

基于快速 SR-UKF 的锂离子动力电池 SOC 联合估计

章军辉^{1,2,3,4}, 李庆^{1,2,4}, 陈大鹏^{1,2,3,4}, 赵野¹

(1.中国科学院微电子研究所, 100029, 北京; 2.江苏物联网研究发展中心, 214135, 江苏无锡;

3.无锡物联网创新中心有限公司, 214135, 江苏无锡; 4.中科院微电子研究所昆山分所, 215347, 江苏昆山)

摘要: 针对标准 UKF 算法本身存在着因状态误差协方差矩阵无法实现 Cholesky 分解而导致滤波发散的隐患, 以及在电池状态估计过程中由离线标定的电池等效模型参数而造成的累积误差的问题, 本文发展了一种平方根无迹卡尔曼滤波 (square-root unscented Kalman filter, SR-UKF) 算法, 并设计了一种电池状态联合估计策略。① 快速 SR-UKF 算法通过对观测方程进行准线性化处理, 降低了每次无迹变换时的计算开销; ② 在迭代过程中, 用状态误差协方差矩阵的平方根代替状态误差协方差矩阵, 该平方根是由 QR 分解与 Cholesky 因子的一阶更新得到, 解决了 UKF 算法迭代过程中可能由计算累积误差引起状态误差协方差矩阵负定而导致滤波结果发散的问题, 保证了电池荷电状态 (state of charge, SOC) 在线滚动估计的数值稳定性; ③ 采用联合估计策略, 对电池等效模型参数进行实时辨识, 保证了电池等效模型的准确性与有效性, 从而提高了电池 SOC 的估计精度。仿真对比结果验证了快速 SR-UKF 算法以及电池状态联合估计策略的可行性与鲁棒性。

关键词: 荷电状态; 健康状态; 平方根无迹卡尔曼滤波; 联合估计; 锂离子动力电池

中图分类号: TM912.9 **文献标志码:** A **文章编号:**

Real-time SOC Co-Estimation Algorithm for Li-ion Power Batteries Based on Fast Square-Root Unscented Kalman Filters

(1. Institute of Microelectronics of Chinese Academy of Sciences, Beijing 100029, China; 2. Jiangsu R&D Center for Internet of Things, Jiangsu Wuxi 214135, China; 3. Wuxi Internet of Things Innovation Center Co., Ltd., Jiangsu Wuxi 214135, China; 4. Kunshan Department, Institute of Microelectronics, Chinese Academy of Sciences, Suzhou Kunshan 215347, China)

Abstract: Li-ion power battery is an important energy source for electric vehicles (EVs). Accurate battery state estimation provides a reliable reference for battery packing and battery management system (BMS) balancing, and meanwhile it is of great practical significance to make full and reasonable utilization of battery, and improve battery life cycle as well as vehicle operation efficiency. Upon the practical issues such as filtering divergence caused by non-positive definite error covariance matrix in standard unscented Kalman filter (UKF) and accumulative state estimation errors due to the simplified mathematical modeling of li-ion power battery who has inherent features of strong non-linearity, time-variety as well as uncertainty, a real-time states co-estimation algorithm that is based on fast square-root unscented Kalman filter framework is thus proposed in this article. Firstly, during the iteration process, the non-linear measurement function which describes the propagation of each sigma point is called by unscented transform (UT) at iteration step. And the reduction of computational complexity could be achieved providing that the non-linear measurement function is quasi-linearized. Secondly, instead of state error covariance matrix, the square root of the state error covariance matrix, which can be obtained by QR decomposition and first-order updating of Cholesky factor is employed so as to deal with the problem that the state error covariance matrix may be negative definite caused by the accumulative computational errors while performing the recursive estimation in the standard UKF, and then the numerical stability of battery state of charge (SOC) estimation in real time can be well-guaranteed. Thirdly, the inner ohmic resistance as well as nominal capacity which could characterize the state of health (SOH) indirectly can be estimated online, and

收稿日期: 2020-7-30; 录用日期: 2020--

作者简介: 章军辉(1985-), 男, 在站博士后; 李庆, 男, 研究员, 博士生导师; 赵野, 男, 研究员, 博士生导师; 陈大鹏(通信作者), 男, 研究员, 博士生导师。本文受江苏省博士后科研资助计划(2020Z411), 国家重点研发计划“新能源汽车专项”(2016YFB0100516)资助。

accordingly a high-precision estimation of SOC is able to be realized owing to the accuracy and efficiency of the battery model. The comparative experimental results confirmed and validated the feasibility and robustness of the fast SR-UKF algorithm as well as co-estimation strategy suggested.

Keywords: state of charge; state of health; square-root unscented Kalman filter; co-estimation strategy; li-ion power battery

引言

锂离子动力电池是新能源电动汽车的重要供能来源,而电池生产工艺上的波动、材质本身的不均匀性,使得单体电池的容量、内阻、自放电特性等皆有一定的差异,并且随着充放电循环次数的增加以及车内特殊工作环境的影响,电池容量也会出现不同程度的衰减,进一步加剧了单体之间的差异性。准确的电池状态估计为电池成组、电池管理系统(battery management system, BMS)均衡等用途提供可靠参考依据,从而对单体电池的充分利用、电池组使用寿命的延长以及整车运行效率的改善具有重要实际意义^[1-2]。

电池状态估计本身属于非线性估计问题,而针对非线性问题求解,常用手段包括非线性函数局部线性化^[3-4]、概率密度分布逼近法^[5-6]、神经网络法^[7-8]等。其中,非线性函数局部线性化的主要方法有 Taylor 展开法^[3]、插值多项式法^[4]; 概率密度分布逼近的主要方法有确定性样本逼近法^[5]、大量粒子逼近法^[6]。

目前,电池荷电状态(state of charge, SOC)估计方法主要有:(1)安时积分计量(ampere-hour counting, AH)法^[9],应用较广,不过算法本身缺少对内外在扰动因素进行补偿的措施,存在由 SOC 初值标定偏差而导致曲线始终不能收敛、计算累积误差等问题;(2)开路电压(open circuit voltage, OCV)法^[10-11],通过“浅放-静置”的方法拟合出 OCV 与 SOC 一一映射曲线,实现对 SOC 初值进行离线校正,其因需较长的静置时间而无法用于在线工况,一般是与其它方法结合使用;(3)扩展卡尔曼滤波(extended Kalman filter, EKF)法^[12],仅利用 Taylor 展开式中的一阶偏导项对非线性函数

进行线性化处理,再基于 KF 框架完成状态估计,存在较低的截断精度、Jacobian 矩阵计算繁杂、滤波性能不稳定等问题;(4)无迹卡尔曼滤波(unscented Kalman filter, UKF)法^[13],通过构造满足一定规则的确性样本来逼近非线性系统的后验概率密度分布,相对 EKF 来说,其估计精度有明显改善,不过 UKF 无法保证滤波过程中状态误差协方差矩阵的非负定性,存在滤波发散的隐患,同时其估计精度也一定程度上受限于电池等效模型的准确性。(5)粒子滤波(particle filter, PF)法^[14],通过大量随机粒子来逼近非线性系统的后验概率密度分布,对于强非线性、非高斯系统具有潜在应用价值,不过 PF 存在粒子退化、重采样导致的样本贫化、计算负荷严重等问题。(6)神经网络法^[8],通过神经网络学习的方法建立未知系统的非线性映射关系,无需准确的数学建模、非线性近似工作,可适用于各类电池的状态估计,不过其估计精度对数据集的依赖性较强。

目前,电池健康状态(state of health, SOH)估计方法主要概括为两大类:(1)基于特征的预测,通过建立容量、内阻等特征参数与电池寿命之间的对应关系,间接地对电池的老化程度进行预测。如内阻法^[15],然对于毫欧级的内阻来说,其量测难度较大;电化学阻抗谱(Electrochemical Impedance Spectroscopy, EIS)法^[16],需专用仪器,常用于实验室分析。(2)基于数据驱动的预测,不需要对象系统的机理知识,利用测试数据挖掘出描述电池性能演变的潜在规律,进而对电池使用寿命进行预测。如支持向量机(support vector machine, SVM)^[17]、粒子滤波^[14]、神经网络^[8]等,该类方法通常由于

实验数据的有限性、不确定性，而致使其在工程应用上存在着一定的局限性。

针对标准 UKF 算法本身存在着因状态误差协方差矩阵无法实现 Cholesky 分解而导致滤波发散的隐患，以及在电池状态估计过程中由离线标定的电池等效模型参数而造成的累积误差的问题，本文发展了一种基于快速 SR-UKF 的电池状态联合估计算法，首先构建二阶 RC 等效模型的状态空间方程，其次在循环迭代过程中对观测方程进行了准线性化处理，同时用状态误差协方差矩阵的平方根进行迭代运算，以防协方差矩阵负定而致滤波发散，接着设计了一种电池状态联合估计策略，对电池模型参数进行实时辨识，以确保电池等效模型的准确性与有效性，最后对本文设计的快速 SR-UKF 算法以及联合估计策略进行了验证与探讨。

1 数学建模

锂离子动力电池的二阶 RC 等效模型，能够较好地模拟电池的静动态特性，结构复杂度相对适中，便于电池特性分析，本文将采用二阶 RC 等效模型建立电池状态空间方程。




图1 锂离子动力电池的二阶 RC 等效模型

Fig.1 2nd order RC model of Li-ion battery

二阶 RC 等效电路如图 1 所示，其中， E_t 为电池的电动势，其测量方法可通过长时间静置使得电池内部处于平衡状态，此时量测出电池的端电压在数值上等于电池的平衡电动势， I_t 为电池的放电电流， R_e 为电池的欧姆内阻， R_s 、 R_l 为电池的极化内阻， C_s 、 C_l 为电池的极化电容， $U_{cs,t}$ 、 $U_{cl,t}$ 为电池极化内阻上产生的压降， $U_{o,t}$ 为电池两端的观测电压。

1.1 电池 SOC 状态空间模型

根据图 1 所示的电池模型，作如下定义

$$I_t = \frac{1}{R_s} U_{cs,t} + \frac{\tau_s}{R_s} \dot{U}_{cs,t} \quad (1)$$

$$I_t = \frac{1}{R_l} U_{cl,t} + \frac{\tau_l}{R_l} \dot{U}_{cl,t} \quad (2)$$

$$E_t = R_e I_t + U_{cs,t} + U_{cl,t} + U_{o,t} \quad (3)$$

式中， τ_s 、 τ_l 为时间常数。

电池荷电状态的安时积分计量法^[6]定义为

$$S_t = S_{t_0} - \frac{1}{Q_0} \int_{t_0}^t \eta I_t dt \quad (4)$$

式中， S_{t_0} 为电池 t_0 时刻的荷电状态，即 SOC 初始值， Q_0 为电池的额定容量， η 为充放电效率。

以 $\mathbf{x}_1(k) = [S(k), U_{cs}(k), U_{cl}(k)]^T$ 作为状态向量， $y_1(k) = U_o(k)$ 作为系统输出， $u(k)$ 作为控制输入， $w(k)$ 、 $v(k)$ 作为系统扰动，根据式 (1)、式(2)、式(3)、式(4)，建立以 $\mathbf{x}_1(k)$ 为状态向量的一步预测的离散状态空间方程：

$$\begin{cases} \mathbf{x}_1(k+1|k) = \mathbf{A}\mathbf{x}_1(k) + \mathbf{B}u(k) + \mathbf{w}(k) \\ y_1(k) = \mathbf{C}\mathbf{x}_1(k) + Du(k) + v(k) \end{cases} \quad (5)$$

式中， $\mathbf{w}(k) = [w_1(k), w_2(k), w_3(k)]^T$ 为过程噪声， $v(k)$ 为观测噪声， $u(k) = I(k)$ ，各系数矩阵满足

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-T_s/\tau_s} & 0 \\ 0 & 0 & e^{-T_s/\tau_l} \end{bmatrix}$$

$$\mathbf{B} = \begin{bmatrix} \frac{-\eta T_s}{Q_0} \\ R_s(1 - e^{-T_s/\tau_s}) \\ R_l(1 - e^{-T_s/\tau_l}) \end{bmatrix}$$

$$\mathbf{C} = \left[\frac{1}{S(k)} f\{S(k)\}, -1, -1 \right]$$

$$D = -R_e$$

其中， $E_t = f\{S(k)\}$ 表示电池的平衡电动势 E_t 与

电池 SOC 之间的函数关系，该映射关系与环境温度、锂电池老化程度等因素有关。在电池 SOC 状态空间模型中，欧姆内阻 R_e 、极化内阻 R_l 与 R_s 是事先已辨识的模型参数。

1.2 电池 SOH 状态空间模型

锂电池的健康状态可通过电池的欧姆内阻 R_e 来间接评估^[18]。根据图 1 所示的电池模型，把电池的荷电状态、极化电压当作已知值，作如下定义

$$R_{e,t+1} = R_{e,t} + r_t \quad (6)$$

$$E_t = R_{e,t} I_t + U_{cs,t} + U_{cl,t} + U_{o,t} + q_t \quad (7)$$

式中， r_t 为过程噪声， q_t 为观测噪声。

令 $x_2(k) = R_e(k)$ ，建立以 $x_2(k)$ 为状态变量的一步预测的离散状态空间方程：

$$\begin{cases} x_2(k+1|k) = x_2(k) + r(k) \\ y_2(k) = E x_2(k) + F + q(k) \end{cases} \quad (8)$$

式中，各系数满足

$$E = -I(k)$$

$$F = f\{S(k)\} - U_{cs}(k) - U_{cl}(k)$$

2 参数辨识

本文实验对象是合肥国轩公司的一个电池组，内含 12 串单体，每个单体标称容量为 30Ah。在 25℃ 环境温度下，对该电池包进行“浅放-静置”的恒流脉冲放电试验：放电倍率为 0.6C，放电电流恒为 18A，单次放电时长为 1 分钟并静置 30 分钟，重复该操作直至放完。一个脉冲放电周期内的单体端电压变化过程如图 2 所示。

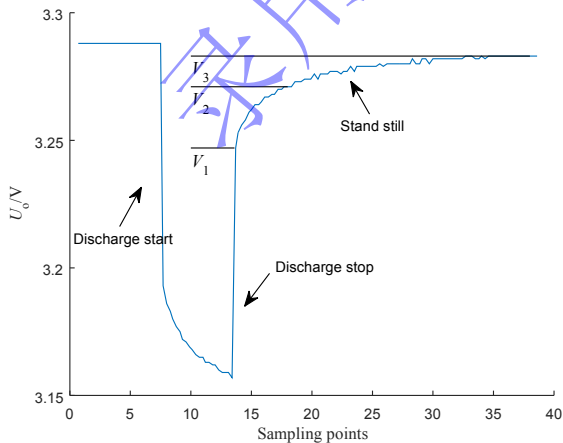


图 2 一个脉冲放电周期内单体端电压响应曲线

Fig.2 Dynamic curve of U_o in a pulse-periodic discharge

利用 RC 网络能够较好地描述电池的放电过程中的动态特性：

(1) 在放电开始时刻，由于欧姆内阻上产生的压降，导致端电压瞬间抖降，随后由于给等效电容进行充电，端电压呈准指数函数下降；

(2) 在放电结束时刻，由于欧姆内阻上的压降消失，导致端电压瞬间抖升，随后由于等效电容放电使得端电压进一步缓慢上升，最终趋于稳定，其中， V_2-V_1 表示端电压相对快速的变化过程， V_3-V_2 表示端电压相对缓慢的变化过程。

2.1 模型参数

通过图 2 所示的“浅放-静置”的恒流脉冲放电试验，对二阶 RC 网络模型参数进行辨识，模型参数初值见表 1。

表 1 基于二阶 RC 网络的模型参数

Table 1 Parameters of 2nd order RC model

$R_o/m\Omega$	$R_s/m\Omega$	$R_l/m\Omega$	Q_0/Ah	C_s/F	C_l/F
5.9	2.0	3.8	29.3	36000	68400

2.2 OCV-SOC 曲线

在上述实验条件下，采用开路电压法^[10]拟合出静置稳定后的开路电压与电池 SOC 之间的映射关系曲线，如图 3 所示。




图 3 开路电压与 SOC 的关系曲线

Fig.3 Relationship between open circuit voltage and SOC

通过图 3 映射关系可以为电池组提供一个相对准确的 SOC 初值，同时也可以对长时间静置后的电池进行 SOC 初值校正。标定完 SOC 初值后，再通过安时积分计量法^[9]来在线估算电池 SOC。而实际上由于安时积分计量法属于一种开环估计方法，当 SOC 初值标定不准的情况下，估计曲线始终是无法收敛于真实轨迹。

对于这一问题，接下来通过无迹卡尔曼滤波对安时积分计量法的估计值进行实时修正，以改善开环估算的效果。此外，考虑到电池老化、环境温度等扰动因素的影响，在工程实施时，宜拟合出多份 OCV_SOC 曲线。

3 电池状态估计

3.1 电池 SOC 估计算法

UKF 滤波的核心是 UT 变换，即通过确定性采样构造 Sigma 点集来近似系统非线性函数的概率密度分布进而求解非线性滤波问题。不过，传统 UKF 算法在更新状态协方差时存在减法运算，不能保证协方差矩阵的非负定性，存在滤波发散的隐患。

为此，本文给出一种快速 SR-UKF 估计方法：在 UKF 滤波过程中，使用状态误差协方差矩阵的平方根进行迭代运算，以避免协方差矩阵负定而致滤波结果发散的缺陷^[19-21]；为了降低 UKF 的计算开销，在 UT 变换时对观测方程进行准线性化处理，建立开路电压与电池 SOC 的映射表，通过查表方法来减少对观测方程的数值计算。

3.1.1 定义

定义 1. QR 分解

若存在正定矩阵 $\mathbf{Q}_{m \times m}$ 与上三角矩阵 $\mathbf{R}_{m \times n}$ ，使得 $\mathbf{A}_{m \times n} = \mathbf{Q}_{m \times m} \mathbf{R}_{m \times n}$ ，则称之为 \mathbf{A} 的 QR 分解，且记 $\mathbf{R} = qr\{\mathbf{A}\}$ 。

定义 2. Cholesky 因子

由定义 1 知， \mathbf{A}^T 的 QR 分解，即 $\mathbf{A}^T = \tilde{\mathbf{Q}}\tilde{\mathbf{R}}$ ，若矩阵 $\mathbf{P} = \mathbf{A}\mathbf{A}^T$ ，有 $\mathbf{P} = \tilde{\mathbf{R}}^T \tilde{\mathbf{Q}}^T \tilde{\mathbf{Q}}\tilde{\mathbf{R}} = \tilde{\mathbf{R}}^T \tilde{\mathbf{R}}$ ，则称 $\tilde{\mathbf{R}}$ 为 \mathbf{P} 的 Cholesky 因子，记为 $\tilde{\mathbf{R}} = chol\{\mathbf{P}\}$ 。

定义 3. Cholesky 因子的一阶更新

由定义 2 知，若已知 \mathbf{P} 的 Cholesky 因子为 $\tilde{\mathbf{R}}$ 则称 $\mathbf{P} \pm \sqrt{v}\mathbf{u}\mathbf{u}^T$ 的 Cholesky 因子为 $\tilde{\mathbf{R}}$ 的一阶更新，记为 $\tilde{\mathbf{R}} = cholupdate\{\tilde{\mathbf{R}}, \mathbf{u}, \pm v\}$ 。

3.1.2 SR-UKF 算法

算法设计如下：

(1) UT 变换

a) 构造 $2N+1$ 维 Sigma 点集

利用随机向量的均值与协方差平方根来构造 Sigma 点集

$$\mathbf{X}_i = \left[\bar{\mathbf{x}} \quad \bar{\mathbf{x}} + \sqrt{(N+\lambda)} \mathbf{S}_x \quad \bar{\mathbf{x}} - \sqrt{(N+\lambda)} \mathbf{S}_x \right] \quad (9)$$

式中， $\bar{\mathbf{x}}$ 、 \mathbf{S}_x 分别为式(5)所示模型中 $\mathbf{x}_1(k)$ 的均值、状态误差协方差的 Cholesky 因子， λ 为设计参数。

为了更好地逼近系统状态的后验分布情况，对 Sigma 点集进行权值设计

$$\begin{cases} w_i^m = w_i^c = 0.5 / (N + \lambda) & , i \in (1, 2N) \\ w_0^m = \lambda / (N + \lambda) \\ w_0^c = \lambda / (N + \lambda) + (1 - \alpha^2 + \beta) \end{cases} \quad (10)$$

式中， α 是用来描述 Sigma 点集的偏离程度，取值范围为 $(10^{-4}, 1)$ ； β 是用来描述系统状态的分布情况，在高斯分布情况下取 2； $\lambda = \alpha^2(N+k) - N$ ，影响逼近精度，其中，参数 k 通常取 0。

b) 对 Sigma 点集进行非线性变换

将 a) 中构造的 Sigma 点集，代入式(5)中得

$$\begin{cases} \mathbf{X}_i^- = f\{\mathbf{X}_i\} \\ \mathbf{Y}_i^- = h\{\mathbf{X}_i\} \end{cases} \quad (11)$$

式中， $f\{\cdot\}$ 、 $h\{\cdot\}$ 分别表示系统状态方程、观测方程的映射关系， \mathbf{X}_i^- 、 \mathbf{Y}_i^- 分别为点集 \mathbf{X}_i 的状态预测、系统输出，其中， $h\{\cdot\}$ 是通过查表的方法对观测方程进行准线性化处理。

(2) 迭代算式

假设过程噪声 $\mathbf{w}(k)$ 服从 $N(0, \mathbf{Q})$ 分布，观测噪声 $\mathbf{v}(k)$ 服从 $N(0, R)$ 分布。

a) 预测更新过程为

$$\begin{cases} \bar{\mathbf{x}} = \sum_{i=0}^{2N} \omega_i^m \mathbf{X}_i^- \\ \bar{\mathbf{y}} = \sum_{i=0}^{2N} \omega_i^m Y_i^- \\ \mathbf{S}_x = qr \left\{ \left[\sqrt{\omega_i^c} [\mathbf{X}_{i=1:2N}^- - \bar{\mathbf{x}}] \quad \sqrt{\mathbf{Q}} \right] \right\} \\ \mathbf{S}_x = cholupdate \left\{ \mathbf{S}_x, [\mathbf{X}_0^- - \bar{\mathbf{x}}], \omega_0^c \right\} \end{cases} \quad (12)$$

b) 观测更新过程为

$$\begin{cases} \mathbf{P}_{xy} = \sum_{i=0}^{2N} \omega_i^c [\mathbf{X}_i^- - \bar{\mathbf{x}}] [Y_i^- - \bar{\mathbf{y}}]^T \\ \mathbf{S}_y = qr \left\{ \left[\sqrt{\omega_i^c} [Y_{i=1:2N}^- - \bar{\mathbf{y}}] \quad \sqrt{R} \right] \right\} \\ \mathbf{S}_y = cholupdate \left\{ \mathbf{S}_y, [Y_0^- - \bar{\mathbf{y}}], \omega_0^c \right\} \\ \mathbf{G} = (\mathbf{P}_{xy} / \mathbf{S}_y^T) / \mathbf{S}_x \\ \hat{\bar{\mathbf{x}}} = \bar{\mathbf{x}} + \mathbf{G} [Z - \bar{\mathbf{y}}] \\ \hat{\mathbf{S}}_x = cholupdate \left\{ \mathbf{S}_x, \mathbf{G} \mathbf{S}_y, -1 \right\} \end{cases} \quad (13)$$

式中， Z 是观测值， \mathbf{G} 是卡尔曼增益，用于动态调整状态预测与观测残差之间的权重分配， $\hat{\bar{\mathbf{x}}}$ 、

$\hat{\mathbf{S}}_x$ 为最优估计结果。

与标准 UKF 算法相比，本文设计的快速 SR-UKF 算法通过准线性化处理降低了 UT 变换过程中的计算开销，同时在迭代过程中，用协方差矩阵的平方根代替协方差矩阵，该平方根是由 QR 分解与 Cholesky 因子的一阶更新得到，解决了 UKF 算法迭代过程中可能由计算累积误差引起协方差矩阵负定而导致滤波结果发散的问题，保证了电池 SOC 在线滚动估计的数值稳定性。

3.1.3 SOC 初值校准

工程上，对 SOC 初值的校准工作是非常有必要的，一则可有效避免估计误差的累积效应，进一步改善估计精度；二则可使估计结果更平滑，且能快速收敛于期望轨迹。

方式 1，在电池满充时，将 SOC 校准为

100%；

方式 2，长时间静置后，根据当前温度选取相应的 OCV-SOC 映射表来校准。

3.2 电池 SOH 估计策略

单体不一致性、监测误差、环境因素等给 BMS 均衡带来了较大的技术难度，严重时会引起容量低的单体过充过放，进一步加剧了单体之间的一致性，从而及时了解电池组中各单体的健康状态，并及时更换掉老化的单体，对延长电池组的整体寿命具有实际意义。

随着充放电循环次数的增加，电池欧姆内阻会缓慢增大，电池标称容量也会逐渐衰减，且衰减达 20% 时电池报废^[22]。因此，可以通过电池欧姆内阻、电池最大可用容量来间接地表征电池的 SOH 健康状态。

3.2.1 基于欧姆内阻的 SOH 估计

与电池 SOC 估计方法类似，仅需将式(5)所示的模型换成式(8)所示的模型，即可实现欧姆内阻的在线滚动估计。

再利用欧姆内阻对电池 SOH 进行间接量化，其数学描述^[23]为

$$SOH = \frac{R_{EOL} - R_e}{R_{EOL} - R_0} \times 100\% \quad (14)$$

式中， R_{EOL} 为电池寿命终结时的阻抗值， R_0 为电池出厂时的阻抗值， R_e 为在线辨识的阻抗值。

3.2.2 基于电池容量的 SOH 估计

车用锂离子动力电池常用恒流转恒压的充电方式，恒流充电时电流恒定，这样安时积分计量法的估算误差较小，可以利用该特点实现对电池

总容量的校准。

假设电池 t_1 时刻处于静置状态， S_{t_1} 为 t_1 时刻由开路电压得到的 SOC 值， S_{t_2} 为恒流充电至 t_2 时刻且静置一段后，由开路电压得到的 SOC 值。

$$Q_{\text{present}} = \frac{Q_{\text{in}}}{S_{t_2} - S_{t_1}} \quad (15)$$

式中， Q_{present} 为当前电池最大可用容量， $Q_{\text{in}} = \int_{t_1}^{t_2} \eta I dt$ 为充入电量，其中， η 为充放电效率， I 为恒流充电电流。

再利用电池最大可用容量对电池 SOH 进行间接量化，其数学描述为

$$SOH = \frac{Q_{\text{present}}}{Q_0} \times 100\% \quad (16)$$

式中， Q_0 为电池出厂时的额定容量。

3.3 电池状态联合估计策略

在实际工程中，考虑到电池老化、温度等因素的影响，有必要对电池等效模型参数 R_e 、 Q_0 进行

在线校准，以保证电池 SOC 的估计精度，而较高的 SOC 估算精度又将进一步改善 SOH 估计效果以及 BMS 管理^[24-25]。

为此，设计了一种联合估计策略，如图 4 所示。该策略充分考虑了电池 SOC 与 SOH 之间紧密的内在关联性，实时辨识与修正离线标定的电池模型参数，能够较好地解决模型参数的时变问题，保证了电池等效模型的准确性与有效性。同时对 SOC 初值进行有条件校准，以期避免累积误差，提高收敛速度。

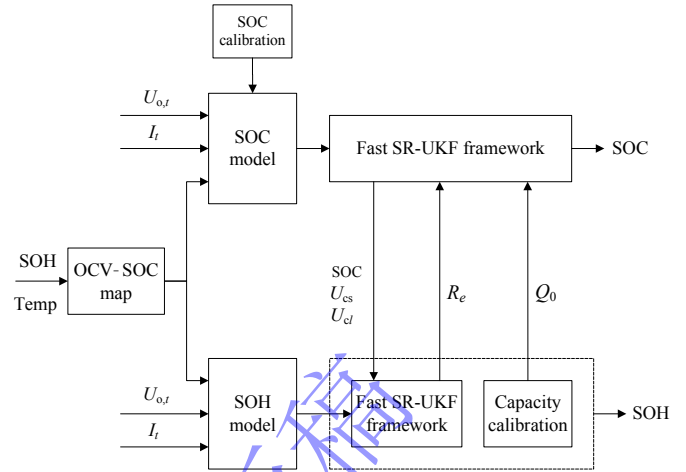


图 4 电池 SOC、SOH 联合估计策略

Fig.4 SOC and SOH co-estimation strategy

4 仿真验证

本文设计的快速联合估计算法记为 SR-UKF 联合估计，二阶 RC 网络模型参数的初值见表 1，对比实验如下。

(I) SR-UKF 联合估计与标准 UKF 估计对比

文献[4]表明，锂离子电池的欧姆内阻阻值变化受环境温度以及电池 SOC 的影响，当环境温度或电池 SOC 较高时，电池的活性增强，从而欧姆内阻阻值较小，反之亦然。

实验条件：

① 放电实验过程中，将恒温箱温度由 25℃ 缓慢升至 30℃，采样周期为 30 秒。




图5 SR-UKF 联合估计与标准 UKF 估计曲线对比

Fig.5 Comparison of SR-UKF and UKF estimation




图6 SR-UKF 联合估计与标准 UKF 估计误差曲线对比

Fig.6 Comparison of SR-UKF and UKF estimation error

SR-UKF 联合估计与标准 UKF 估计^[10]的仿真对比如图 5 与图 6 所示。SR-UKF 联合估计的最大误差约 1.4%，且误差曲线呈收敛趋势，而标准 UKF 估计误差曲线的收敛性较差，从而 SR-UKF 联合估计优势相对明显，能够较好地适应电池等效模型参数的时变特性。

(2) 估计曲线的收敛性对比

实验条件：

① 常温环境下，采用恒流放电方式，采样周期为 30 秒；

② SOC 真实值为 98%，而初值标定为 93%。

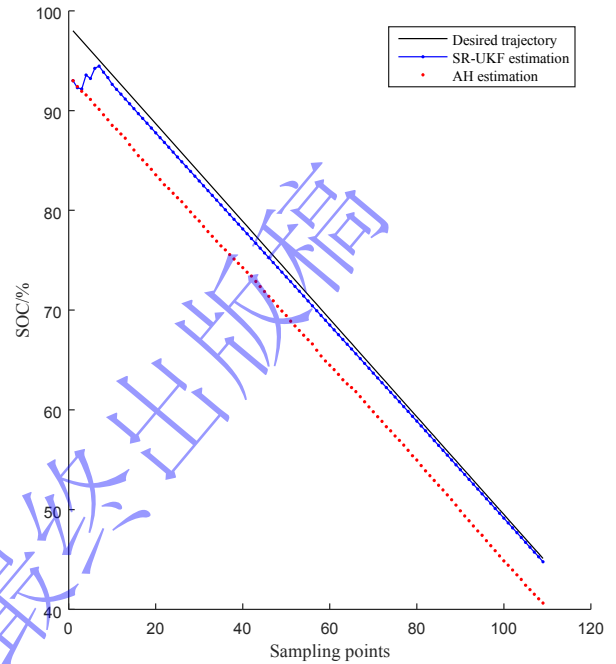


图7 SOC 初值标定偏差为 5%情况下的 SOC 估计曲线对比

Fig.7 Comparison of SOC estimation when the calibration deviation of SOC initial value is 5%

如图 7 所示，在 SOC 初值标定偏差为 5%的情况下，由于 AH 安时计量法是开环估计，从而滤波过程中 AH 估计曲线始终不能收敛于期望轨迹，而采用闭环的 SR-UKF 估计能够较好解决 AH 估计因 SOC 初值标定不准而引入的估计误差问题。

(3) 电池内阻估计

如图 8 所示，电池模型参数中欧姆内阻初值标定分别为 5mΩ、8mΩ 的情况下，经过 SR-UKF 迭代运算，两条估计曲线的变化趋势几近一致，即由内阻初值偏差而引入的扰动对估计结果的影响并不明显。此外，在电池放电初始阶段，由于电池放电产生的热量，使得内阻阻值出现略微减小的过程，而当电池 SOC 较低时，内阻阻值显著增大。

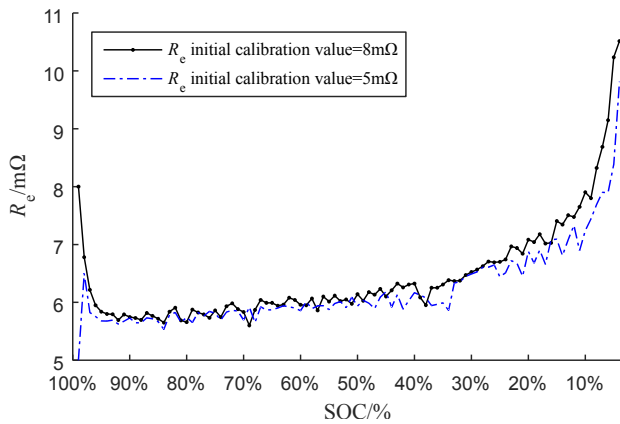


图8 电池内阻估计曲线

Fig.8 Comparison of li-ion battery inner resistance

前文中，图2已描述了一个脉冲放电周期内单体端电压的变化过程，在放电瞬间端电压由于欧姆内阻上产生的压降而发生抖降现象。进一步，图9描述的是端电压的峰值与谷值压差变化曲线，当SOC较低后，由于放电过程的端电压下降的幅度将显著高于静置过程的端电压所能回弹的幅度，从而压差曲线呈上升趋势。




图9 放电过程中端电压的峰谷压差曲线

Fig.9 Peak-valley difference of terminal voltage during the process of discharge

(4) 电池额定容量标定

由于恒流充电时电流相对恒定，这样安时积分计量法的估算误差较小，再通过式(15)对电池额定容量进行校准，以降低初始估计偏差。

本实验所用电池包中，最低单体电池额定容量 Q_0 的标定结果约为 29.3Ah，说明单体容量已有

一定程度的衰减了。为此，基于图4所示的联合估计策略对 Q_0 进行定期在线更新，保证电池等效模型的准确性与有效性是有必要的。

(5) 实车工况验证

实验条件：

① 试验车为安凯纯电动公交车，试验场地在定远国家汽车试验场，单体的标称容量为 200Ah，采样周期为 0.5 秒，试验车的整个电流工况如图 10 所示；

② SOC 真实值为 99%，而初值标定为 95%。




图10 试验车的电流工况

Fig.10 Currency curve of test vehicle




图11 SOC初值标定偏差为4%情况下的SOC估计曲线对比

Fig.11 Comparison of SOC estimation when the calibration deviation of SOC initial value is 4%

如图 11 所示, 在 SOC 的初值标定偏差为 4% 的情况下, 相比 AH 估计法, SR-UKF 估计曲线能够快速收敛于期望轨迹, 实车工况进一步验证了 SR-UKF 估计算法的有效性。

5 结论

针对标准 UKF 算法本身存在着因状态误差协方差矩阵无法实现 Cholesky 分解而导致滤波发散的隐患, 以及在电池状态估计过程中由离线标定的电池等效模型参数而造成的累积误差的问题, 本文设计了一种快速 SR-UKF 算法以及电池状态联合估计策略, 主要结论如下。

(1) 快速 SR-UKF 算法通过对观测方程进行线性化处理, 降低了 UT 变换过程中的计算开销; 同时采用闭环设计避免了工程上 AH 开环估计不能收敛的缺陷。

(2) 在 SR-UKF 迭代过程中, 用协方差矩阵的平方根代替协方差矩阵, 该平方根是由 QR 分解与 Cholesky 因子的一阶更新得到, 解决了标准 UKF 算法迭代过程中可能由计算累积误差引起协方差矩阵负定而导致滤波结果发散的问题, 保证了电池 SOC 在线滚动估计的数值稳定性。

(3) 联合估计策略充分考虑了电池 SOC、电池容量以及内阻之间紧密的内在关联性, 能够较好地适应电池等效模型参数的时变特性, 从而提高了电池 SOC 的估计精度。

参考文献

[1] Zhang H, Wang Y, Qi H, et al. Active battery equalization method based on redundant battery for electric vehicles[J]. IEEE Transactions on Vehicular Technology, 2019, 68(8): 7531-7543.

[2] Yang J, Xia B, Shang Y, et al. Adaptive state-of-charge estimation based on a split battery model for electric vehicle applications[J]. IEEE Transactions on Vehicular Technology, 2017, 66(12):10889-10898.

[3] Afshar S, Morris K, Khajepour A. State-of-Charge estimation using an EKF-based adaptive observer[J]. IEEE

Transactions on Control Systems Technology, 2019, 27(5):1907-1923.

[4] Petzl M, Danzer M A. Advancements in OCV measurement and analysis for Lithium-ion batteries[J]. IEEE Transactions on Energy Conversion, 2013, 28(3):675-681.

[5] Xiong R, Zhang Y, He H, et al. A Double-scale, particle-filtering, energy state prediction algorithm for Lithium-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2018, 65(2): 1526-1538.

[6] Partovibakhsh M, Liu G. An adaptive unscented Kalman filtering approach for online estimation of model parameters and state-of-charge of Lithium-Ion batteries for autonomous mobile robots[J]. IEEE Transactions on Control Systems Technology, 2015, 23(1):357-363.

[7] Chaoui H, Ibe-Ekeocha C C. State of charge and state of health estimation for Lithium batteries using recurrent neural networks[J]. IEEE Transactions on Vehicular Technology, 2017, 66(10): 8773-8783.

[8] Wu J, Zhang C, Chen Z. An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks [J]. Applied Energy, 2016, 173:134-140.

[9] Chun C Y, Cho B H, Kim J. Implementation of discharging/charging current sensorless state-of-charge estimator reflecting cell-to-cell variations in lithium-ion series battery packs [J]. International Journal of Automotive Technology, 2016, 17(5):909-916.

[10] Weng C, Sun J, Peng H. A unified open-circuit-voltage model of lithium-ion batteries for state-of-charge estimation and state-of-health monitoring [J]. Journal of Power Sources, 2014, 258:228-237.

[11] Lavigne L, Sabatier J, Francisco J M, et al. Lithium-ion open circuit voltage (OCV) curve modelling and its ageing adjustment[J]. Journal of Power Sources, 2016, 324:694-703.

[12] Paschero M, Storti G L, Rizzi A, et al. A novel mechanical analogy-based battery model for SOC estimation using a multi-

- cell EKF [J]. IEEE Transactions on Sustainable Energy, 2016, 7(4): 1695-1702.
- [13] Meng J, Luo G, Gao F. Lithium polymer battery state-of-charge estimation based on adaptive unscented Kalman filter and support vector machine[J]. IEEE Transactions on Power Electronics, 2016, 31(3): 2226-2238.
- [14] Wang D, Yang F, Tsui K, et al. Remaining useful life prediction of Lithium-ion batteries based on spherical cubature particle filter[J]. IEEE Transactions on Instrumentation and Measurement, 2016, 65(6): 1282-1291.
- [15] Takeno K, Ichimura M, Takano K, et al. Quick testing of batteries in lithium-ion battery packs with impedance-measuring technology[J]. Journal of Power Sources, 2004, 128(1) : 67-75.
- [16] Abraham D P , Knuth J L , Dees D W , et al . Performance degradation of high-power lithium-ion cell electrochemistry of harvested electrodes[J] . Journal of Power Sources, 2007, 170(2): 65-475.
- [17] Klass V, Behm M, Lindbergh G. A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation [J]. Journal of Power Sources, 2014, 270:262-272.
- [18] El Mejdoubi A, Chaoui H, Gualous H, et al. Lithium-ion batteries health prognosis considering aging conditions [J]. IEEE Transactions on Power Electronics, 2019, 34(7): 6834-6844.
- [19] Van der Merwe R, Wan E A. The square-root unscented Kalman filter for state and parameter-estimation[C]// Proceedings of 2001 IEEE International Conference on Acoustics, Speech and Signal Processing. Salt Lake City, UT, USA: IEEE, 2001, 6:3461-3464.
- [20] Aung H, Soon Low K, Ting Goh S. State-of-Charge estimation of Lithium-ion battery using square root spherical unscented Kalman filter (Sqrt-UKFST) in nanosatellite[J]. IEEE Transactions on Power Electronics, 2015, 30(9):4774-4783.
- [21] 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.
- [22] Lin H T, Liang T J, Chen S M. Estimation of battery state of health using probabilistic neural network [J]. IEEE Transactions on Industrial Informatics, 2013, 9(2):679-685.
- [23] Kim J, Cho B H, State-of-Charge estimation and State-of-Health prediction of a Li-ion degraded battery based on an EKF combined with a per-unit system [J]. IEEE Transactions on Vehicular Technology, 2011, 60(9):4249-4260.
- [24] Shen J, Shen J, He Y, et al. Accurate state of charge estimation with model mismatch for Li-ion batteries: a joint moving horizon estimation approach [J]. IEEE Transactions on Power Electronics, 2019, 34(5): 4329-4342.
- [25] Yu Q, Xiong R, Lin C, et al. Lithium-ion battery parameters and state-of-charge joint estimation based on H-Infinity and unscented Kalman filters [J]. IEEE Transactions on Vehicular Technology, 2017, 66(10):8693-8701.

录用稿件，非最终出版稿