

DOI:10.19651/j.cnki.emt.2209455

基于 ARWLS-AEKF 的锂电池 SOC 估计*

田元武¹ 张诗建² 周博雅² 黎 芬¹

(1. 河北工业大学能源与环境工程学院 天津 300401; 2. 中国汽车技术研究中心有限公司 天津 300300)

摘要: 根据 SOC 在电池管理系统中的应用需求, 针对锂离子电池的模型准确度低、SOC 估算精度差的问题, 提出了一种 ARWLS-AEKF 联合算法。该方法以二阶 R-C 网络模型为基础, 通过加权自适应算法引入自适应遗传因子, 优化参数辨识精度, 并搭建 MATLAB 仿真平台联合自适应扩展卡尔曼滤波算法(AEKF)算法对 SOC 进行在线估算。将三种测试工况下的算法仿真结果与电池实验平台所得测量数据进行对比, 结果表明: ARWLS-AEKF 算法相对于离线 EKF 算法有更高的准确度与适应性, 能适应随机变化的噪声环境。在 LA_92、UDDS、HWFET 工况下, ARWLS-AEKF 算法的误差在 2% 以内, MAE 分别为 0.45%、0.74%、0.87%, RMSE 值分别为 0.54%、0.71%、0.42%。

关键词: 荷电状态; 自适应扩展卡尔曼滤波; 等效电路模型; 锂离子电池

中图分类号: TM912 **文献标识码:** A **国家标准学科分类代码:** 510

Lithium battery SOC estimation based on ARWLS-AEKF joint algorithm

Tian Yuanwu¹ Zhang Shijian² Zhou Boya² Li Su¹

(1. School of Energy and Environmental Engineering, Hebei University of Technology, Tianjin 300401, China;

2. China Auto-motive Technology Research Center Co., Ltd., Tianjin 300300, China)

Abstract: According to the application requirements of SOC in battery management system, an ARWLS-AEKF joint algorithm was proposed to estimate the SOC of lithium ion battery. Based on the second-order R-C network model, the method introduced adaptive genetic factors through the weighted adaptive algorithm, to optimized the parameter identification method. And combined with the adaptive extended Kalman Filter (AEKF) algorithm for online identification, to complete the estimate of SOC. The simulation results and experimental data show that the error of ARWLS-AEKF algorithm is within 2% under LA_92, UDDS and HWFET conditions, MAE is 0.45%, 0.74% and 0.87%, RMSE is 0.54%, 0.71% and 0.42%, respectively. ARWLS-AEKF algorithm has higher accuracy and stronger disturbance resistance to noise than off-line EKF method.

Keywords: state of charge; adaptive extended Kalman filter; equivalent circuit model; lithium ion battery

0 引言

锂离子电池作为纯电动汽车的直接能量来源, 是决定电动汽车续航里程、充电性能的关键因素。电池管理系统(battery management system, BMS)通过对锂电池状态进行监测并实时调整能量供应策略, 以达到保护电池组、提高能量利用率、优化纯电动汽车经济性的目的^[1]。电池荷电状态(state of charge, SOC)是 BMS 的重要监测参数, 其估算精度直接决定了电池管理系统的可靠性与安全性。由于 SOC 不能被直接测量只能通过建立相应的电池模型并结合不同算法间接估算, 不同估算策略的选择决定了 SOC 的估算准确度。估算策略的研究重点主要集中在两方面: 电池模型的选择与辨识、SOC 估算方法的优化^[2]。

常用的电池等效模型有 Rint 模型, R-C 网络模型, 和 PNGV 模型等^[3]。二阶 R-C 网络模型, 能够在较为理想的计算成本下满足 SOC 估算精度, 是目前应用较广泛的电路模型。电气元件的参数辨识精度对模型准确性有很大影响, 传统最小二乘法参数辨识会导致模型参数不具备实时性^[4]。递推最小二乘法(recursive least squares, RLS)是由最小二乘算法衍生而来, 时效性大大提高, 但是在采样时间较长的境况下会出现数据饱和问题, 导致模型的辨识精度下降^[5]。带遗忘因子的递推最小二乘法(forget factor recursive least squares, FFRLS)能够有效地提升算法追踪效果, 但遗忘因子的选定需要人工选定^[6]。

目前 SOC 的估算方法主要有安时积分法、开路电压

收稿日期: 2022-03-30

* 基金项目: 中国汽车技术研究中心有限公司重大专项(ZX21220002)资助

法、数据驱动法、卡尔曼滤波法等^[7]。按时积分法从 SOC 的定义出发,将采集的电流数据直接积分从而完成 SOC 的估算,属于开环算法。其累计误差无法自我修正,且受初始值的影响较大,故该方法只适用于实验室环境,不适合实际车辆的应用^[8]。开路电压法多用在电池的标定阶段,因为该方法需要在每个实验步骤后对电池进行以小时为单位的静置,所以无法满足纯电动汽车 BMS 的时效性要求^[9]。数据驱动法结合电流、电压等测量数据,以 BP 神经网络、支持向量机等模型为基础,完成对电池 SOC 的预测。该方法需要巨大的数据量作为训练集,且算法模型的计算成本较大,对车载处理器的计算能力要求较高,并未取得广泛的应用^[10]。卡尔曼滤波法是目前较为成熟的一种估算方法,其计算简单并具有较高精度,适用于实车的 SOC 估计。

卡尔曼滤波法只适用于线性模型,对非线性系统适应性较差。针对此问题,一些学者对传统卡尔曼滤波法进行了优化,使该方法成功地应用于锂电池的 SOC 状态估计。文献[11]通过研究系统噪声对估计结果的影响机理,使用 FFRLS 法对电池模型进行离线辨识,并通过扩展卡尔曼滤波法(extended Kalman filter, EKF)对锂电池进行了 SOC 预测,结果表明,离线辨识无法准确地反映锂电池的实时特性,对温度、电池老化程度等因素适应性较差。文献[12]对 EKF 算法进行了改进,联合 FFRLS,对一阶 R-C 网络模型进行了在线辨识,并进行了 SOC 估算。但一阶 R-C 网络模型的精度较差,不能反映电池内部真实的极化现象,同时,模型辨识过程中固定的遗忘因子会使得后期各电气元件辨识精度下降,影响 SOC 的估算精度。文献[6]使用 FFRLS 联合 EKF 对锂离子电池的 SOC 进行了估算,并验证了该算法在动态工况下的稳定性。不足在于其将电池系统的噪声设定为恒定的高斯白噪声,不符合实际的噪声特性。

基于上述分析,本文使用二阶 R-C 网络模型作为电池模型,通过自适应加权算法引入动态遗忘因子以优化最小二乘法在估算后期的精度。考虑到数据采集时噪声的变化情况,采用 AEKF(adaptive extended Kalman filter)方法实时更新噪声矩阵,并联合自适应遗忘因子最小二乘法(adaptive recursive weighted least square, ARWLS),对锂电池的 SOC 进行在线估算。最后在 3 种动态工况下验证了 ARWLS-AEKF 算法的适应性与鲁棒性。结果表明,ARWLS-AEKF 算法在不同动态工况下均有较高估算精度,且抗扰能力较强。

1 动力电池数学模型的建立

1.1 SOC 的定义

对于动力锂离子电池而言, SOC 为剩余可用电荷量与电池最大可用电荷量之比,值在 0~1 之间,通常以百分数表示,其计算方法如式(1)所示。

$$SOC(t) = \left(SOC_0 - \int_{Q_n} i_c dt \right) \quad (1)$$

式中: i_c 为瞬时电流,规定放电电流为正值,充电电流为负值, Q_n 为电池额定电荷量。 SOC_0 为 SOC 初始值, $SOC(t)$ 为 t 时刻的 SOC。为适应实验中所采集的电流数据对式(1)进行离散处理:

$$SOC(k+1) = SOC(k) - \frac{\sum_{j=1}^k i_j \times \Delta t}{Q_n} \quad (2)$$

式中: Δt 为采样周期, k 为采样时刻, $SOC(k)$ 是电池在 k 时刻的 SOC 值。

1.2 等效电路模型的选取与离散处理

Rint 模型只含有一个电阻,不能反映电池在频繁充电放电情况下的极化现象^[13]。PNGV 模型与三阶 R-C 模型虽然能有效地反映电池瞬时状态,但其复杂的数学模型不但大幅增加了计算量,而且不利于参数辨识算法的收敛^[14]。综合考虑模型的辨识精度与算法计算量两方面,本文采用了二阶 R-C 模型,电池模型如图 1 所示。




图 1 二阶 R-C 等效电路模型

其中, U_{oc} 为理想电压源, R_0 为电池内阻, C_1 、 C_2 为极化电容, R_1 、 R_2 为极化电阻, U_t 为电路端电压, I 为电路电流。

电流端电压 U_t 与电路电流 I 可由传感器实时测量,由基尔霍夫定律(KVL)与电流定律(KCL)对电路进行求解得到二阶 R-C 电路的数学模型如式(3)所示。

$$\begin{cases} \dot{U}_1(t) = \frac{I(t)}{C_1(t)} - \frac{U_1(t)}{R_1(t)C_1(t)} \\ \dot{U}_2(t) = \frac{I(t)}{C_2(t)} - \frac{U_2(t)}{R_2(t)C_2(t)} \\ U_t(t) = U_{oc}(t) - U_1(t) - U_2(t) - I(t) \times R_0(t) \end{cases} \quad (3)$$

将式(1)与(3)联立,并进行离散化处理,可以得到二阶 R-C 电路模型的状态空间方程:

$$\begin{bmatrix} SOC(k+1) \\ U_1(k+1) \\ U_2(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{\Delta t}{\tau_1(k)}} & 0 \\ 0 & 0 & e^{-\frac{\Delta t}{\tau_2(k)}} \end{bmatrix} \begin{bmatrix} SOC(k) \\ U_1(k) \\ U_2(k) \end{bmatrix} + I(k) \times \begin{bmatrix} -\frac{\Delta t}{Q_n} & R_1(1 - e^{-\frac{\Delta t}{\tau_1(k)}}) & R_2(1 - e^{-\frac{\Delta t}{\tau_2(k)}}) \end{bmatrix}^T \quad (4)$$

式中: $\tau = RC$, 为时间常数。端电压的观测方程如式(5)所示。

$$U_t(k) = U_{oc}(k) - U_1(k) - U_2(k) - I(k)R_0 \quad (5)$$

1.3 OCV-SOC 关系的建立

开路电压(open circuit voltage, OCV)与锂离子电池的 SOC 具有较强的相关性。确定静置条件下开路电压与电池 SOC 的函数关系是估算 SOC 的重要环节。由于 SOC 与 OCV 的函数关系在 20 °C ~ 40 °C 的温度区间内变化不大^[15],故本文选择在常温(25 °C)环境下进行锂电池进行混合脉冲功率特性实验(hybrid pulse power characteristic, HPPC)以得到 OCV-SOC 曲线。实验采用的电池参数如表 1 所示。

表 1 锂离子电池参数

参数	数值	参数	数值
额定容量/(A·h)	3	充电截至电流/A	0.15
额定电压/V	3.6	放电截至电压/V	2.75
充电截至电压/V	4.2	能量密度/(wh·kg ⁻¹)	166

锂电池的 OCV-SOC 曲线在两端的变化趋势更加剧烈,为获取更加精准的 OCV-SOC 曲线,本文在进行 HPPC 实验时在 SOC 小于 10%或大于 90%的区间内以 5%为间隔记录对应的开路电压,具体实验步骤如下:

- 1)保持环境温度为 25 °C,将电池以 1 C 倍率恒流充电至 4.2 V 后,恒压充电到电流小于 0.15 A,完成充电后静置 1 h。
- 2)以 0.2 C 的放电倍率对电池进行放电,当 SOC 减少 5%时停止放电,静置 1 h 后记录此刻开路电压。
- 3)以 0.2 C 的放电倍率对电池进行放电,当 SOC 减少 10%时停止放电,静置 1 h 候记录此刻开路电压。
- 4)重复步骤 2)直至电池 SOC 降至 10%。
- 5)以 0.2 C 的放电倍率对电池进行放电,在 SOC 为 5%、0%时按照步骤 2)对电池进行静置处理并记录相应开路电压。

根据实验获得的数据进行多项式拟合以构建 OCV-SOC 曲线,考虑到多项式拟合阶数所造成的过拟合、欠拟合问题,选择六阶多项式进行拟合处理,结果如图 2 所示。




图 2 OCV-SOC 曲线(六阶)

最终得到的六阶多项式解析式如式(6)所示。

$$U_{oc} = 13.339 \times SOC^6 - 43.389 \times SOC^5 + 50.866 \times SOC^4 - 24.399 \times SOC^3 + 3.227 \times SOC^2 + 1.193 \times SOC + 3.299 \quad (6)$$

2 电池模型的参数在线辨识

锂电池在充放电过程中伴随着内部复杂的化学反应,伴随着工作状态的改变,电池模型各电气元件参数也会发生变化,影响 SOC 的估算。在线辨识方法通过采集到的电流、电压值对电流模型参数进行修正并实时更新,相较于离线辨识法具有适应强、精度高的特点,能够准确反映电路系统的实时特性。

2.1 二阶 R-C 电路的最小二乘法形式

最小二乘法因为其结构简单,算法收敛迅速的特点被广泛地应用于参数估计领域。使用最小二乘法前,要将二阶 R-C 电路模型变换为形如式(7)的形式。

$$Y = \varphi \times \theta \quad (7)$$

对式(3)进行拉氏变换,得到 s 域上的观测方程如式(8)所示。

$$U_i(s) - U_{oc}(s) = I(s) \left(\frac{R_1}{1 + sR_1C_1} + \frac{R_2}{1 + sR_2C_2} + R_0 \right) \quad (8)$$

式中:s 为 s 域上的拉普拉斯算子。

记 $G(s) = \frac{U_i(s) - U_{oc}(s)}{I(s)}$ 为电池模型在 s 域上的传递函数,结合式(9)对式(8)进行双线性变换:

$$s = \frac{2}{\Delta t} \times \frac{1 - Z^{-1}}{1 + Z^{-1}} \quad (9)$$

式中:Z = e^{Δt·s} 为 Z 变换算子,得到在 Z 域上的传递函数如式(10)所示。

$$G(Z^{-1}) = \frac{a_3 + a_4 Z^{-1} + a_5 Z^{-2}}{1 - a_1 Z^{-1} - a_2 Z^{-2}} \quad (10)$$

式中:a₁, a₂, a₃, a₄, a₅ 为待定系数。对式(10)进行差分处理,得到形如式(11)的差分公式:

$$y(k) = a_1 y(k-1) + a_2 y(k-2) + a_3 I(k) + a_4 I(k-1) + a_5 I(k-2) \quad (11)$$

式中:y(k) 为 k 时刻开路电压与端电压的差值。记 $\varphi = (y(k-1), y(k-2), I(k), I(k-1), I(k-2))^T$, $\theta = (a_1, a_2, a_3, a_4, a_5)$, 将式(11)转换为形如式(7)的最小二乘形式。

2.2 基于自适应遗忘因子的递推最小二乘法

本文采用的自适应遗忘因子递推最小二乘法,通过引入可变遗传因子克服了单一递推最小二乘法在大数据量下受陈旧数据影响产生的“数据饱和”现象,能够实时反应新数据的特性。同时,动态的遗传因子对递推模型的新旧数据比例进行实施修正,提高了在线辨识的准确性。自适应遗忘因子递推方程为:

$$\begin{cases} \lambda(k) = 1 - \frac{e^2(k)}{(1 + \varphi(k-1-l)\mathbf{P}(k-1)\varphi^T(k-1-l)) \times r} \\ \hat{\theta}(k) = \hat{\theta}(k-1) + \mathbf{K}(k) \times e(k) \\ \mathbf{K}(k) = \frac{\mathbf{P}(k-1)\varphi^T(k-1)}{\lambda(k) + \varphi(k-1)\mathbf{P}(k-1)\varphi^T(k-1)} \\ \mathbf{P}(k) = \frac{1}{\lambda(k)}[\mathbf{E} - \mathbf{K}(k)\varphi(k-1)]\mathbf{P}(k-1) \end{cases} \quad (12)$$

式中： \mathbf{E} 为单位矩阵， \mathbf{P} 为误差协方差矩阵， \mathbf{K} 为增益矩阵， λ 为可变遗传因子， l, r 为加权调节系数，估计误差 $e(k) = y(k) - \varphi(k-1) \times \hat{\theta}(k-1)$ 。

将式(8)进行通分处理并与式(10)对比，由待定系数法得到各电器元件参数的辨识方程组：

$$\begin{cases} \tau_1 + \tau_2 = \frac{1 + a_2}{1 - a_1 - a_2} \times \Delta t \\ \tau_1 \tau_2 = \frac{1 + a_1 - a_2}{1 - a_1 - a_2} \times \frac{\Delta t^2}{4} \\ R_0 + R_1 + R_2 = \frac{a_3 + a_4 + a_5}{1 - a_1 - a_2} \\ R_0 \tau_1 + R_0 \tau_2 + R_1 \tau_2 + R_2 \tau_1 = \frac{a_3 - a_5}{1 - a_1 - a_2} \times \Delta t \\ R_0 \tau_1 \tau_2 = \frac{a_3 - a_4 + a_5}{1 - a_1 - a_2} \times \frac{\Delta t^2}{4} \end{cases} \quad (13)$$

使用式(12)实时估算最优参数矩阵 θ ，并将估算的参数代入式(13)，得到电池模型中各项电气元件的参数。自适应递推最小二乘法能够准确地估算各电气元件的参数，为下文建立精确地状态空间方程提供了基础。

3 联合算法在线估算 SOC

3.1 AEKF 的 SOC 估算原理

卡尔曼滤波法是基于最小均方差准则，通过状态空间表达式结合上一时刻的估计值、当前时刻输出值，迭代求解当前时刻最优估计值的估算方法。但是传统的卡尔曼滤波法只适用于线性模型，对非线性系统适应性较差。针对锂电池模型所体现的高度非线性，扩展卡尔曼滤波法通过对模型非线性部分进行泰勒展开，并忽略高阶项的误差，使系统线性化，进而利用卡尔曼滤波法进行估算。

电池模型的非线性离散形式表示为：

$$\begin{cases} x_{k+1} = f(x_k, u_k) + \omega_k \\ y_k = g(x_k, u_k) + \nu_k \\ \omega_k \sim (q_k, \mathbf{Q}(k)) \\ \nu_k \sim (r_k, R(k)) \end{cases} \quad (14)$$

式中： x_k 为 k 时刻的状态变量， y_k 为 k 时刻的输出变量， u_k 为 k 时刻的观测值，假设过程噪声与观测噪声为互相独立的高斯噪声， ω_k 均值为 q_k ，协方差为 $\mathbf{Q}(k)$ ， ν_k 均值为 r_k ，协方差为 $R(k)$ 。

将非线性函数 $f(x, u), g(x, u)$ 在估计点 x_k 处进行一阶泰勒展开，则有：

$$\begin{cases} f(x_k, u_k) = f(\hat{x}_k, u_k) + \frac{\partial f}{\partial x_k}(x_k - \hat{x}_k) \\ g(x_k, u_k) = g(\hat{x}_k, u_k) + \frac{\partial g}{\partial x_k}(x_k - \hat{x}_k) \end{cases} \quad (15)$$

将式(15)代入式(14)并进行离散化处理，最终得到电池系统的状态方程、观测方程如式(16)所示。

$$\begin{cases} x_{k+1} = \mathbf{A}x_k + \mathbf{B}u_k + q_k \\ y_k = \mathbf{C}_k x_k + \mathbf{D}_k u_k + r_k \end{cases} \quad (16)$$

取 $[\text{SOC}, U_1, U_2]^T$ 作为状态向量 x_k ，电流 I 为输入量 u_k ，端电压 U_i 为输出量 y_k ，对照式(4)确定式(16)的 4 个矩阵如式(17)所示。

$$\begin{cases} \mathbf{A}_k = \frac{\partial f}{\partial x} \Big|_{x=x_k} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{\Delta t}{\tau_1(k)}} & 0 \\ 0 & 0 & e^{-\frac{\Delta t}{\tau_2(k)}} \end{bmatrix} \\ \mathbf{B}_k = \begin{bmatrix} -\frac{\Delta t}{Q_n} & R_2(k)(1 - e^{-\frac{\Delta t}{\tau_1(k)}}) & R_2(k)(1 - e^{-\frac{\Delta t}{\tau_2(k)}}) \end{bmatrix}^T \\ \mathbf{C}_k = \frac{\partial g}{\partial x} \Big|_{x=x_k} = \begin{bmatrix} \frac{\partial U_{\text{SOC}}}{\partial \text{SOC}} \Big|_{x=x_k} & -1 & -1 \end{bmatrix} \\ \mathbf{D}_k = -R_0(k) \end{cases} \quad (17)$$

传统的 EKF 算法中，将观测噪声、状态噪声设定为固定值。受道路情况、环境温度等因素的影响，动力电池的实际工作环境较为复杂，EKF 法无法适应实际噪声的变化趋势。AEKF 算法利用每一时刻测量数据的变化，实时估计和修正系统的过程噪声和测量噪声，使算法中的噪声统计能随着工作环境与估计值的变化自适应更新，具有更高的估计精度。AEKF 算法的估算流程如下：

1) 确定初始状态，对算法进行初始化。

$$\begin{cases} \hat{x}_{0|0} = \mathbf{E}[x_0] \\ \mathbf{P}_{0|0} = \mathbf{E}[(x_{0|0} - \hat{x}_{0|0})(x_{0|0} - \hat{x}_{0|0})^T] \end{cases} \quad (18)$$

2) 计算状态向量的先验估计值，并对协方差矩阵进行预估。

$$\begin{cases} \hat{x}_{k|k-1} = \mathbf{A}_k \hat{x}_{k-1|k-1} + \mathbf{B}_k u_{k-1} + q_{k-1} \\ \mathbf{P}_{k|k-1} = \mathbf{A}_k \mathbf{P}_{k-1|k-1} \mathbf{A}_k^T + \mathbf{Q}_{k-1} \end{cases} \quad (19)$$

3) 计算卡尔曼增益矩阵。

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{C}_k^T (\mathbf{C}_k \mathbf{P}_{k|k-1} \mathbf{C}_k^T + \mathbf{R}_k)^{-1} \quad (20)$$

4) 结合先验估计值与观测值误差对先验估计值进行修正。

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + \mathbf{K}_k (y_k - (\mathbf{C}_k \hat{x}_{k|k-1} + \mathbf{D}_k u_k + r_k)) \quad (21)$$

5) 更新误差协方差矩阵。

$$\mathbf{P}_{k|k} = (\mathbf{E} - \mathbf{K}_k \mathbf{C}_k) \mathbf{P}_{k|k-1} \quad (22)$$

6) 更新观测噪声与状态噪声的均值。

$$\begin{cases} d_k = (1-b)/(1-b^k) \\ q_k = (1-d_k)q_{k-1} + d_k(\hat{x}_{k|k} - \hat{x}_{k-1|k-1}) \\ r_k = (1-d_k)r_{k-1} + d_k(y_k - (C_k\hat{x}_{k|k-1} + D_k u_k)) \end{cases} \quad (23)$$

式中: d_k 为更新数据的权重分配, b 为遗忘因子, 本文中取 0.97。

7) 更新观测噪声与状态噪声的误差矩阵。

$$\begin{cases} e_k = y_k - \hat{y}_k \\ Q_k = (1-d_k)Q_{k-1} + d_k K_k e_k e_k^T K_k^T \\ R_k = (1-d_k)R_{k-1} + d_k (e_k e_k^T - C_k P_{k|k} C_k^T) \end{cases} \quad (24)$$

式中: e_k 为测量端电压与估计端电压的误差。式(18)~(22)为扩展卡尔曼法的滤波过程, 先采用递归形式计算预测值, 然后利用卡尔曼增益和测量得到的电压、电流数据, 对预测值进行纠偏。式(23)~(24)利用新息矩阵对噪声的均值、误差矩阵进行实时更新并传入下一状态对参与滤波过程, 实现自适应的功能。

3.2 ARWLS-AEKF 联合算法原理

在 1、2 节中, 详细介绍了自适应加权最小二乘法与自适应扩展卡尔曼滤波法的实现流程与细节。将两种算法联合使用, 可以对锂电池实现准确的 SOC 估计, 其具体流程如图 3 所示。

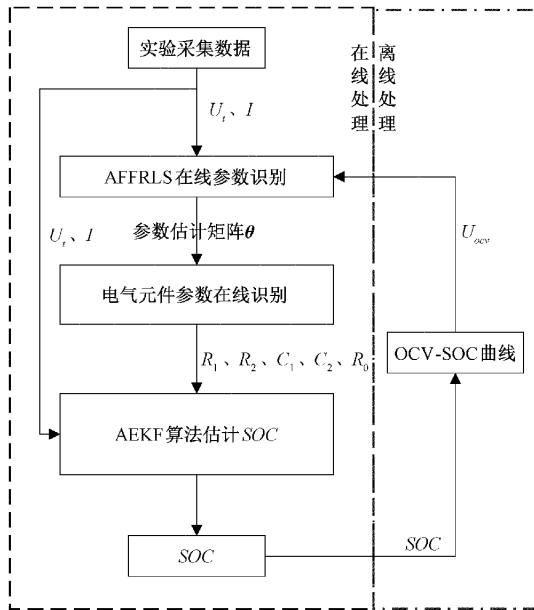


图 3 联合算法流程

利用采集的电流、电压数据, 通过 ARWLS 法实时进行估算, 并将输出的参数矩阵通过式(13)转换为各电气元件的参数。将该参数代入式(17), 基于 AEKF 法对 SOC 进行估算。将估算的 SOC 值通过 OCV-SOC 曲线获得开路电压 U_{oc} 参与下一循环的运算。由此循环递推即可获得任意时刻下, 电路模型的值与 SOC。ARWLS-AEKF 联合算法对电池模型参数进行了在线辨识并通过递推过程实

现了噪声矩阵与遗忘因子的闭环修正, 提升了整个系统的鲁棒性, 降低了算法对噪声的敏感度。

4 结果验证与分析

4.1 二阶 R-C 网络精度验证

首先对等效电路模型的端电压进行验证, 以保证 ARWLS-AEKF 联合算法的准确性。验证方式为端电压验证, 即将模型中的仿真电压 U_i 与实际测量结果进行对比。验证工况选用了 LA_92、UDDS 与 HWFET 工况, 3 种测试工况的测试周期分别为 1 435、1 370、765 s, 每个循环下的速度、电流曲线如图 4 所示。




图 4 测试工况速度、电流曲线

LA_92 与 UDDS 为典型的城市行车工况, 侧重于模拟动力电池在城市驾驶条件下的负载变化, HWFET 为高速工况, 用以反映动力电池在高速行驶情况下的负载变化。使用 MATLAB 的 m 语言脚本依据上文的算法流程编写相应程序, 将 3 种工况的电流、电压数据分别输入程序, 记录输出的仿真电压并与实际测量电压进行对比, 结果如图 5 所示。在 3 种工况下, 等效电路的预测值与测量端电压基本吻合, 相对误差在 1.5% 之间, 具有较高的精度。仿真末期电池 SOC 小于 5%, 内部参数变化剧烈, 造成了相对误差的小幅升高, 但仍保持在 $\pm 2\%$ 。3 种工况下的端电压验证结果说明, ARWLS-AEKF 联合算法所建立的二阶 R-C 网络模型有较高的精准度, 在多种负载变化情况下均能准确地反映动力电池的瞬时特性与工作状态。

4.2 ARWLS-AEKF 的 SOC 估算验证

基于 LA_92、UDDS、以及 HWFET 3 种工况对 ARWLS-AEKF 算法进行验证, 由于 SOC 的初始值难以获得, 本文以将实验室状态下通过安时积分得到的 SOC 作为基准值, 定义为 SOC_{True} , 分别使用离线辨识 EKF 算法与 ARWLS-AEKF 算法对 SOC 进行估算, 仿真过程中通过 random 函数模拟随机生成的噪声均值与协方差, 结果如图 6 所示。仿真初期, EKF 算法并不能很好地追踪 SOC




图 5 LA_92、UDDS、HWFET 工况下的电压验证




图 6 LA_92、UDDS、HWFET 工况下的 SOC 验证

曲线,出现了较大的误差波动,这是由于 EKF 算法的噪声均值、协方差矩阵是固定值,无法适应仿真过程中随机生

成的噪声。ARWLS-AEK 算法通过实时更新噪声状态参数,迅速地收敛到了 SOC-True,误差不超过 2%。仿真中

期,EKF 算法误差减小,但仍在 2% 以上,ARWLS-AEKF 算法较 EKF 算法波动性较小,误差保持在 2% 以内。仿真末期,电池各项参数变化加剧,EKF 算法由于参数离线识别过程与 EKF 滤波过程没有形成闭环反馈,自校正能力较弱不能及时地调整辨识参数,致 SOC 估算误差增大超过 4%。

ARWLS-AEKF 算法利用在线辨识方法,实时地将电池参数传递给 AEKF 滤波算法,在 $SOC < 0.1$ 时,估算误差虽有上升,但仍保持在 2% 的范围内。

为表征算法整体的估算准确度,本文使用平均绝对误差(mean absolute error, MAE)与均方根误差(root-mean-square error, RMSE)作为 SOC 估算结果的评价指标,MAE, RMSE 的计算公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |SOC(i) - SOC_{pre}(i)| \quad (25)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (SOC(i) - SOC_{pre}(i))^2} \quad (26)$$

式中: n 为总样本数, SOC 为真实 SOC, SOC_{pre} 为算法预测 SOC。

由式(18)、(19)可知,MAE, RMSE 值越小代表算法精度越高,3 种工况下的 MAE, RMSE 值如表 2 所示。

表 2 3 种验证工况下的 MAE、RMSE

评价指标	算法	LA/%	UDDS/%	HWFET/%
MAE	EKF	1.53	2.17	3.59
	ARWLS-AEKF	0.45	0.74	0.58
RMSE	EKF	1.66	2.31	3.88
	ARWLS-AEKF	0.54	0.81	0.67

LA_92、UDDS 工况下 ARWLS 算法的 MAE 值为 0.45%、0.74%, RMSE 值为 0.54%、0.81%, 均小于 EKF 算法。在 HWFET 工况下, EKF 算法的表现较 ARWLS-AEKF 算法差异较大, MAE、RMSE 值分别为 3.59%、3.88%, 而 ARWLS-AEKF 算法的 MAE、RMSE 值仍在 1% 以内, 分别为 0.58%、0.6%。这是因为 HWFET 工况侧重于车辆的高速行驶状态, 动力电池的电流负荷较大, 在充放电状态转换时会引起更大的波动, 使 EKF 算法的估算误差变大。

综上所述, ARWLS-AEKF 算法精度较高, 能在时变的噪声环境对 SOC 进行准确预估, MAE、RMSE 值均在 1% 以内。对城市驾驶条件与高速路段驾驶条件, 都表现出了很好的适应性。

5 结 论

为减小电池管理系统中 SOC 的估算误差, 本文以锂离子电池作为研究对象, 使用二阶 R-C 网络作为电池模型, 通过自适应加权算法引入可变遗忘因子优化参数辨识过

程。同时考虑噪声的变化, 利用新息矩阵对噪声参数进行更新, 完成 AEKF 算法的构建。将两种方法联合, 以 ARWLS-AEKF 算法对电池的 SOC 进行在线估算。结果表明, ARWLS-AEKF 算法能够实现电池模型参数的在线辨识, 为 SOC 估算提供可靠支持。在 LA_92、UDDS、HWFET 3 种工况下, ARWLS-AEKF 算法均能适应变化的噪声环境, 与真实 SOC 误差均在 2% 以内, MAE、RMSE 值在 1% 以内。相比与离线辨识的 EKF 法, ARWLS-AEKF 算法能提高 SOC 估算精度, 收敛速度快、鲁棒性强。

参考文献

- [1] 詹大琳, 黄丽莹, 卢欣欣. 基于 BMS 的电动汽车电池管理系统控制[J]. 专用汽车, 2022(2): 18-21.
- [2] 郝世宇, 殷会飞, 杨茹, 等. 基于 AEKF 的锂离子动力电池荷电状态估计[J]. 国外电子测量技术, 2021, 40(9): 49-53.
- [3] 章群, 严世榕. 电动汽车动力锂电池模型参数辨识[J]. 机电工程, 2016, 33(12): 1506-1510.
- [4] 孙鹏宇, 李建良, 陶知非, 等. 动态工况电池在线参数辨识及 SOC 估计研究[J]. 电子测量与仪器学报, 2021, 35(1): 10-17.
- [5] 段洋. 电动汽车用锂离子电池 SOC 估算方法研究[D]. 长沙: 湖南大学, 2018.
- [6] 王建锋, 张照震, 李平. 基于加权自适应递推最小二乘法与 EKF 的锂离子电池 SOC 估计[J]. 汽车技术, 2021(10): 16-22.
- [7] NGK S, HUANG Y F, MOO C S, et al. An enhanced coulomb counting method for estimating state-of-charge and state-of-health of lead-acid batteries [C]. INTELEC 2009-31st International Telecommunications Energy Conference, IEEE, 2009: 1-5.
- [8] 谢路耀, 华思聪, 陈怡, 等. 基于容量修正的安时积分法研究[J]. 浙江工业大学学报, 2021, 49(4): 403-408.
- [9] 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.
- [10] 熊瑞. 基于数据模型融合的电动车辆动力电池组状态估计研究[D]. 北京: 北京理工大学, 2014.
- [11] 符容. 基于 EKF 的锂离子电池 SOC 估计的非线性因素研究[D]. 长春: 吉林大学, 2019.
- [12] 封居强, 伍龙, 黄凯峰, 等. 基于 FFRLS 和 AEKF 的锂离子电池 SOC 在线估计研究[J]. 储能科学与技术, 2021, 10(1): 242-249.
- [13] 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.

- [14] 安诺静. 基于 EKF 的电动汽车用锂离子电池 SOC 估计方法研究[D]. 西安:长安大学, 2020.
- [15] 刘征宇, 朱诚诚, 尤勇, 等. 面向 SOC 估计的计及温度和循环次数的锂离子电池组合模型[J]. 仪器仪表学报, 2019, 40(11): 117-127.

作者简介

田元武, 硕士研究生, 主要研究方向为新能源汽车检测技术。

张诗建, 工程师, 主要研究方向为汽车测试与评价。

周博雅, 高级工程师, 主要研究方向为汽车测试与评价。

黎苏(通信作者), 教授, 主要研究方向为新能源汽车检测技术。

E-mail: lewis_1001@163.com