

# 自适应卡尔曼滤波器在车用锂离子动力电池 SOC 估计上的应用<sup>①</sup>

熊 瑞<sup>②</sup> 孙逢春 何洪文

(北京理工大学电动汽车国家工程实验室 北京 100081)

**摘要** 进行了用自适应扩展卡尔曼滤波(AEKF)算法估计电动车用锂离子动力电池的荷电状态(SOC)的研究。基于混合脉冲功率特性(HPPC)试验,利用遗传优化算法改进Thevenin 电路模型参数辨识方法,且从充放电两个方向来获得模型参数,然后在动态应力测试(DST)工况下对改进的模型进行仿真验证分析,基于改进的模型和联邦城市行驶工况(FUDS),应用 AEKF 算法开展 SOC 估计研究。仿真和台架试验结果对比表明,改进的 Thevenin 电路模型和 AEKF 算法均具有较高的精度,最大估算误差分别为 1.70% 和 2.53%;同时 AEKF 算法具有较好的鲁棒性,可以有效地解决初始估算不准和累计误差的问题。

**关键词** 自适应扩展卡尔曼滤波(AEKF), 荷电状态(SOC), 参数辨识, 电池模型, 锂离子电池, 电动汽车

## 0 引言

电池管理系统是电动汽车的一个关键部件,对电池的荷电状态(state of charge, SOC)做出准确估计是该部件的主要功能之一。准确的 SOC 估计是进行电动汽车整车控制优化的先决条件,也是合理实施电池管理的依据<sup>[1-3]</sup>。

常用的蓄电池 SOC 估计方法有 4 类:(1)基于电池表征参数测量值的估计方法,如开路电压法、内阻法等。由于汽车多变的工况、复杂的应用环境会导致表征参数测量困难,此类方法难以实际应用<sup>[4]</sup>。(2)基于经验方程和数学模型的估计方法。模型基于先期的试验数据获得,虽然在使用初期能够获得较好的估计效果,但由于模型的固定性,随着使用时间的增加和电池性能的衰减,导致模型偏差加大、SOC 估计误差加大<sup>[5]</sup>。(3)基于安时计量的估计方法。在 SOC 的初值比较精确以及电流传感器精度足够好的前提下,可以获得较好的 SOC 估计<sup>[4]</sup>。(4)基于卡尔曼滤波算法的估计方法。卡尔曼递推滤波算法在 SOC 估算上取得了很好的成效,但是该算法对动力电池模型的精度具有很强的依赖性,而且需要复杂的高计算量的矩阵求逆运算,对噪声的初值的选择十分敏感,错误的先验信息容易导

致算法发散<sup>[6,7]</sup>。本文以额定电压为 57.6V,额定电容量为 100Ah 的锰酸锂电池为研究对象,基于改进的 Thevenin 电路模型,应用自适应扩展卡尔曼滤波(adaptive extended Kalman filter, AEKF)算法开展 SOC 估计的研究。该 AEKF 算法具有较好的发散抑制性和鲁棒性,可以改善常规卡尔曼滤波算法对电池模型的依赖程度,同时也可对不确定信息进行实时估计和修正。通过台架试验证明,该算法有较高的精度和可靠性。

## 1 等效电路模型的建立

Thevenin 等效电路模型相比 Rint 模型、RC 模型以及 PNGV 模型等具有更好的动态适应性,可以更加准确地模拟锂离子动力电池的动态特性,具体如图 1 所示<sup>[4,8]</sup>。

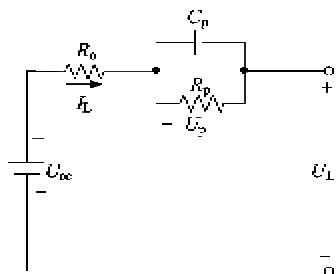


图 1 Thevenin 模型电路结构

① 863 计划(2008AA11A124,2011AA112304,2011AA11A228,2011AA1290)资助项目。

② 男,1985 年生,博士生;研究方向:节能技术与新能源应用;联系人,E-mail: rxiongbit@hotmail.com  
(收稿日期:2010-10-08)

图1中,  $R_p$  和  $C_p$  分别为极化内阻和极化电容,  $U_p$  为  $R_p$  引起的电压降且表示电池的极化电压,  $R_0$  描述电池的欧姆内阻,  $U_{oc}$  描述电池的开路电压,  $U_R$  为内阻上产生的电压降,  $I_L$  描述端电流,  $U_L$  描述端电压。模型中各参数均为 SOC 和温度的函数, 鉴于本文的试验在恒温箱中进行(温差 < 5℃), 暂时不考虑温度对各参数的影响, 则各参数为 SOC 的函数。

根据基尔霍夫电压定律和基尔霍夫电流定律, 以及电容电压变化与其电流的关系, 可得 Thevenin 等效电路模型的电路方程:

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

### 1.1 模型参数辨识

为进行模型参数辨识, 对锂离子电池模块开展了混合脉冲功率特性(hybrid pulse power characterization, HPPC) 试验<sup>[9]</sup>, 试验在等间隔(10%) 的 SOC 点进行, 然后在不同 SOC 之间使用 C/3 恒流放电完成电池组 SOC 试验点的切换, 相邻脉冲之间处于搁置状态, 搁置时间为 2h。为了区分电池的放电与充电, 假设电池放电时电流为正、充电时电流为负。定义时间常数  $\tau = R_p C_p$ , 对式(1)进行离散化:

$$\begin{cases} U_{L,i} = U_{oc} - R_0 I_{L,i} - R_p I_{p,i} \\ I_{p,i} = \left\{ 1 - \frac{[1 - \exp(-\Delta t/\tau)]}{(\Delta t/\tau)} \right\} \times I_{L,i} \\ + \left\{ \frac{[1 - \exp(-\Delta t/\tau)]}{(\Delta t/\tau)} - \exp(-\Delta t/\tau) \right\} \\ \times I_{L,i-1} + \exp(-\Delta t/\tau) \times I_{p,i-1} \end{cases} \quad (2)$$

应用式(2)进行拟合前需要获得电路的时间常数, 传统的方法为试值法<sup>[4,8]</sup>。为更加合理地选取时间常数  $\tau$ , 本文引入遗传优化算法。记时间常数矩阵为  $\tau = \text{diag}(\tau_1, \tau_2, \tau_3)$ , 假设时间常数矩阵的对角元素均相等, 即  $\tau_1 = \tau_2 = \tau_3 = \tau$ , 则待优化的参数矢量可表示为  $\chi = \tau^T$ 。时间常数的优化是以实际采样端电压  $U_L$  与模型输出值  $\hat{U}_L(\hat{\chi}_{k,i}^{(g)})$  误差的均方差最小为目的, 即定义如下目标函数:

$$\begin{cases} \min_N \{f(\hat{\chi}_i^{(g)})\} \\ f(\hat{\chi}_i^{(g)}) = \frac{1}{N} \sum_{i=1}^N (U_{L,i} - \hat{U}_{L,i}(\hat{\chi}_k^{(g)}))^2 \end{cases} \quad (3)$$

式中,  $\hat{\chi}_k^{(g)}$  表示遗传到第  $g$  代时第  $k$  个体的辨识值;  $N$  为估计长度,  $N$  越大, 搜索范围越广, 但每代的遗

传操作时间越长, 反之,  $N$  越小, 遗传操作时间越短, 但搜索范围越小, 本文计算取  $N = 200$ 。线性回归的精度可以通过确定系数

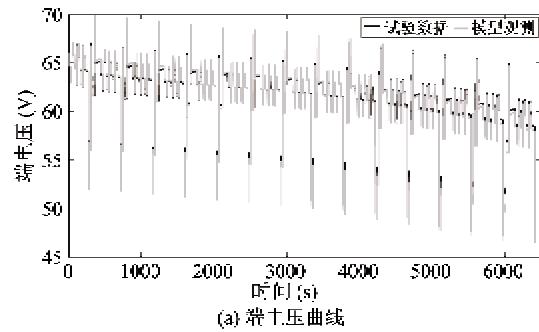
$$r^2 = \frac{\sum (\hat{U}_L - \bar{U}_L)^2}{\sum (U_L - \bar{U}_L)^2} \quad (4)$$

来判断, 原则上超过 0.99 即可<sup>[10]</sup>。式中  $\hat{U}_L$  和  $\bar{U}_L$  分别为  $U_L$  的观测值和均值。应用遗传优化算法获得最优的时间常数  $\tau$ , 结合式(2)采用线性回归算法便可拟合得到模型参数。其中, 辨识后的开路电压  $U_{oc}$  与 SOC 的关系可以拟合为

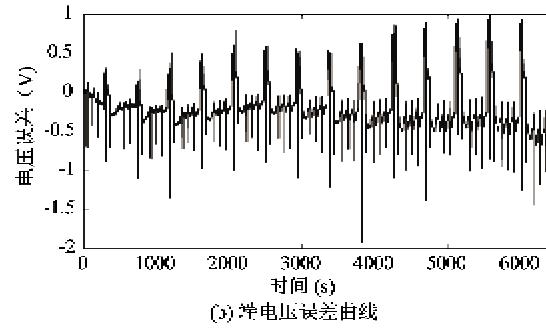
$$U_{oc} = 22 \times SOC^4 - 39 \times SOC^3 + 18 \times SOC^2 + 5.8 \times SOC + 59 \quad (5)$$

### 1.2 模型验证

选用动态应力测试(dynamic stress test, DST) 循环工况, 获得的端电压试验结果与模型仿真结果对比如图2(a)所示, 端电压误差曲线如图2(b)所示, 端电压误差绝对值统计结果见表1。Thevenin 模型的最大误差在 2% 以内, 并且误差较迅速地收敛于 0.1572V 的均值误差, 具有较高的精度, 能够很好地模拟锂离子动力电池的动态特性。



(a) 端电压曲线



(b) 端电压误差曲线

图2 DST 动态工况下的端电压及误差电压差曲线

表1 模型误差绝对值统计分析

最大误差(V)	均值误差(V)	误差方差(V <sup>2</sup> )	最大误差率
0.9809	0.1572	0.0234	1.70%

## 2 锂离子动力电池 SOC 估计

### 2.1 AEKF 算法

自适应滤波的目的之一是在利用量测数据进行递推滤波的同时,不断地由滤波本身去判断目标动态是否有变化。当判断到目标动态有变化时,要进一步决定是把这种变化当作随机干扰,归到模型噪声中去,还是对原动态模型进行修正,使之适应目标变化的动态。另一个目的,是当系统噪声方差和观测噪声方差未知或近似已知时,利用观测数据带来的信息,由滤波本身不断地估计和修正噪声统计特性或滤波器增益阵,提高滤波精度<sup>[11,12]</sup>。为克服算法运算实时性差的缺点,本文引进滤波发散判断条件(式(16)),在判断出滤波结果超出预先设定的发散条件下,才启动噪声估计器开始自适应滤波推算,这样既可避免滤波发散,有效提高滤波计算的稳定性,又可以提高推算的实时性。

设离散系统的状态方程和观测方程分别为

$$\begin{cases} X_k = A_{k-1}X_{k-1} + B_{k-1}u_{k-1} + \Gamma_{k-1}w_{k-1} \\ Y_k = C_kX_k + D_ku_k + v_k \\ v_k \sim (\mathbf{r}_k, R_k) \\ w_k \sim (q_k, Q_k) \end{cases} \quad (6)$$

其中  $X$  为  $n \times 1$  状态向量,  $Y$  为  $m \times 1$  观测矩阵,  $A$ 、 $B$ 、 $C$ 、 $D$  和  $\Gamma$  分别为  $n \times n$ 、 $n \times 1$ 、 $m \times n$ 、 $m \times 1$  和  $n \times n$  的矩阵,  $u$  为系统的输入矩阵,  $w$  和  $v$  分别为带有均值  $\mathbf{r}$ 、协方差  $R$  的测量噪声和均值  $q$ 、协方差  $Q$  的过程噪声。

Sage 和 Husa 给出了基于观测  $Y$  的噪声统计极大后验次优无偏估计器<sup>[13]</sup>,但是其给出的系统噪声统计极大后验次优无偏估计器各式都是算术平均,和式中每项的加权系数都为  $1/k+1$ ,对于时变噪声而言,应更多地强调新近数据的作用,本文应用指数加权方法,即和式中每项乘以不同的指数加权系数应选取加权系数  $\beta_k$ ,使之满足

$$\beta_i = \beta_{i-1}b, \quad 0 < b < 1, \quad \sum_{i=0}^k \beta_i = 1 \quad (7)$$

从而得到

$$\beta_i = d_k b, \quad d_k = \frac{1-b}{1-b^{k+1}} \quad (i = 0, 1, 2, \dots, k) \quad (8)$$

其中  $b$  为遗忘因子。在 Sage 和 Husa 等人的噪声估计器<sup>[13]</sup>中每项乘以  $\beta_{k-1}$ ,代替原来的  $1/k+1$ ,便得到了时变噪声估计器(考虑到系统(5)中  $\Gamma$  的存在,

定义  $\mathbf{G}_k = [\mathbf{\Gamma}_k^\top \mathbf{\Gamma}_k]^{-1} \mathbf{\Gamma}_k^\top$ :

$$\hat{q}_{k+1} = (1 - d_k)\hat{q}_k + d_k \left\{ G_k \sum_{i=0}^k [\hat{X}_{k+1} - A_k \hat{X}_k - B_k u_k] \right\} \quad (9)$$

$$\begin{aligned} \hat{Q}_{k+1} = & (1 - d_k) \hat{Q}_k + d_k \left\{ G_k \left( \sum_{i=0}^k [K_{k+1} \tilde{Y}_{k+1} \right. \right. \\ & \left. \left. - \tilde{Y}_{k+1}^\top K_{k+1}^\top + P_{k+1} - A_k P_k A_k^\top] \right) G_k^\top \right\} \end{aligned} \quad (10)$$

$$\begin{aligned} \hat{r}_{k+1} = & (1 - d_k) \hat{r}_k + d_k \left\{ \sum_{i=0}^k [Y_{k+1} - C_k \hat{X}_{k+1} \right. \\ & \left. - D_k u_k] \right\} \end{aligned} \quad (11)$$

$$\begin{aligned} \hat{R}_{k+1} = & (1 - d_k) R_k + d_k \sum_{i=0}^k [\tilde{Y}_{k+1} \tilde{Y}_{k+1}^\top \\ & - C_{k+1} P_{k+1}^- C_{k+1}^\top] \end{aligned} \quad (12)$$

其中,误差矩阵为

$$\begin{aligned} \tilde{Y}_{k+1} = & Y_{k+1} - C_{k+1} (A_{k+1} \hat{X}_{k+1} + B_{k+1} u_{k+1}) \\ & - D_{k+1} u_{k+1} - \hat{r}_k \end{aligned} \quad (13)$$

增益矩阵为

$$\mathbf{K}_{k+1} = P_{k+1}^- C_{k+1}^\top [C_{k+1} P_{k+1}^- C_{k+1}^\top + \hat{R}_k]^{-1} \quad (14)$$

式中,状态矩阵的协方差  $P$  的预估值为

$$\begin{cases} P_{k+1}^- = A_k P_k A_k^\top + \Gamma_k Q_k \Gamma_k^\top \\ P_{k+1}^- = (I - K_{k+1} C_{k+1}) P_{k+1}^- \end{cases} \quad (15)$$

AEKF 算法发散判断条件为

$$\tilde{Y}_{k+1}^\top \tilde{Y}_{k+1} \leq r \text{Tr}(E(\tilde{Y}_{k+1}^\top \tilde{Y}_{k+1})) \quad (16)$$

式中  $r \geq 1$  为可调常系数,不同系统采取相应数值,  $r = 9$  时,相当于 3 倍中误差检验,  $\text{Tr}$  表示矩阵的迹。若不满足上式,则认为滤波发散,先验值不准确。

### 2.2 SOC 估算

综合 2.1 节的内容,可得到如图 3 所示的 AEKF 算法的递推计算流程。

根据 SOC 的定义<sup>[14]</sup>,可得 SOC 的计算表达式为

$$SOC = SOC_0 - \frac{\int \eta i_L dt}{C_N} \rightarrow s_k = s_{k-1} - \eta I_{L, k-1} \frac{\Delta t}{C_N} \quad (17)$$

式中,  $s$  为 SOC 的简写,  $SOC_0$  为 SOC 的初始值,  $\eta$  表示充放电效率,  $C_N$  为动力电池的额定容量(与电池的温度和老化等有关,需要多次全充全放试验来标定),  $\Delta t$  表示采样时间步长,本文为 0.5s,  $\Phi_k$  描述  $\Phi$  的第  $k$  步值( $\Phi$  代表任意变量)。基于自适应扩展卡尔曼滤波(AEKF)的 SOC 估算方法是基于安时计量的最优估计方法,实质上是用安时计量法来计

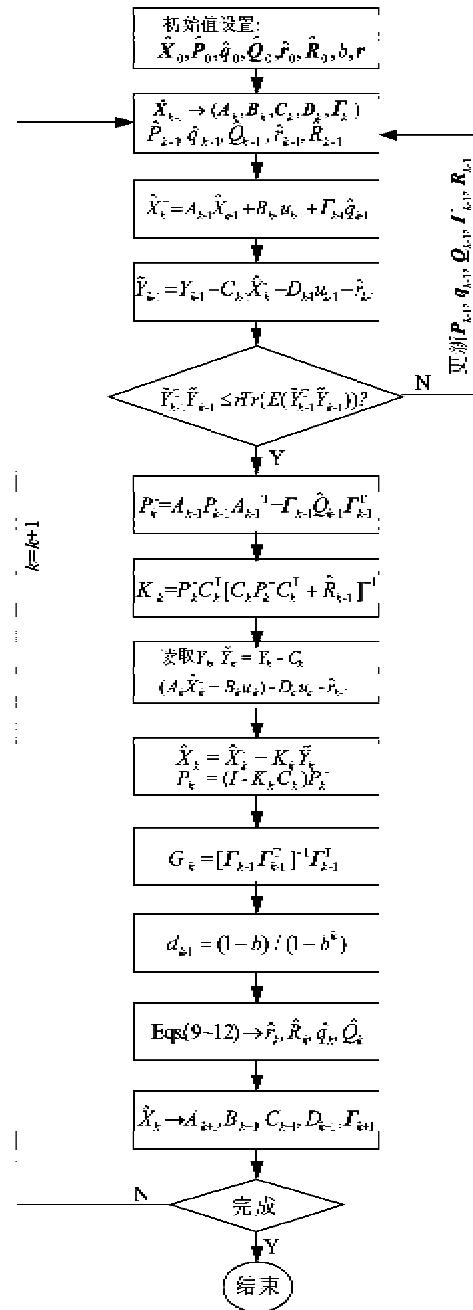


图 3 AKEF 算法流程

算电池 SOC 的同时,用观测的电压值来修正安时计量法算得的 SOC 值。当初始  $SOC_0$  误差较大时,滤波增益矩阵  $K$  的权值也大,对 SOC 的修正作用就强,当初始误差较小时,  $K$  的权值就小,对 SOC 的修正作用也小。这种方法克服了安时计量法难以确定 SOC 初值和累计误差较大的问题,同时也可以有效地滤除测量噪声的影响。

将式(1)离散化,可得式

$$\begin{cases} U_{p,k} = U_{p,k-1} \exp(-\Delta t/(R_p C_p)) \\ + I_{L,k-1} R_p (1 - \exp(-\Delta t/(R_p C_p))) \\ U_{L,k} = U_{u_k}(s_k) - I_{L,k} R_u - U_{p,k} \end{cases} \quad (18)$$

将式(17)和式(18)改写为系统(6)所示状态方程,有

$$\begin{aligned} X &= \begin{pmatrix} U_p \\ s \end{pmatrix} \\ A &= \begin{pmatrix} \exp(-\Delta t/(R_p C_p)) & 0 \\ 0 & 1 \end{pmatrix} \\ B &= \begin{pmatrix} R_p (1 - \exp(-\Delta t/(R_p C_p))) \\ \eta \Delta t / C_s \end{pmatrix} \\ C &= \left. \frac{\partial U_L}{\partial x} \right|_{x=s} = \left[ -1 \quad \frac{dU_{u_k}(s)}{ds} \right], D = [R_u] \end{aligned}$$

结合图 3 的 AKEF 算法流程,可得出 AKEF 算法用于 SOC 估算的原理结构(图 4)。

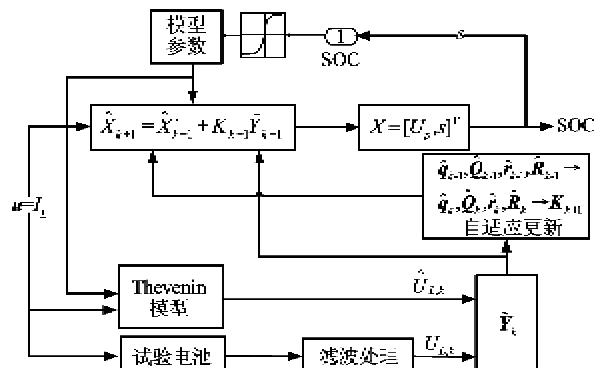


图 4 AKEF 估算 SOC 流程图

### 2.3 台架试验验证

联邦城市行驶工况(Federal Urban Driving Schedules, FUDS)是一种典型的运行工况,常被用来验证各种 SOC 算法<sup>[15]</sup>。本文选取 5 个 FUDS 循环来验证和评价本文所提出的 SOC 算法。噪声的统计特性初值的设定对系统的影响与传统卡尔曼滤波算法不同,传统卡尔曼滤波算法需要较精确的先验信息,而 AKEF 算法可以对不确定信息进行实时在线估计和修正,避免因先验信息不精确而出现的发散现象。AKEF 算法的初始值设定如下:

$$\begin{aligned} \hat{X}_0 &= [0, 0.899]^T, \hat{q}_0 = \hat{r}_0 = [I]_{2 \times 2}, \Gamma = [I]_{2 \times 2} \\ A_1 &= A_0 = \begin{bmatrix} 0.9856 & 0 \\ 0 & 1 \end{bmatrix} \\ B_1 &= B_0 = \begin{bmatrix} 9.8374e^{-005} & 0 \\ 0 & 0.0052 \end{bmatrix} \end{aligned}$$

$$C_1 = C_0 = [-1 \quad 8.3819]^T$$

$$D_1 = D_0 = [0.0242]$$

$$P_0 = \begin{bmatrix} 10 & 0 \\ 0 & 0.1 \end{bmatrix}, R = 20$$

$$\hat{Q}_0 = \begin{bmatrix} 0.001 & 0 \\ 0 & 0.001 \end{bmatrix}$$

通过设定初始值启动图 3 所示的递推过程,便可以实施对动力电池 SOC 的观测。图 5 为 5 个 FUDS 循环下的端电压台架试验值和观测值的对比曲线,图 6 为误差曲线,图 7 为 AEKF 观测器观测的电池的极化电压曲线。

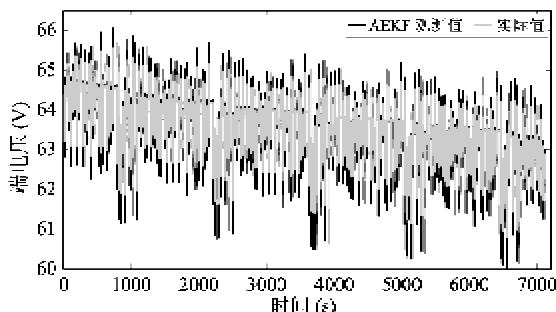


图 5 端电压台架试验值和观测值的对比曲线

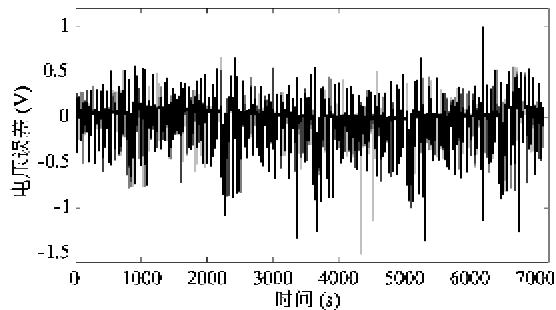


图 6 端电压观测值误差曲线

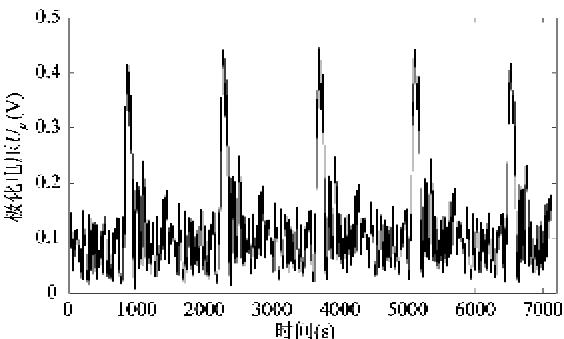


图 7 动力电池极化电压曲线

图 5 和图 6 表明,AEKF 观测器能够较好地观测到动力电池的端电压特性,且具有较高的精度,具

体分析结果见表 2,表 2 为 AEKF 观测器和台架试验端电压误差的绝对值的统计分析结果。

表 2 端电压误差绝对值统计信息

最大误差(V)	均值误差(V)	方差(V <sup>2</sup> )	最大误差率
1.1511	0.0554	0.0187	2%

表 2 表明,AEKF 观测到的端电压与台架试验相比,最大误差率仅为 2%,且观测误差较稳定的收敛于均值误差 0.0554V。图 7 为 AEKF 观测器观测的极化电压曲线,极化电压与动力电池的动态特性有着直接的关系,结合图 5 可知,当大功率输出时,动力电池的端电压会显现较大的电压降,此时动力电池的极化特性也随之变大来减缓动力电池的端电压下降的趋势,因此模型中需要考虑电池的极化特性来提高动态精度。

使用安时计量法确定电池  $SOC_0$  时,电池管理系统一般根据上次停机前记录的 SOC 值和开路电压来确定  $SOC_0$ ,然而由于电池极化、自恢复以及自放电等因素,往往难以获得准确的  $SOC_0$ ,由此会扩大累积误差。为验证本文设计的 AEKF 算法在估计 SOC 时可以有效地解决  $SOC_0$  估计不准以及由此带来的累计误差的问题,本文对不同 SOC 初值时的 AEKF 算法的收敛性进行了仿真分析,图 8 描述了不同 SOC 初值时 AEKF 算法的收敛情况。本文的 SOC 试验值是利用 Digatron EVT 500-500 试验台进行测试的结果,由于 SOC 的真值难以确定,本文利用 Digatron 试验台采用充放电试验法确定电池初始 SOC 值和放电终止时的 SOC 值。充放电试验法得到这两点的值比较精确,在比较精确的 SOC 初值基础上用考虑库仑效率的安时计量法计算,并利用放电试验法的终值 SOC 值对安时计量法修正,从而得图中的试验数据值。充放电试验比较精确但仅限于实验室使用,因此用该方法确定的测量值作为真值和 AEKF 算法进行对比。图 8 中,SOC 的真实初值为 0.899,卡尔曼滤波算法的初值分别设为 1.00,0.95,0.925,0.90,0.875,0.85,0.80 七个不同的值。本文截取 FUDS 试验中的前 20s 来分析 AEKF 算法的鲁棒性。

图 8 表明,当 SOC 初值出现误差时,AEKF 也可以根据模型观测的端电压与试验数据实时在线比较,通过调整滤波增益矩阵  $K$  的权值来实时修正 SOC 估算误差,使 SOC 的观测值能够较快地收敛于真值。由此可见,不同的初值都可以收敛于真实值,

AEKF 不会因为 SOC 的初始误差而造成误差积累, 具有较好的鲁棒性, 同时也表明 SOC 初始误差越大, 收敛的越慢。图 9 为初始值为 0.9 时的 SOC 观测值和试验值的对比曲线, 图 10 为 SOC 的 AEKF 观测值和试验值的误差曲线。

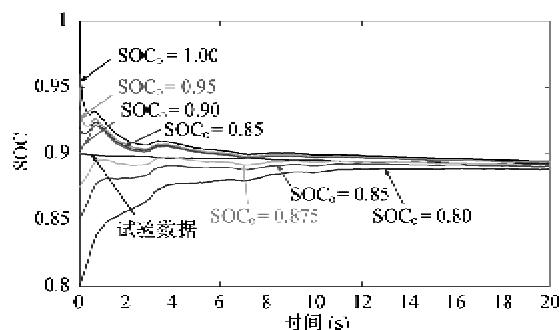


图 8 不同 SOC 初值时 SOC 的观测曲线

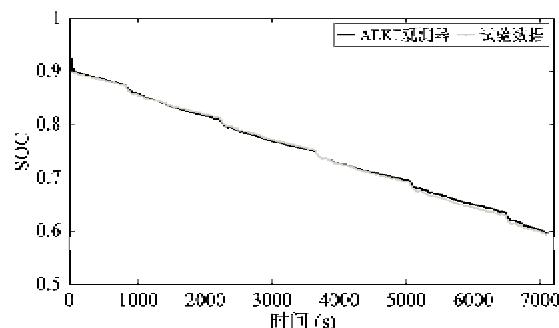


图 9 SOC 观测结果与试验数据对比曲线

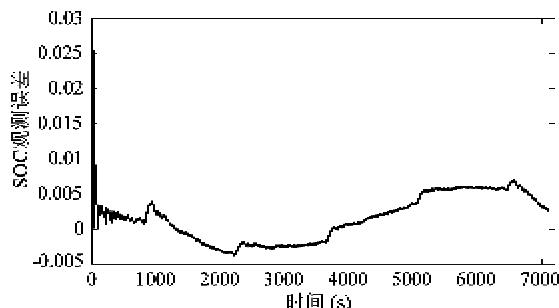


图 10 SOC 观测误差

图 9 和图 10 给出了利用 AEKF 算法的 SOC 估计结果, 试验值表示利用 Digatron EVT 500-500 试验台进行测试的结果。图 10 表明, 不确定信息的设置的误差仅仅造成很短时间的波动, 自适应滤波器可以根据系统的状态实时估计和修正, 具有较好的发散抑制性, 误差迅速降低, 具有较好的精度。表 3 为 SOC 观测误差的绝对值的统计分析。

表 3 SOC 观测误差分析

最大误差	均值误差	方差
0.0253	0.0022	2.2977e-006

以上表明, 文中所采用的基于 AEKF 算法的 SOC 估计方法是适用于锂离子动力电池的动态 SOC 估计的, 通过变功率的 FUDS 工况循环台架试验验证, 估计结果的最大相对误差为 2.53%, 并且误差较稳定地收敛于不到 1% 的均值误差。

### 3 结 论

(1) 通过利用遗传算法优化时间常数的选取和从充放电双方向辨识模型参数来改进 Thevenin 等效电路模型, 获得的改进的模型在 DST 动态工况下的最大误差不到 2%, 能够较好地模拟动力电池的动力特性。

(2) 自适应卡尔曼滤波算法具有较好的发散抑制性和鲁棒性, 不同的 SOC 初值均能够较快地收敛于真值, 能够有效地解决安时计量法的 SOC 初值估算不准以及由此带来误差累积的问题。

(3) 自适应卡尔曼滤波算法可以提高 SOC 估算算法的精度和可靠性, 更适用于整车应用, FUDS 工况验证下的最大误差仅为 2.53%, 且较快地收敛于 0.22% 均值误差。

### 参考文献

- [1] Kaiser R. Optimized battery-management system to improve storage lifetime in renewable energy systems. *Journal of Power Sources*, 2007, 168(1): 58-65
- [2] Plett G. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs - part 3. state and parameter estimation. *Journal of Power Sources*, 2004, 134(2):277-291
- [3] 吴东兴, 关道静, 齐国光. 高精度预测 SOC 的混合电动车电池管理系统的研究. *高技术通讯*, 2006, 16(4): 391-394
- [4] 熊瑞. 插电式混合动力车用复合电源系统仿真研究: [硕士学位论文]. 北京: 北京理工大学, 2010
- [5] Caumont O, Moigne P, Rombaut C, et al. Energy gauge for lead-acid batteries in electric vehicles. *IEEE Transactions on Energy Conversion*, 2000, 15 (3):354-360
- [6] Wang J P, Guo J G, Ding L. An adaptive Kalman filtering based state of charge combined estimator for electric vehicle battery pack. *Energy Conversion and Management*, 2009, 50(12): 3182-3186

- [ 7 ] Wei J Q, Du L M, Yan Z L, et al. Improved Kalman filter-based speech enhancement. In: Proceedings of the 8th European Conference on Speech Communication and Technology, Geneva, Switzerland, 2003. 549-552
- [ 8 ] Zhang C P, Zhang C N, Sharkh S M. Estimation of real-time peak power capability of a traction battery pack used in an HEV. In: Proceedings of the 2010 Asia-Pacific Power and Energy Engineering Conference (APPEEC), Chengdu, China, 2010. 1-6
- [ 9 ] INEEL (Idaho National Engineering & Environmental Laboratory). FreedomCAR Battery Test Manual, Revision 3, DOE/ID-10597, PDF version. [http://avt.inel.gov/battery/pdf/PLUG\\_IN\\_HYBRID\\_Manual%20Rev%200.pdf](http://avt.inel.gov/battery/pdf/PLUG_IN_HYBRID_Manual%20Rev%200.pdf), 2008
- [ 10 ] Sanford W. Applied Linear Regression. Hoboken: A John Wiley & Sons, Inc., Publication, 2005. 19-32
- [ 11 ] Meng Q H, Sun Y C, Cao Z L. Adaptive extended Kalman filter (AEKF)-based mobile robot localization using sonar. *Robotica*, 2000, 18(part5): 459 - 473
- [ 12 ] 严竹旺. 自适应卡尔曼滤波在风场测量中的应用:[硕士学位论文]. 上海:上海交通大学, 2003
- [ 13 ] Sage A P, Husa G W. Adaptive filtering with unknown prior statistics. In: Proceedings of the Joint American Control Conference, Boulder, USA, 1969. 769-774
- [ 14 ] Xiong R, He H, Wang Y, et al. Study on ultracapacitor-battery hybrid power system for PHEV applications. *High Technology Letters*, 2010, 16(1): 23-28
- [ 15 ] 林成涛, 陈全世, 王军平等. 用改进的安时计量法估计电动汽车动力电池 SOC. 清华大学学报(自然科学版), 2006, 46(2): 247-251

## State-of-charge estimation of lithium-ion batteries in electric vehicles based on an adaptive extended Kalman filter

Xiong Rui, Sun Fengchun, He Hongwen

(National Engineering Laboratory for Electric Vehicles, School of Mechanical Engineering,  
Beijing Institute of Technology, Beijing 100081)

### Abstract

An adaptive extended Kalman filter (AEKF) algorithm was adopted to estimate the state-of-charge (SOC) of lithium-ion batteries in electric vehicles. Based on the hybrid pulse power characterization (HPPC) test, an improved Thevenin battery model was achieved by using the genetic algorithm to optimize the parameter identification method and identify the model parameters from the charge direction and the discharge direction respectively. In addition, the improved model was verified under the dynamic stress test cycle. Further, an AEKF algorithm was adopted to design the approach for estimation of SOC of lithium-ion batteries. Finally, the proposed method was verified by the simulation experiment and the bench test under the federal urban driving schedules. It is shown that the improved Thevenin model and the proposed SOC estimation method all have the high accuracy and their maximum errors are 1.70% and 2.53% respectively, and the AEKF algorithm is of robustness and it can efficiently solve the problems of cumulate error and inaccurate initial SOC estimation.

**Key words:** adaptive extended Kalman filter (AEKF), state-of-charge (SOC), parameter identification, battery model, lithium-ion power battery, electric vehicles