结果比较, 如图 11 所示。

由图 11 可知: 满电时, 充电电流能力应更关注 SOC 限制; 放电末期, 放电电流能力的计算更关注 SOC 限制。综上, 为防止电池出现过充或过放故障, 在电池电量处于边界期时, 其充放电能力的估算更应关注 SOC 的限制, 在电量处于中间期时, 更应关注电池电压的限制。

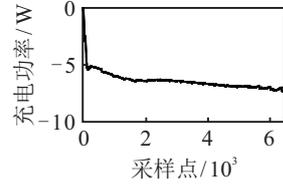
图 12 给出多因素限制下, 电池长时充放电峰值电流及功率结果。可得出与图 10 类似的结论, 峰值功率与峰值电流的变化趋势几乎一致。因此, 无论长时还是短时, 电池的充放电电流可以在一定程度上反应电池 SOP 状态。



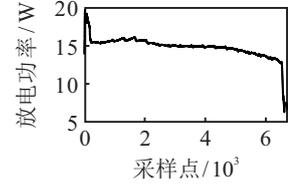
(a) 长时充电峰值电流



(b) 长时放电峰值电流

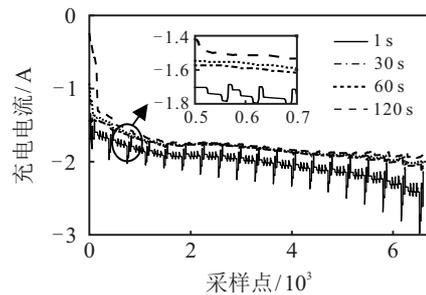


(c) 长时充电峰值功率

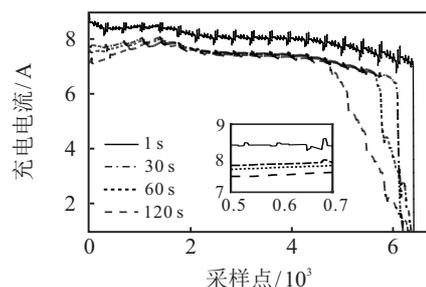


(d) 长时放电峰值功率

图12 多因素限制下长时充放电峰值能力计算结果



(a) 不同持续时间的充电电流



(b) 不同持续时间的放电电流

图13 不同持续时间下充放电电流能力对比

选取  $L = 1\text{ s}, 30\text{ s}, 60\text{ s}, 120\text{ s}$ , 对比不同时长下充放电能力特点如图 13 所示. 可见, 长期峰值功率的绝对值明显小于短期峰值功率, 这是由于在连续放电/充电过程中极化电压的绝对值持续上升<sup>[18]</sup>所致. 为了得到可靠的峰值充放电能力, 保证动力电池系统的安全性与稳定性, 需要限制电池的持续输出时间.

## 4 结论

面向电动汽车一类电池充放电随机、电流波动巨大且具有瞬态尖峰特征的应用场景, 考虑电池多状态间耦合问题, 本文提出一种基于 AR-ECM 的电池关键状态联合估计方法. 该方法首先提出 AR-ECM 全新模型结构, 并推导其状态方程, 提出区别化模型参数辨识策略; 考虑状态矩阵易不正定问题, 提出利用 SR-UKF 算法求解状态方程, 实现 SOC、SOH 的精确估计; 进一步在多因素限制下实现 SOP 长时及短时的预测计算; 最后, 基于 DST 工况的验证表明所提出的 AR-ECM 相较于 1 阶 RC-ECM, 在满电和放电末期具有更好的动态跟踪特性, 在噪声环境下具有更好的精度. 噪声环境下基于 AR-ECM 的 SOC 及 SOH 的估计具有较好的精度, 最大误差低于 2%, 具有较好的鲁棒性. 在多因素限制下 SOP 短时及长时预测中发现, 满电以及放电末期时要更关注 SOC 的限制, 而充放电的其他时期更应关注电池电压的限制问题.

## 参考文献(References)

- [1] Ling L Y, Wei Y. State-of-charge and state-of-health estimation for lithium-ion batteries based on dual fractional-order extended Kalman filter and online parameter identification[J]. IEEE Access, 2021, 9: 47588-47602.
- [2] Tian H X, Qin P L, Li K, et al. Prediction of Li-ion battery SOH based on HI-DD-AdaBoost.RT[J]. Control and Decision, 2021, 36(3): 686-692.
- [3] Rivera-Barrera J, Muñoz-Galeano N, Sarmiento-Maldonado H. SoC estimation for lithium-ion batteries: Review and future challenges[J]. Electronics, 2017, 6(4): 102.
- [4] Zhang J, Wang P, Liu Y S, et al. Variable-order equivalent circuit modeling and state of charge estimation of lithium-ion battery based on electrochemical impedance spectroscopy[J]. Energies, 2021, 14(3): 769.
- [5] Feng X N, Li J Q, Ouyang M G, et al. Using probability density function to evaluate the state of health of lithium-ion batteries[J]. Journal of Power Sources, 2013, 232: 209-218.
- [6] Stroe D I, Schaltz E. Lithium-ion battery state-of-health estimation using the incremental capacity analysis technique[J]. IEEE Transactions on Industry Applications, 2020, 56(1): 678-685.
- [7] Liu F, Liu Y P, Su W X, et al. Online estimation of

lithium-ion batteries state of health during discharge[J]. International Journal of Energy Research, 2021, 45(7): 10112-10128.

- [8] 刘新天, 李涵琪, 魏增福, 等. 基于 Drift-Ah 积分法的 CKF 估算锂电池 SOC[J]. 控制与决策, 2019, 34(3): 535-541.  
(Liu X T, Li H Q, Wei Z F, et al. CKF estimation Li-ion battery SOC based on Drift-Ah integral method[J]. Control and Decision, 2019, 34(3): 535-541.)
- [9] Xing J, Wu P. State of charge estimation of lithium-ion battery based on improved adaptive unscented Kalman filter[J]. Sustainability, 2021, 13(9): 5046.
- [10] Yang H, Sun X Z, An Y B, et al. Online parameters identification and state of charge estimation for lithium-ion capacitor based on improved cubature Kalman filter[J]. Journal of Energy Storage, 2019, 24: 100810.
- [11] Fotouhi A, Auger D J, Propp K, et al. A review on electric vehicle battery modelling: From Lithium-ion toward Lithium-Sulphur[J]. Renewable and Sustainable Energy Reviews, 2016, 56: 1008-1021.
- [12] He H W, Zhang Y Z, Xiong R, et al. A novel Gaussian model based battery state estimation approach: State-of-Energy[J]. Applied Energy, 2015, 151: 41-48.
- [13] Xiong R, Sun F C, He H W, et al. A data-driven adaptive state of charge and power capability joint estimator of lithium-ion polymer battery used in electric vehicles[J]. Energy, 2013, 63: 295-308.
- [14] Yang D, Wang Y J, Pan R, et al. State-of-health estimation for the lithium-ion battery based on support vector regression[J]. Applied Energy, 2018, 227: 273-283.
- [15] Xie K, Zhou Y Y, Xue M G, et al. Ballistic target tracking based on the square root unscented Kalman filter[J]. Journal of National University of Defense Technology, 2007, 29(2): 97-100.
- [16] Gholizade-Narm H, Charkhgard M. Lithium-ion battery state of charge estimation based on square-root unscented Kalman filter[J]. IET Power Electronics, 2013, 6(9): 1833-1841.
- [17] CALCE battery group[EB/OL]. (2021-09-08). <https://web.calce.umd.edu/batteries/data.htm>.
- [18] Hu X S, Jiang H F, Feng F, et al. An enhanced multi-state estimation hierarchy for advanced lithium-ion battery management[J]. Applied Energy, 2020, 257: 114019.

## 作者简介

刘芳(1983—), 女, 副教授, 博士, 从事新能源车系统状态在线分析与优化、电池管理系统等研究, E-mail: lf@tiangong.edu.cn;

邵晨(1997—), 女, 硕士生, 从事电池状态预测、电池管理系统的研究, E-mail: shaochen1118@163.com;

苏卫星(1980—), 男, 教授, 博士, 从事制造物联、智能工厂技术、工业大数据等研究, E-mail: suweixing@tiangong.edu.cn;

刘阳(1979—), 男, 工程师, 博士, 从事新能源汽车电控系统开发的研究, E-mail: 95118748@qq.com.