DOI：10.13234/j.issn.2095-2805.2026.3.153 **中图分类号**：TM912 **文献标志码**：A

基于自适应平方根秩滤波算法的锂电池SOC估计

张传明[1,2]，万佑红[1,2]，肖 杨[1,2]，陈子龙[1,2]
(1.南京邮电大学自动化学院，南京 210023；2.南京邮电大学人工智能学院，南京 210023)

摘要：锂电池荷电状态SOC(state-of-charge)的估计性能对电池管理系统起着至关重要的作用。采用带遗忘因子的递推最小二乘法辨识电池模型参数，针对现有SOC估计算法中滤波器的采样不能很好地模拟系统状态概率分布的问题，引入秩采样方法，提出自适应平方根秩滤波算法，以平方根形式对系统状态的协方差矩阵进行迭代更新，且每次迭代依据新息自适应地调整观测噪声，以提高SOC的估计精度及其对噪声的自适应能力。通过在联邦城市驾驶FUDS(federal urban driving schedule)和动态压力测试DST(dynamic stress test)工况下的仿真实验来验证所提算法的性能，结果表明，所提算法与扩展卡尔曼滤波、无迹卡尔曼滤波及秩滤波相比，在收敛速度和估计精度方面均有所提升。

关键词：锂电池；荷电状态；递推最小二乘法；自适应；平方根；秩滤波

SOC Estimation of Lithium Battery Based on Adaptive Square Root Rank Filter Algorithm

ZHANG Chuanming[1,2], WAN Youhong[1,2], XIAO Yang[1,2], CHEN Zilong[1,2]
(1. College of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210023, China; 2. College of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: The estimation performance of state-of-charge (SOC) of lithium battery plays a vital role in abattery management system. The recursive least squares method with forgetting factor was used to identify the parameters of a battery model. Aimed at the problem that the sampling of a filter in the existing SOC estimation algorithm cannot well simulate the probability distribution of the system state, a rank sampling method was introduced, and an adaptive square root rank filter algorithm was proposed. The covariance matrix of the system state was updated iteratively in the form of square root, and the observation noise was adjusted adaptively according to the innovation in each iteration, so as to improve the SOC estimation accuracy and its adaptive capability with respect to noise. The performance of the proposed algorithm was verified by simulation experiments under FUDS and DST conditions. Results show that the proposed algorithm can improve the convergence speed and estimation accuracy compared with extended Kalman filter, unscented Kalman filter and rank filter.

Keywords: Lithium battery; state-of-charge (SOC); recursive least squares method; adaptive; square root; rank filter

锂离子电池因其循环寿命长、自放电率低及比能量高等优越性能[1]，已经成为电动汽车的首选动力电池。作为电动汽车能源的锂离子电池对电动汽车的整体性能有着直接影响，电池过度充电可能造成内压升高、过热，甚至爆炸，过度放电可能会造成电池容量减小且不可恢复[2]。荷电状态SOC(state-of-charge)作为电池能量管理的重要决策因素，有助于消除电池使用过程中的安全隐患[3]。因此，准确可靠的SOC估计对动力电池有着重要意义。

常见的SOC估计方法可分为4类：①基于表

收稿日期：2023-03-09；**修回日期**：2023-07-17；**录用日期**：2023-12-02；**网络首发日期**：2024-03-12
基金项目：国家自然科学基金资助项目(62073172)
This work is supported by National Natural Science Foundation of China under the grant 62073172

征参数的方法[4]，简单且易实现，实时性好，但易受环境因素和测量条件的影响，比如温度、工况、老化程度等；②安时积分法[5]，理论简单，计算成本低且有较好的实时性，但过度依赖于准确的 SOC 初值，需要定期修正 SOC 初值，因此实用性较差；③基于数据驱动的方法[6]，估计精度高，但算法较复杂且结果受训练数据的影响大；④基于模型的方法[7]，采用闭环反馈控制，估计精度高且鲁棒性强，有较大的应用前景，其中，卡尔曼(Kalman)滤波及其衍生算法应用最为广泛。

标准的 Kalman 滤波算法受限于线性系统，无法解决工程中存在的非线性问题，因此产生了一系列适用于非线性系统的衍生 Kalman 滤波算法。扩展 Kalman 滤波 EKF(extended Kalman filter)[8]的基本原理是采用一阶泰勒展开对非线性函数进行线性化处理，忽略二阶及以上误差，在强非线性系统中会出现较大的误差，且 EKF 在使用过程中需要求解雅可比矩阵，增加了算法实现的复杂度。无迹 Kalman 滤波 UKF(unscented Kalman filter)[9]的核心思想是无迹变换，即采用一群带权重的 sigma 点对概率密度函数进行近似，无需对非线性函数进行求导，减少了算法计算的工作量，同时精度优于 EKF，但算法迭代过程中需要保证协方差矩阵正定，否则极易导致算法崩溃。秩滤波 RF(rank filter)[10]的基本原理同 UKF 相似，不同之处在于采样方法，RF 采用秩采样[10]，采样点偏多但分布更加合理，能有效模拟系统状态的概率分布，误差更小，能更好地跟踪系统状态的变化。

本文建立一阶 RC 等效电路模型，采用带遗忘因子的递推最小二乘法 FFRLS(recursive least squares method with forgetting factor)对模型参数进行在线辨识，引入秩滤波对锂离子电池 SOC 进行估计，为解决算法迭代过程中协方差矩阵不正定及噪声对滤波结果带来的影响，结合平方根和 Sage-Husa 自适应滤波理论提出自适应平方根秩滤波 ASRRF(adaptive square root rank filter)算法。ASRRF 以平方根形式对系统状态的协方差矩阵进行迭代更新，且每次迭代根据新息自适应地调整观测噪声协方差矩阵，可有效提高 SOC 收敛速度和估计精度。

1 锂离子电池建模与参数辨识

1.1 模型的建立

与锂电池其他常用模型如 P2D 模型、Rint 模型及二阶 RC 模型相比，一阶 RC 模型可以相对准确地表达锂电池的动态特性，结构简单、计算量适中且实用性较强[11]，因此本文采用一阶 RC 等效电路模型，如图 1 所示。图中：U_{OC} 为理想电压源，用于描述电池的开路电压；U_{t} 为电池的端电压；R_0 为电池的欧姆内阻；R_{D} 和 C_{D} 分别为极化电阻和极化电容，用于描述电池的极化特性；U_{D} 为 RC 并联环节的电压降，用于模拟电池的极化电压；i_{L} 为电流，规定放电为正。

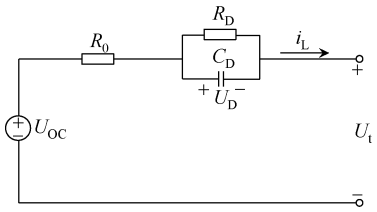


图 1 一阶 RC 等效电路模型

Fig. 1 First-order RC equivalent circuit model

根据基尔霍夫定律，该模型的电路方程为

$$\begin{cases}\dot{U}_{\mathrm{D}}=\dfrac{i_{\mathrm{L}}}{C_{\mathrm{D}}}-\dfrac{U_{\mathrm{D}}}{R_{\mathrm{D}}C_{\mathrm{D}}}\\ U_{\mathrm{t}}=U_{\mathrm{OC}}-U_{\mathrm{D}}-i_{\mathrm{L}}R_0\end{cases}\tag{1}$$

锂电池的 SOC 可根据安时积分法获得，即

$$S_{\mathrm{OC},t}=S_{\mathrm{OC},0}-\frac{\eta}{C_{\mathrm{n}}}\int_0^t i_{\mathrm{L}}(t)\mathrm{d}t\tag{2}$$

式中：$S_{\mathrm{OC},t}$ 为 t 时刻电池的 SOC；$S_{\mathrm{OC},0}$ 为电池初始 SOC；C_{n} 为电池的额定容量；η为充放电效率系数。

由于电池量测数据是离散数据，因此将式(1)和式(2)离散化，得到电路模型的状态空间方程为

$$\begin{bmatrix}U_{\mathrm{D},k}\\ S_{\mathrm{OC},k}\end{bmatrix}=\begin{bmatrix}\mathrm{e}^{-\frac{\Delta t}{\tau_{\mathrm{D}}}} & 0\\ 0 & 1\end{bmatrix}\begin{bmatrix}U_{\mathrm{D},k-1}\\ S_{\mathrm{OC},k-1}\end{bmatrix}+\begin{bmatrix}R_{\mathrm{D}}(1-\mathrm{e}^{-\frac{\Delta t}{\tau_{\mathrm{D}}}})\\ -\Delta t\cdot\dfrac{\eta}{C_{\mathrm{n}}}\end{bmatrix}I_{k-1}+\omega_{k-1}\tag{3}$$

$$U_{\mathrm{t},k}=U_{\mathrm{OC}}(S_{\mathrm{OC},k})-R_0I_k-U_{\mathrm{D},k}+v_k \tag{4}$$

式中：$U_{\mathrm{D},k}$为 k 时刻电压降；$S_{\mathrm{OC},k}$为 k 时刻电池 SOC；Δt 为采样间隔时间；τ_{D}为 RC 网络的时间常数，$\tau_{\mathrm{D}}=R_{\mathrm{D}}C_{\mathrm{D}}$；$\eta$ 取值为 1；ω_{k-1}为 k–1 时刻的过程噪声；$U_{\mathrm{t},k}$为 k 时刻电池端电压；$U_{\mathrm{OC}}(\cdot)$为 U_{OC}关于 SOC 的函数；I_k为 k 时刻的电流；v_k为 k 时刻的观测噪声。

1.2 OCV-SOC 曲线

本文基于 INR 18650-20R 电池进行实验，电池的额定容量为 2 A·h，充电截止电压为 4.2 V，放电截止电压为 2.5 V，数据采样间隔时间为 1 s，实验环境温度为 25 ℃。采用增量开路电压 OCV(open circuit voltage)测试来预先确定 OCV-SOC 曲线关系，即采用恒流恒压方式将电池充电至截止电压，静置 2 h 后记录开路电压 U_{OC}，以 1 A 的放电速率将电池放电 12 min，静置 2 h 后记录相应的 U_{OC}，重复上述步骤直至电压降至 2.5 V，充电 OCV-SOC 曲线的测定原理同放电。由于迟滞效应，同一 SOC 值下的充放电 U_{OC}存在电压差，取充放电的均值进行多项式拟合，经仿真对比，当多项式阶数为 7 时，拟合曲线具有最小的均方根误差。拟合曲线如图 2 所示，函数表达式为

$$\begin{aligned}U_{\mathrm{OC}}(S_{\mathrm{OC}})=&-38.9\times S_{\mathrm{OC}}^7+143.5\times S_{\mathrm{OC}}^6-205.5\times\\&S_{\mathrm{OC}}^5+139.2\times S_{\mathrm{OC}}^4-40\times S_{\mathrm{OC}}^3+0.632\,4\times\\&S_{\mathrm{OC}}^2+2.024\times S_{\mathrm{OC}}+3.298\end{aligned} \tag{5}$$

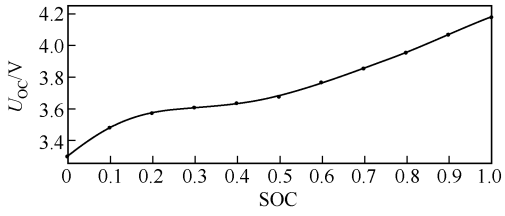


图 2　OCV-SOC 曲线

Fig. 2 OCV-SOC curve

1.3 带遗忘因子的递推最小二乘法

递推最小二乘法 RLS(recursive least squares)[12]是 1 种由自适应滤波理论发展而来的参数辨识方法，对于模型参数受外界环境影响而发生较大变化的情形，RLS 通过定期的参数校正可以获得稳定的辨识结果。但对于参数持续缓慢变化的系统，采用 RLS 会出现数据饱和现象，难以获取稳定可靠的辨识结果。为此，FFRLS 通过对测量数据引入遗忘因子来减少旧数据的影响，增加新数据所占比重，从而实现参数的可靠辨识[13]。受外界温度及电池本身老化的影响，电池模型参数会发生缓慢变化，因此本文采用 FFRLS 对模型参数进行在线辨识，其表达式为

$$\begin{cases}\boldsymbol{K}_k=\boldsymbol{P}_{k-1}\boldsymbol{\varphi}_k^{\mathrm{T}}[\boldsymbol{\varphi}_k\boldsymbol{P}_{k-1}\boldsymbol{\varphi}_k^{\mathrm{T}}+\mu]^{-1}\\\hat{\boldsymbol{\theta}}_k=\hat{\boldsymbol{\theta}}_{k-1}+\boldsymbol{K}_k[y_k-\boldsymbol{\varphi}_k\hat{\boldsymbol{\theta}}_{k-1}]\\\boldsymbol{P}_k=\dfrac{1}{\mu}[\boldsymbol{E}-\boldsymbol{K}_k\boldsymbol{\varphi}_k]\boldsymbol{P}_{k-1}\end{cases} \tag{6}$$

式中：$\boldsymbol{K}_k$为增益向量；$\boldsymbol{\varphi}_k$为数据向量；μ为遗忘因子，一般取值为 0.90~1.00，本文取 0.96；$\hat{\boldsymbol{\theta}}_k$为待估计的参数向量；$y_k$为系统的实际输出；$\boldsymbol{P}_k$为状态估计误差协方差矩阵；$\boldsymbol{E}$ 为单位矩阵。

1.4 模型参数辨识

根据所建的一阶 RC 模型可得到传递函数为

$$G(s)=\frac{U_{\mathrm{t}}(s)-U_{\mathrm{OC}}(s)}{i_{\mathrm{L}}(s)}=-\left(R_0+\frac{R_{\mathrm{D}}}{R_{\mathrm{D}}C_{\mathrm{D}}s}\right) \tag{7}$$

采用双线性变换法将式(5)映射到 z 平面，可得

$$G(z)=\frac{a_2+a_3z^{-1}}{1-a_1z^{-1}} \tag{8}$$

式中，a_1、a_2、a_3为与模型参数相关的系数，这些系数可与一阶 RC 模型中的电阻和电容相互转换。

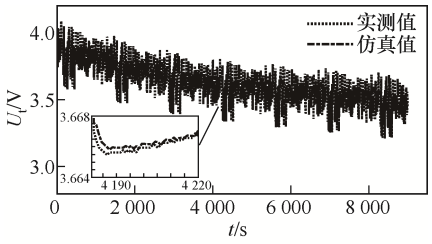
令 $E_{\mathrm{L},k}=U_{\mathrm{t},k}-U_{\mathrm{OC},k}$，则式(6)可以转化为差分方程，即

$$E_{\mathrm{L},k}=a_1E_{\mathrm{L},k-1}+a_2i_{\mathrm{L},k}+a_3i_{\mathrm{L},k-1} \tag{9}$$

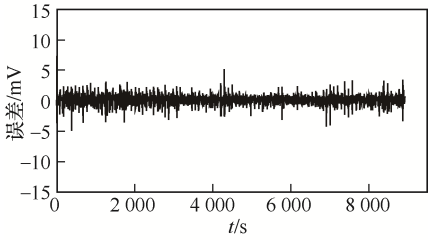
令 $y_k=U_{\mathrm{t},k}-U_{\mathrm{OC},k}$，$\boldsymbol{\varphi}_k=[y_{k-1}\ \ i_{\mathrm{L},k}\ \ i_{\mathrm{L},k-1}]$，待辨识的参数向量 $\hat{\boldsymbol{\theta}}_k^{\mathrm{T}}=[a_1\ \ a_2\ \ a_3]$。设置合理的初值后，导入工况数据，应用 FFRLS 进行模型参数辨识，得到各电阻和电容的实时值。

联邦城市驾驶 FUDS(federal urban driving schedule)和动态压力测试 DST(dynamic stress test)工况下端电压对比结果和电压误差分别如图 3 和图 4 所示。可见，在辨识初期电压误差较大，这是由初始参数设置偏离真实值及放电初期电流电压数据变化不明显引起的。除参数辨识初期外，其余时刻

电压误差均保持在 10 mV 以内，辨识精度较高。



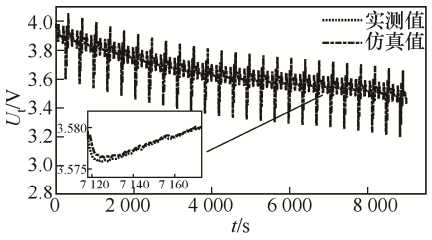
(a) 端电压实测值与仿真值



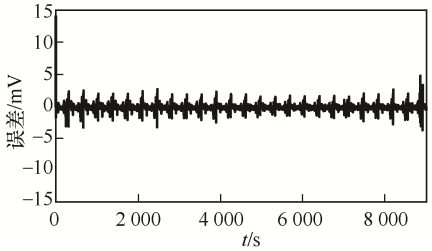
(b) 端电压误差

图 3 FUDS 工况下端电压和误差

Fig. 3 Terminal voltage and error under FUDS condition



(a) 端电压实测值与仿真值



(b) 端电压误差

图 4 DST 工况下端电压和误差

Fig. 4 Terminal voltage and error under DST condition

2 基于 ASRRF 的 SOC 估计

RF 是近年提出的非线性系统滤波方法，通过采样点实现 2 个相邻时刻之间的估计误差协方差的迭代更新，避免了 EKF 复杂的求导运算。与 RF 不同，平方根秩滤波 SRRF(square root rank filter)以平方根形式对状态的协方差矩阵进行迭代更新，即 Cholesky 分解[14]，保证每一步得到的状态协方差矩阵必为半正定矩阵，解决了 RF 中可能出现协方差矩阵不正定而导致算法崩溃的情形，提高了算法的稳定性。同时，在标准 RF 中，过程噪声协方差矩阵 $\boldsymbol{Q}$ 和观测噪声协方差矩阵 $\boldsymbol{R}$ 的值需多次手动调整才能获得较好的估计结果，不合理的 $\boldsymbol{Q}$ 和 $\boldsymbol{R}$ 将导致 SOC 估计结果出现较大的偏差。为解决该问题，在 SRRF 的基础上结合 Sage-Husa 自适应滤波理论[15]，对噪声协方差矩阵进行自适应调整，提出自适应平方根秩滤波算法。

基于以上思路，ASRRF 的估算过程如下。

(1)状态初始化，通过 Cholesky 分解计算状态协方差矩阵的平方根来初始化滤波器，且矩阵的平方根在后续迭代过程中会被直接更新，避免在每个时间步骤进行平方根操作，同时，$\boldsymbol{Q}$ 和 $\boldsymbol{R}$ 也以平方根形式参与算法的迭代，即

$$\begin{cases} \hat{x}_0 = E[x_0] \\ \boldsymbol{P}_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^{\mathrm{T}}] \\ \boldsymbol{S}_{x_0} = \mathrm{chol}(\boldsymbol{P}_0) \\ \boldsymbol{S}_{\boldsymbol{Q}} = \mathrm{chol}(\boldsymbol{Q}) \\ \boldsymbol{S}_{\boldsymbol{R}} = \mathrm{chol}(\boldsymbol{R}) \end{cases} \tag{10}$$

式中：x_0 为初始状态估计值；$\hat{x}_0$ 为初始状态预测值；chol(·)表示对矩阵进行 Cholesky 分解并返回下三角 Cholesky 因子。

(2)通过秩采样计算时间更新所需的 sigma 点集。秩采样是基于秩统计量相关原理提出的 1 种采样方法，可以根据系统的分布类型调整参数，进而优化采样形式，可以很好地处理非线性滤波问题[16]。当状态估计误差 $x_k - \hat{x}_{k-1}$ 服从高斯分布时，秩采样通过适当调整相应的采样点修正系数，可使估计误差更好地服从高斯分布。因此与传统的滤波采样方法相比，秩采样的采样点分布更加合理，能更好地模拟系统状态的概率分布，滤波精度更高。采样点可表示为

$$\chi_{k-1,i} = \begin{cases} \hat{x}_{k-1} + r\lambda_{p_1} \boldsymbol{S}_{x_{k-1,i}} & i = 1,\cdots,n \\ \hat{x}_{k-1} - r\lambda_{p_1} \boldsymbol{S}_{x_{k-1,i-n}} & i = n+1,\cdots,2n \\ \hat{x}_{k-1} + r\lambda_{p_2} \boldsymbol{S}_{x_{k-1,i-2n}} & i = 2n+1,\cdots,3n \\ \hat{x}_{k-1} - r\lambda_{p_2} \boldsymbol{S}_{x_{k-1,i-3n}} & i = 3n+1,\cdots,4n \end{cases} \tag{11}$$

式中：n 为系统状态的维数；r 为采样点修正系数，本文取 1；λ_{p_1} 和 λ_{p_2} 为标准正态分布下概率为 p_1 和 p_2 的分位点，采用中位秩计算 $p_j=(j+2.7)/5.4$，其中 $j=1,2$，$p_1=0.685\,2$，$\lambda_{p_1}=0.482\,3$，$p_2=0.870\,4$，$\lambda_{p_2}=1.128\,1$。

(3)计算新的 sigma 采样点集，加权处理可得到状态预测值 $\hat{x}_k^-$，并采用 *QR* 分解来更新状态误差协方差矩阵 $\boldsymbol{S}_{x_k}^-$。

$$\begin{cases} X_{k|k-1,i}=f(\chi_{k-1,i}) \\ \hat{x}_k^-=\dfrac{1}{4n}\sum\limits_{i=1}^{4n}X_{k|k-1,i} \\ \boldsymbol{S}_{x_k}^-=qr\left\{\left[\sqrt{\dfrac{r^*}{\omega}}(X_{k|k-1,i}-\hat{x}_k^-)\quad \boldsymbol{S}_{\boldsymbol{Q}}\right]\right\} \end{cases} \tag{12}$$

式中：ω 为协方差权重系数，且 $\omega=2r^2(\lambda_{p_1}^2+\lambda_{p_2}^2)=3.010\,5$；$r^*$ 为协方差修正系数，本文取 0.999；qr 表示对矩阵进行 *QR* 分解，并取 $\boldsymbol{R}$ 矩阵的下三角部分。

(4)根据状态预测值 $\hat{x}_k^-$ 及状态误差协方差矩阵 $\boldsymbol{S}_{x_k}^-$ 重新进行秩采样，从而得到量测更新所需的秩采样点集，即

$$\chi_{k|k-1,i}=\begin{cases} \hat{x}_k^-+r\lambda_{p_1}\boldsymbol{S}_{x_{k,i}}^- & i=1,\cdots,n \\ \hat{x}_k^-+r\lambda_{p_1}\boldsymbol{S}_{x_{k,i-n}}^- & i=n+1,\cdots,2n \\ \hat{x}_k^-+r\lambda_{p_2}\boldsymbol{S}_{x_{k,i-2n}}^- & i=2n+1,\cdots,3n \\ \hat{x}_k^-+r\lambda_{p_2}\boldsymbol{S}_{x_{k,i-3n}}^- & i=3n+1,\cdots,4n \end{cases} \tag{13}$$

(5)量测方程更新。根据非线性系统的观测方程对量测更新的采样点集进行非线性变换，对变换后的 Sigma 点集进行加权处理，从而得到 k 时刻输出变量 y 的预测值 $\hat{y}_k^-$，可表示为

$$Y_{k|k-1,i}=h(\chi_{k,k-1,i}) \tag{14}$$

$$\hat{y}_k^-=\frac{1}{4n}\sum_{i=1}^{4n}Y_{k|k-1,i} \tag{15}$$

采用 *QR* 分解计算 k 时刻的后验误差协方差矩阵 $\boldsymbol{S}_{y_k}$，根据时间更新步及量测更新步的采样点集计算互协方差矩阵 $\boldsymbol{P}_{x_k,y_k}$，由 $\boldsymbol{S}_{y_k}$ 和 $\boldsymbol{P}_{x_k,y_k}$ 可计算出卡尔曼增益 $\boldsymbol{K}_k$，即

$$\boldsymbol{S}_{y_k}=qr\left\{\left[\sqrt{\frac{r^*}{\omega}}(Y_{k|k-1,i}-\hat{y}_k^-)\quad \boldsymbol{S}_{\boldsymbol{R}}\right]\right\} \tag{16}$$

$$\boldsymbol{P}_{x_k,y_k}=\frac{r^*}{\omega}\sum_{i=1}^{4n}\{(\chi_{k|k-1,i}-\hat{x}_k^-)(Y_{k|k-1,i}-\hat{y}_k^-)\} \tag{17}$$

$$\boldsymbol{K}_k=(\boldsymbol{P}_{x_k,y_k}/\boldsymbol{S}_{y_k}^{\mathrm{T}})/\boldsymbol{S}_{y_k} \tag{18}$$

根据卡尔曼增益 $\boldsymbol{K}_k$ 和量测值 y_k 对状态预测值 $\hat{x}_k^-$ 及状态误差协方差矩阵 $\boldsymbol{S}_{x_k}^-$ 进行更新，即

$$\hat{x}_k=\hat{x}_k^-+\boldsymbol{K}_k(y_k-\hat{y}_k^-) \tag{19}$$

$$\boldsymbol{S}_{x_k}=\mathrm{cholupdate}\{\boldsymbol{S}_{x_k}^-,\boldsymbol{K}_k\boldsymbol{S}_{y_k},-1\} \tag{20}$$

式中，cholupdate 表示 Cholesky 因子更新。

(6)噪声自适应，利用当前时刻的新息对观测噪声协方差的平方根进行更新，从而降低噪声对滤波结果的影响，提高滤波精度，考虑到同时更新 $\boldsymbol{Q}$ 和 $\boldsymbol{R}$ 可能会导致滤波结果发散[17]，本文仅对 $\boldsymbol{R}$ 进行自适应调整，可表示为

$$\varepsilon_k=y_k-\hat{y}_k^- \tag{21}$$

$$\sqrt{\boldsymbol{R}^{**}}=\mathrm{cholupdate}\left\{\sqrt{1-d_k}\,\boldsymbol{S}_{\boldsymbol{R}},|\,\varepsilon_k\,|,d_k\right\} \tag{22}$$

$$\sqrt{\boldsymbol{R}^{*}}=\mathrm{cholupdate}\left\{\sqrt{\boldsymbol{R}^{**}},Y_{k|k-1,1:4n}-\hat{y}_k^-,-d_k\frac{r^*}{\omega}\right\} \tag{23}$$

$$\boldsymbol{S}_{\boldsymbol{R}}=\mathrm{diag}\left\{\sqrt{\mathrm{diag}(\sqrt{\boldsymbol{R}^*}\sqrt{\boldsymbol{R}^*}^{\mathrm{T}})}\right\} \tag{24}$$

式中：$d_k=(1-b)/(1-b^{k+1})$，b 为遗忘因子，$0<b<1$；diag 表示对角矩阵。

3　实验结果与分析

在 FUDS 和 DST 工况下分别对电池进行放电，并在这 2 种工况下验证本文算法的有效性。遗忘因子 b 取 0.99，设置不同的观测噪声 R 进行实验，2 种工况下 RF 与 ASRRF 的 SOC 估计绝对误差曲线分别如图 5 和图 6 所示。可见，不同观测噪声下，基于 RF 的 SOC 估计结果出现明显的偏差，而本文所提算法 ASRRF 估计结果受观测噪声影响较小，这是由于 ASRRF 在迭代过程中 R 的值不是恒定的，在利用观测数据进行递推滤波的同时，通过对噪声的估计实时修正噪声的统计特性，降低了噪声

对滤波结果的影响。

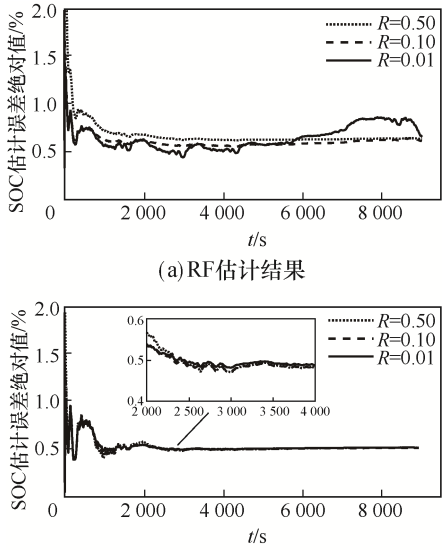


图 5 FUDS 工况下不同观测噪声对 SOC 估计结果的影响

Fig. 5 Influence of different observation noises on SOC estimation results under FUDS condition

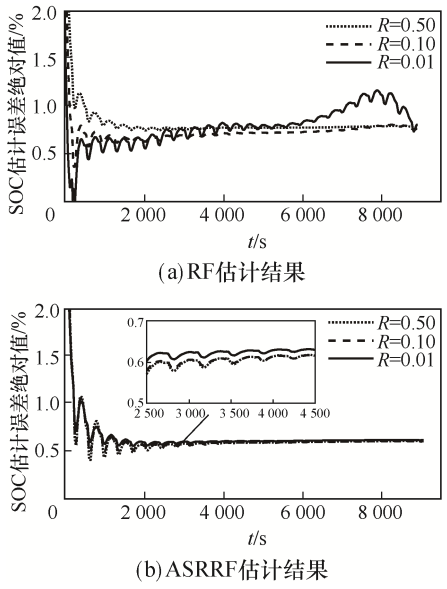


图 6 DST 工况下不同观测噪声对 SOC 估计结果的影响

Fig. 6 Influence of different observation noises on SOC estimation results under DST condition

为比较 ASRRF 与 EKF、UKF、RF 的收敛速度和估计精度，ASRRF 在噪声统计特性未知的情况下设置初始的观测噪声协方差矩阵 $\boldsymbol{R}$，EKF、UKF 和 RF 这 3 种算法均设置过程噪声协方差矩阵 $\boldsymbol{Q}$= diag([0.000 000 02　0.000 000 02])，R=0.1，SOC 初值均设置为 0.6。其中，采用调节时间评价各算法的收敛速度，定义为 $t_s=\max\{t\,|\,(S_{OC,ref}-S_{OC,es})\leqslant \pm 5\%\}$，$S_{OC,ref}$ 为 SOC 参考值，$S_{OC,es}$ 为 SOC 估计值。FUDS 和 DST 工况下，4 种算法 SOC 估计结果和 SOC 估计绝对误差曲线如图 7 和图 8 所示。

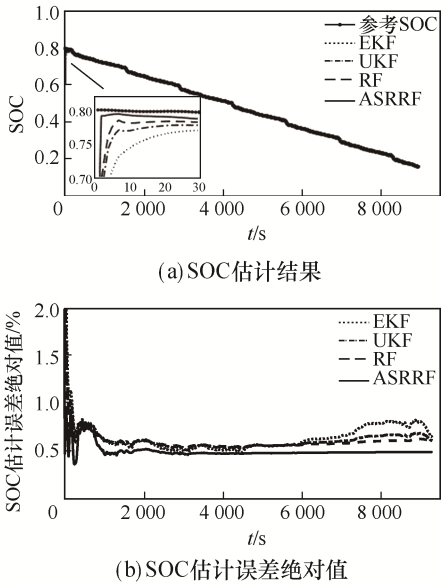


图 7 FUDS 工况下 SOC 估计结果对比

Fig. 7 Comparison of SOC estimation results under FUDS condition

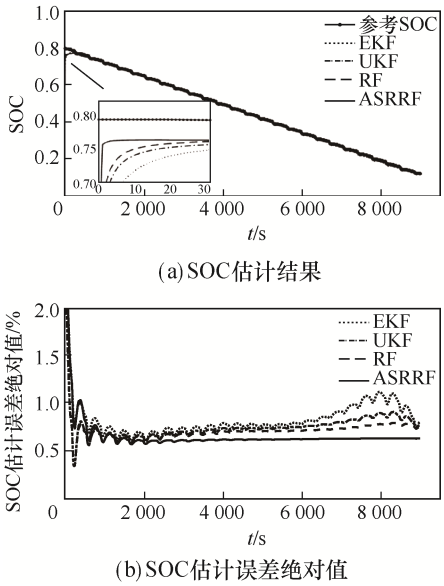


图 8 DST 工况下 SOC 估计结果对比

Fig. 8 Comparison of SOC estimation results under DST condition

由图 7(a)和图 8(a)可以看出，尽管 4 种算法的 SOC 初值设置与参考值有一定偏差，但随着算法迭

代，均能较快收敛到参考值附近。FUDS 工况下 EKF、UKF、RF 及 ASRRF 的调节时间分别为 12 s、5 s、4 s、2 s，DST 工况下调节时间分别为 20 s、11 s、8 s、2 s。显然，ASRRF 在收敛速度上具有明显优势，RF 和 UKF 次之，EKF 较差。由图 7(b)和图 8(b)可以看出，4 种算法收敛后估计误差绝对值均保持在 1.5%以下，其中 ASRRF 收敛后误差更小，估计精度明显优于 EKF、UKF 及 RF，且误差波动较小，更为稳定。此外，由于电池本身的非线性，在放电后期除 ASRRF 外，其他算法的估计误差均有所变大，但 RF 因其特殊的采样方式，能很好地跟踪状态的变化，因此误差变化的幅度较 EKF 和 UKF 并不大。

为进一步评估上述算法的性能，从绝对误差均值 MAE(mean absolute error)、最大误差绝对值 MAXE(maximum absolute error)和均方根误差 RMSE(root mean square error)3 方面进行评测，4 种算法的性能对比如图 9 所示。可以看到，ASRRF 的 SOC 估计结果比 EKF、UKF 和 RF 更精确，SOC 估计的绝对误差均值、最大误差绝对值及均方根误差与 EKF、UKF 和 RF 相比均有一定程度的改善。

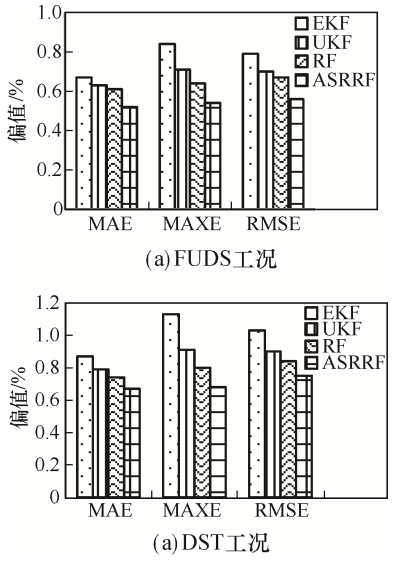


图 9　不同 SOC 估计方法性能对比

Fig. 9 Comparison of performance among different SOC estimation methods

4　结语

在一阶 RC 等效电路模型的基础上，采用 FFRLS 对模型参数进行在线辨识，引入 RF 对 SOC 进行估计，结合平方根和 Sage-Husa 自适应滤波理论提出了 ASRRF，避免了标准 RF 迭代过程中易出现协方差矩阵不正定及噪声不准确对 SOC 估计结果的影响。应用 FUDS 和 DST 工况数据来评估所提出方法的性能，并将 ASRRF 与 EKF、UKF 和 RF 进行实验对比，结果表明 ASRRF 在收敛速度和估计精度方面具有更优异的性能。

参考文献：

[1] Randau S, Weber D A, Kötz O, et al. Benchmarking the performance of all-solid-state lithium batteries [J]. Nature Energy, 2020, 5(3): 259-270.

[2] Finegan D P, Zhu Juner, Feng Xuning, et al. The application of data-driven methods and physics-based learning for improving battery safety [J]. Joule, 2021, 5(2): 316-329.

[3] Liu Yuefeng, Li Jiaqi, Zhang Gong, et al. State of charge estimation of lithium-ion batteries based on temporal convolutional network and transfer learning [J]. IEEE Access, 2021, 9: 34177-34187.

[4] How D N T, Hannan M A, Hossain Lipu M S, et al. State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review [J]. IEEE Access, 2019, 7: 136116-136136.

[5] Yang Wenrong, Zhu Saifei, Chen Yang, et al. SOC estimation of lithium-ion battery based on improved ampere-hour integral method [J]. Chinese Journal of Power Sources, 2018, 42:183-184.

[6] Cui Zhenhua, Wang Licheng, Li Qiang, et al. A comprehensive review on the state of charge estimation for lithium-ion battery based on neural network [J]. International Journal of Energy Research, 2022, 46(5): 5423-5440.

[7] 巫春玲，吕晶晶，相里康，等. 基于变分模态分解和核极限学习机集成模型的电动汽车锂电池健康状态预测

[J]. 电源学报, 2025, 23(6): 288-299.
Wu Chunling, Lü Jingjing, Xiangli Kang, et al. SOH prediction of electric vehicle lithium battery based on integrated model of variation modal decomposition and Kernel-based extreme learning machine [J]. Journal of Power Supply, 2025, 23(6): 288-299. (in Chinese)

[8] Cui Zhenjie, Hu Weihao, Zhang Guozhou, et al. An extended Kalman filter based SOC estimation method for Li-ion battery [J]. Energy Reports, 2022, 8: 81-87.

[9] 白俊琦, 贤燕华. 基于 BP-多时间尺度 UKF 优化算法的 SOC 估计[J]. 电源学报, 2025, 23(3): 363-372.
Bai Junqi, Xian Yanhua. State-of-charge estimation based on BP-multi-timescale UKF optimization algorithm [J]. Journal of Power Supply, 2025, 23(3): 363-372. (in Chinese)

[10] 傅惠民, 肖强, 吴云章, 等. 秩滤波方法[J]. 机械强度, 2014, 36(4): 521-526.
Fu Huimin, Xiao Qiang, Wu Yunzhang, et al. Rank filter method [J]. Journal of Mechanical Strength, 2014, 36(4): 521-526. (in Chinese)

[11] Hu Xiaosong, Li Shengbo, Peng Huei. A comparative study of equivalent circuit models for Li-ion batteries [J]. Journal of Power Sources, 2012, 198: 359-367.

[12] Ma Ping, Wang Lei. Filtering-based recursive least squares estimation approaches for multivariate equation-error systems by using the multiinnovation theory [J]. International Journal of Adaptive Control and Signal Processing, 2021, 35(9): 1898-1915.

[13] Baldi S, Zhang Zichen, Liu Di. Eligibility traces and forgetting factor in recursive least-squares-based temporal difference [J]. International Journal of Adaptive Control and Signal Processing, 2022, 36(2): 334-353.

[14] 褚云通. 基于 Cholesky 分解的协方差矩阵估计[J]. 高师理科学刊, 2020, 40(9): 11-16.
Chu Yuntong. Covariance matrix estimation based on Cholesky decomposition [J]. Journal of Science of Teachers' College and University, 2020, 40(9): 11-16. (in Chinese)

[15] Narasimhappa M, Mahindrakar A D, Guizilini V C, et al. MEMS-based IMU drift minimization: Sage Husa adaptive robust Kalman filtering [J]. IEEE Sensors Journal, 2020, 20(1): 250-260.

[16] Yang Haifeng, Wang Zhihua, Fu Huimin, et al. Integrated navigation for Mars final approach based on Doppler radar and X-ray pulsars with atomic clock error [J]. Acta Astronautica, 2019, 159: 308-318.

[17] Lin Yanping, Liu Kaizhou, Wang Xiulian. An adaptive square-root unscented Kalman filter for underwater vehicle navigation [C]// 2014 IEEE International Conference on Mechatronics and Automation. Tianjin, China, 2014: 717-722.


张传明

作者简介：

张传明(1998—)，男，硕士研究生。研究方向：锂电池 SOC 估计。E-mail：zhangcm0203@163.com。

万佑红(1974—)，女，通信作者，博士，教授。研究方向：锂电池 SOC 估计与储能关键技术，复杂网络的建模与优化及其在电力系统中的应用。E-mail：wanyh@njupt.edu.cn。

肖杨(1999—)，男，硕士研究生。研究方向：储能电站综合评价。E-mail：2227624023@qq.com。

陈子龙(1999—)，男，硕士研究生。研究方向：锂电池 SOC 估计。E-mail：532379660@qq.com。

(责任编辑：郭凯凯)