

DOI: 10.7652/xjtuxb201812015

双自适应衰减卡尔曼滤波锂电池荷电状态估计

赵云飞^{1,2,3}, 徐俊^{1,2,3}, 王霄^{1,2,3}, 徐浩^{1,2,3}, 梅雪松^{1,2,3}

(1. 西安交通大学陕西省智能机器人重点实验室, 710049, 西安; 2. 西安交通大学机械制造与
系统工程国家重点实验室, 710049, 西安; 3. 西安交通大学机械工程学院, 710049, 西安)

摘要: 针对卡尔曼滤波法在锂离子电池荷电状态(SOC)估计时存在误差较大、收敛较慢等问题,提出了一种双自适应衰减扩展卡尔曼滤波荷电状态估计(DAFEKF)算法。该算法首先设计了针对动力电池的荷电状态估计观测器,利用测得的电流和电压值分别作为观测器的输入和观测值,结合双自适应衰减扩展卡尔曼滤波估计出观测器中的电池荷电状态,在卡尔曼滤波算法的基础上加入时变衰减因子来减弱过去数据对当前滤波值的影响,并自适应地调整卡尔曼算法中过程噪声和测量噪声协方差。利用 DAFEKF 算法估计出的 SOC 结果与扩展卡尔曼滤波(EKF)和自适应扩展卡尔曼滤波(AEKF)算法进行了比较,结果表明,DAFEKF 方法具有较好的准确性、鲁棒性和收敛性,使 SOC 估计误差控制在 2% 以内。

关键词: 锂离子电池; 荷电状态; 自适应卡尔曼滤波; 扩展卡尔曼滤波; 双自适应

中图分类号: TM912.8 **文献标志码:** A **文章编号:** 0253-987X(2018)12-0099-07

An Estimation Method for State of Charge of Lithium-ion Batteries Using Dual Adaptive Fading Extended Kalman Filter

ZHAO Yunfei^{1,2,3}, XU Jun^{1,2,3}, WANG Xiao^{1,2,3}, XU Hao^{1,2,3}, MEI Xuesong^{1,2,3}

(1. Shaanxi Provincial Key Laboratory of Intelligent Robots, Xi'an Jiaotong University, Xi'an 710049, China;
2. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China;
3. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A dual adaptive fading extended Kalman filter(DAFEKF) algorithm is proposed for the problem of low accuracy and convergent speed of state-of-charge (SOC) estimation. The algorithm designs an observer of state-of-charge for the power battery, and the measured current and voltage are taken as input and observation values of the observer, respectively. Then the state of charge of a battery is estimated by the DAFEKF. The DAFEKF bases on the Kalman algorithm, and adds the time-varying fading factor to reduce the influence of past data on current filtering values and to adaptively adjust the covariances of the process noise and measurement noise. SOC results of a lithium battery obtained using the proposed DAFEKF are compared with those obtained using the extended Kalman filter (EKF) and the adaptive extended Kalman filter (AEKF), and the comparison shows that the DAFEKF method provides better accuracy, robustness and convergence, and the SOC error of the proposed method is less than 2%.

Keywords: lithium-ion batteries; state of charge; adaptive Kalman filter; extended Kalman filter; dual adaptive

电池管理系统(BMS)是电动汽车的关键部件之一。电池荷电状态(SOC)估计是BMS控制策略的基础,准确估计SOC可以提高电池安全性、更好地管理电池能量和延长电池寿命^[1-2]。

电池荷电状态估计易受温度、充放电倍率以及容量等因素影响,且电池系统是复杂的非线性系统,致使准确SOC估计变得困难。目前SOC估计存在几种主流的估计方法:安时积分法^[3]是工程上最常用的算法,它是一种开环估计方法,简单易行,但电流的累积误差会导致估计误差变大;开路电压法^[4]只能在静态条件下通过开路电压与SOC关系精确辨识SOC值,不适用于动态过程;基于模型的方法^[5-8]利用电池信息来建立电池模型,使用测量的电压信号作为反馈形成闭环估计,完成高精度的SOC估计。


扩展卡尔曼滤波(EKF)算法是最常用的基于模型的估计方法,具备闭环和在线估计等优点。然而,在利用EKF算法估计电池SOC时,系统统计噪声的不确定性和当前滤波值对旧数据的过度依赖等问题,会导致估计误差较大、收敛较慢和滤波发散。何洪文教授指出,利用卡尔曼滤波算法来估计电池SOC时,由于电池模型和系统噪声的不确定性,容易引起滤波发散^[9]。孙逢春院士进一步研究了卡尔曼滤波算法,指出在估算过程开始时,过程噪声协方差或测量噪声协方差太小,会使估计误差变大;反之,过程噪声协方差或测量噪声协方差过大,则会出现滤波发散等现象^[10]。北京理工大学的熊瑞副教授深入研究了自适应扩展卡尔曼滤波(AEKF)算法,通过自适应地更新过程和测量噪声协方差来提高电池SOC估计的准确度^[11-12]。马来西亚理工大学的学者继续提出一种新的AEKF算法^[13],降低了算法的复杂度,实现电池SOC的在线估计。但是,这类估计算法依然存在明显弊端,即在利用AEKF算法估计电池SOC时,存在当前滤波值对旧数据的过度依赖问题,从而导致估计误差变大甚至发散。

针对以上问题,本文提出一种双自适应衰减扩展卡尔曼滤波(DAFEKF)算法。该算法采用时变衰减因子来抑制滤波器的记忆长度,以便充分利用当前观测数据,减小陈旧量测值的影响,同时自适应地调整过程噪声和测量噪声协方差。实验结果表明,本文提出的方法与EKF和AEKF算法相比,能有效地提高电池SOC估计精度和收敛速度。

1 电池等效电路模型及其参数辨识

1.1 电池模型

等效电路模型是电路模型的主流发展方向,其结构简单,易用数学方程来表达,且通用性强。它是由电路元器件组合而成的电路网络,通过增加RC网络数量来提高模型的准确度,但是这样会使模型的复杂度增加,计算效率降低,实用性降低,所以本文采用一阶RC模型^[14-15],如图1所示。



R_1 为欧姆内阻; R_2 、 C_2 分别为极化内阻和极化电容;

V_2 为极化电压; E_0 为电池的开路电压

图1 一阶RC电池模型

在图1中, V_2 和电流 I 的关系可以通过并联的 R_2 和 C_2 得到, 即

$$\dot{V}_2 = -\frac{V_2}{R_2 C_2} + \frac{I}{C_2} \quad (1)$$

同时, 根据基尔霍夫电压定律有

$$V_0 = E_0 + IR_1 + V_2 \quad (2)$$

用 z 代表 SOC, 根据 SOC 定义有

$$\dot{z} = \frac{I}{C_n} \quad (3)$$

分段线性插值可得到开路电压 E_0 与 z 的关系 $E_0(z) = a_n z + b_n$, 其中 a_n 和 b_n 为拟合参数。

综上, 可以获得电池模型的状态空间表达式

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}u \\ y = \mathbf{C}\mathbf{x} + Du \end{cases} \quad (4)$$

$$\text{式中: } \mathbf{A} = \begin{bmatrix} 0 & 0 \\ 0 & -\frac{1}{R_2 C_2} \end{bmatrix}; \mathbf{B} = \begin{bmatrix} \frac{1}{C_n} \\ \frac{1}{C_2} \end{bmatrix}; \mathbf{C} = [1 \quad a_n]; D = R_1; \mathbf{x} = \begin{bmatrix} V_2 \\ z \end{bmatrix}; u = I$$

1.2 参数辨识

最小二乘法因其原理简单、收敛较快、易于理解、易于编程实现, 常用于动态系统的模型参数辨识。

对式(4)进行拉氏变换, 并将式(4)中状态方程的变换结果代入观测方程, 可以得到

$$\frac{Y(s) - b_n}{U(s)} = \left[R_1 s^2 + \left(\frac{a_n}{C_n} + \frac{1}{C_2} + \frac{R_1}{C_2 R_2} \right) s + \frac{a_n}{C_n C_2 R_2} \right] / s \left(s + \frac{1}{C_1 R_2} \right) \quad (5)$$

对式(5)进行反向差分变换($s \rightarrow \frac{1-z^{-1}}{\tau}$),可以离散化得到

$$v_t(k) = a_1 v_t(k-1) - a_2 v_t(k-2) + b_0 i(k) - b_1 i(k-1) + b_2 i(k-2) \quad (6)$$

递推最小二乘法^[16-18]是自适应控制领域中最流行的在线参数估计,在递推最小二乘法的基础上加入遗忘因子,可以加快收敛速度,提高跟踪性能。本文采用含自适应遗忘因子的递推最小二乘(AFFRLS)算法辨识电池模型参数,递推公式为

$$y(k) = \boldsymbol{\varphi}^T(k) \boldsymbol{\theta} \quad (7)$$

$$e(k) = y(k) - \boldsymbol{\varphi}^T(k) \hat{\boldsymbol{\theta}}(k-1) \quad (8)$$

$$\mathbf{P}(k) = \frac{1}{\lambda} (I - \mathbf{K}(k) \boldsymbol{\varphi}^T(k)) \mathbf{P}(k-1) \quad (9)$$

$$\mathbf{K}(k) = \frac{\mathbf{P}(k-1) \boldsymbol{\varphi}(k)}{\lambda(k) + \boldsymbol{\varphi}^T(k) \mathbf{P}(k-1) \boldsymbol{\varphi}(k)} \quad (10)$$

$$\lambda(k) = \hat{\lambda}_{\min} + (1 - \hat{\lambda}_{\min}) 2^{L(k)} \quad (11)$$

$$L(k) = -\text{round}(\mu e^2(k)) \quad (12)$$

$$\hat{\boldsymbol{\theta}}(k) = \hat{\boldsymbol{\theta}}(k-1) + \mathbf{K}(k) e(k) \quad (13)$$

式中: $e(k)$ 是 $y(k)$ 的预计误差; $\lambda(k)$ 、 $\lambda_{\min}$ 分别是遗忘因子和遗忘因子的最小值; $\mathbf{K}(k)$ 是增益因子; $\mathbf{P}(k)$ 是协方差矩阵; $\boldsymbol{\varphi}^T(k) = [v_t(k-1), -v_t(k-2), i(k), -i(k-1), i(k-2)]$; $\boldsymbol{\theta} = [a_1, a_2, b_0, b_1, b_2]$;round 是四舍五入取整函数。

通过混合动力脉冲能力特性测试获得电压实验数据,进行离线参数辨识后得到 R_1 、 R_2 、 C_2 真实值,具体过程如图 2 所示。采用电池 10 s 放电(AC 段)和放电后 40 s 搁置(CE 段)的电压数据,利用 Matlab 中 cftool 工具箱拟合电压时间曲线来获得参数真实值,分别是 $R_1=0.041 \Omega$ 、 $R_2=0.011 \Omega$ 和 $C_2=2 \text{ kF}$ 。

采用 AFFRLS 算法估计负载电压误差如图 3,参数估计值与实际值对比如图 4 所示。




图 2 脉冲测试电压曲线

真实测量端电压与模型端电压间的绝对误差如图 3 所示,其负载电压最大误差为 0.020 5 V,平均误差为 0.001 6 V,相对误差是 0.43%,表明模型端电压对真实测量端电压具有很好的追踪效果。







图 3 采用 AFFRLS 算法估计的负载电压误差



(a) 欧姆内阻



(b) 极化内阻



(c) 极化电容

图 4 采用 AFFRLS 算法辨识电池模型参数的结果

理论上电池模型参数不可能出现负值,所以可以设置参数 R_1 、 R_2 、 C_2 的下限为 0,据此得到电池参数辨识的结果(见图 4)。由图 4 可知,电池模型参数快速收敛于真实值,到达稳态后波动很小,表明 AFFRLS 算法适用于电池参数的在线辨识。

图 3 和图 4 的分析结果表明,本文所建立的电池模型和参数辨识方法是可靠的。下面,将采用 AFFRLS 对电池模型参数进行在线辨识。

2 双自适应衰减扩展卡尔曼滤波

将式(4)离散化并结合在线辨识参数,可得离散电池模型

$$\begin{cases} \mathbf{x}_{k+1} = (\mathbf{A}_k + \mathbf{E})\mathbf{x}_k + \mathbf{B}_k\mathbf{u}_k + \boldsymbol{\omega}_k \\ \mathbf{y}_k = \mathbf{C}_k\mathbf{x}_k + \mathbf{D}_k\mathbf{u}_k + \mathbf{v}_k \end{cases} \quad (14)$$

$$\mathbf{e}_{x_{k+1}} = \mathbf{x}_{k+1} - \hat{\mathbf{x}}_{k+1} \quad (15)$$

$$\mathbf{e}_{k+1} = \mathbf{y}_{k+1} - \hat{\mathbf{y}}_{k+1} \quad (16)$$

$$\mathbf{P}_{k+1} = \text{cov}(\mathbf{x}_{k+1} - \hat{\mathbf{x}}_{k+1}) \quad (17)$$

$$\mathbf{P}_{y_{k+1}} = \text{cov}(\mathbf{y}_{k+1} - \hat{\mathbf{y}}_{k+1}) \quad (18)$$

式中: $\boldsymbol{\omega}_k$ 和 $\mathbf{v}_k$ 为零均值不相关白噪声向量; $\boldsymbol{\omega}_k$ 表示系统噪声,其协方差矩阵为 $\mathbf{Q}_k$; $\mathbf{v}_k$ 表示观测噪声,其协方差矩阵为 $\mathbf{R}_k$; $\mathbf{e}_{x_{k+1}}$ 是系统状态量误差; $\mathbf{e}_{k+1}$ 是残差; $\mathbf{P}_{k+1}$ 是系统状态量误差的协方差; $\mathbf{P}_{y_{k+1}}$ 是残差的协方差;cov表示协方差。

针对卡尔曼滤波法在锂离子电池SOC估计时存在误差较大、收敛较慢等问题,提出了基于DAFEKF算法的SOC估计算法。该算法采用时变衰减因子来减弱过去数据对当前滤波值的影响,提高滤波器的鲁棒性和精度,自适应地调整过程噪声和测量噪声协方差,提高了滤波器的精度和收敛速度。

本文双自适应衰减扩展卡尔曼滤波算法的思想如下。

(1)扩展卡尔曼滤波的系统状态协方差。在系统结构已知的情况下,给定 k 时刻的状态观测向量 $\mathbf{x}_k$,求 k 时刻系统状态量的最优估计 $\hat{\mathbf{x}}_k$,使 $\mathbf{P}_k$ 最小,计算公式如下

$$\min(\mathbf{P}_k) = \text{cov}(\mathbf{x}_k - \hat{\mathbf{x}}_k) = E[(\mathbf{x}_k - \hat{\mathbf{x}}_k)(\mathbf{x}_k - \hat{\mathbf{x}}_k)^T] \quad (19)$$

(2)自适应观测噪声和测量噪声。在系统结构已知的情况下,给定 k 时刻的残差 $\mathbf{y}_k$,求 k 时刻残差的最优估计 $\hat{\mathbf{y}}_k$,使 $\mathbf{P}_{y_k}$ 最小,计算公式如下

$$\min(\mathbf{P}_{y_k}) = \text{cov}(\mathbf{y}_k - \hat{\mathbf{y}}_k) = E[(\mathbf{y}_k - \hat{\mathbf{y}}_k)(\mathbf{y}_k - \hat{\mathbf{y}}_k)^T] \quad (20)$$

(3)自适应衰减因子。为了提高滤波器的鲁棒性和精度,可加入衰减因子 α 。当模型精准时,卡尔曼滤波的输出残差序列是不自相关的高斯白噪声序列,因此要求不同时刻的残差序列处处保持相互正交,即下式成立

$$\begin{aligned} E[(\mathbf{y}_{k+1+j} - \hat{\mathbf{y}}_{k+1+j})(\mathbf{y}_{k+1} - \hat{\mathbf{y}}_{k+1})^T] &= 0 \\ k &= 0, 1, 2, \dots, \quad j = 1, 2, \dots \end{aligned} \quad (21)$$

通过式(21)可以实现衰减因子 α 的自适应。综上,

DAFEKF的理论推导已完成。DAFEKF算法的实现流程如图5所示。




图5 DAFEKF算法的实现流程图

双自适应衰减扩展卡尔曼滤波的具体递推流程如下。

(1)初始条件为

$$\mathbf{x}_{0/0} = E(\mathbf{x}_0), \mathbf{P}_{0/0} = E[(\mathbf{x} - \mathbf{x}_0)(\mathbf{x} - \mathbf{x}_0)^T] \quad (22)$$

(2)向前推算状态变量

$$\hat{\mathbf{x}}_{k/k-1} = (\mathbf{A}_k + \mathbf{E})\hat{\mathbf{x}}_{k-1} + \mathbf{B}_k\mathbf{u}_{k-1} \quad (23)$$

(3)向前推算误差协方差

$$\mathbf{P}_{k/k-1} = (\mathbf{A}_k + \mathbf{E})\alpha(k)\mathbf{P}_{k-1}(\mathbf{A}_k + \mathbf{E})^T + \mathbf{Q}_k \quad (24)$$

(4)卡尔曼增益更新

$$\mathbf{K}_k = \mathbf{P}_{k/k-1}\mathbf{C}^T[(\mathbf{C}\mathbf{P}_{k/k-1}\mathbf{C}^T + \mathbf{R}_k)]^{-1} \quad (25)$$

(5)状态估计测量更新

$$\hat{\mathbf{x}}_{k/k} = \hat{\mathbf{x}}_{k/k-1} + \mathbf{K}_k\mathbf{e}_k \quad (26)$$

(6)误差协方差测量更新

$$\mathbf{P}_{k/k} = [\mathbf{I} - \mathbf{K}(k)\mathbf{C}_k]\mathbf{P}_{k/k-1} \quad (27)$$

(7)测量噪声和观测噪声更新

$$\mathbf{Q}_k = \mathbf{Q}_{k-1} + 1/L_Q(\mathbf{Q}^* - \mathbf{Q}_{k-1}) \quad (28)$$

$$\mathbf{Q}^* = \mathbf{K}_k\mathbf{e}_k\mathbf{e}_k^T\mathbf{K}_k^T - \mathbf{P}_k + (\mathbf{A}_k + \mathbf{E})\mathbf{P}_{k-1}(\mathbf{A}_k + \mathbf{E})^T \quad (29)$$

$$\mathbf{R}_k = \mathbf{R}_{k-1} + 1/L_R(\mathbf{R}^* - \mathbf{R}_{k-1}) \quad (30)$$

$$\mathbf{R}^* = \mathbf{e}_k\mathbf{e}_k^T - \mathbf{C}_k\mathbf{P}_{k-1}\mathbf{C}_k^T \quad (31)$$

式中: L_Q 和 L_R 分别表示过程噪声和测量噪声调整窗口值。

(8)衰减因子更新

$$\alpha(k) = \begin{cases} \alpha_0, & \alpha_0 \geq 1 \\ 1, & \alpha_0 < 1 \end{cases} \quad (32)$$

$$\alpha_0 = \frac{\text{tr}[N(k)]}{\text{tr}[M(k)]} \quad (33)$$

$$M(k) = \mathbf{C}_k\mathbf{A}_k\mathbf{P}(k)\mathbf{A}_k^T\mathbf{C}_k^T \quad (34)$$

$$N(k) = E(\mathbf{e}_{y_k}\mathbf{e}_{y_k}^T) - \mathbf{C}_k\mathbf{B}_k\mathbf{Q}(k)\mathbf{B}_k^T\mathbf{C}_k^T - \mathbf{R}(k) \quad (35)$$

通过上述流程,完成双自适应衰减扩展卡尔曼滤波的计算,得到准确的SOC估计。

3 实验验证

3.1 实验平台

电池测试台的原理如图 6 所示,其中包括电池测试系统 NEWARE CT4032、Temp & Humi 可编程室、主机和用于编程 CT4032 的 BTS 软件。其中主机的 BTS 软件将当前信息发送到 NEWARE CT4032 系统,NEWARE CT4032 系统根据主机中 BTS 软件的当前信息对电池进行充电和放电。电流、电压和温度由传感器收集并传输到主机。Temp & Humi 可编程室控制电池充放电时的环境温度和湿度。采用 NCR18650 锂离子电池,其额定电压为 3.7 V,实际测量容量为 1 573 mA·h。电池测试实验平台如图 7 所示,实验前电池为满充状态,以 UDDS 循环放电至截止电压,总时间约 5 000 s,根据得到的数据进行电池参数在线辨识和 SOC 估计。




图 6 电池测试台原理图





图 7 电池测试实验平台


3.2 SOC 估计验证

分别使用了安时积分(Ah)算法、扩展卡尔曼滤波(EKF)算法、自适应卡尔曼滤波(AEKF)算法和本文的双自适应衰减卡尔曼滤波(DAFEKF)算法估计电池 SOC(用符号 S_{SOC} 表示),其中在知道初始 SOC 时,采用可以得到较高的估计精度,所以用 Ah 算法得到的 SOC 作为参考值,AEKF 与 EKF 算法

的 SOC 估计对比如图 8 所示,本文 DAFKF 算法与 EKF 算法的对比如图 9 所示。



(a)SOC 估计




(b)SOC 估计误差


图 8 AEKF 与 EKF 算法的 SOC 估计对比 (Ah 算法为参考值)

由图 8 可知,当 SOC 初始化误差为 20% 时, SOC 估计误差降到 1%,采用 AEKF 算法需要 116 s,采用 EKF 算法需要 425.5 s,AEKF 相比于 EKF,整体收敛速度变快,误差减小。但 AEKF 存在超调现象,在 800 s 和 2 200 s 时,估计误差超过 EKF,采用 AEKF 算法估计的 SOC 误差超出 2%。

由图 9 可知,当 SOC 初始化误差为 20% 时, SOC 估计误差降到 1%,采用新型 DAFEKF 算法需要 77.3 s,采用 DAFEKF 估计的 SOC 误差相对于



(a)SOC 估计



(b) SOC 估计误差

图9 本文 DAFEKF 算法与 AEKF 算法的 SOC 估计对比

EKF 收敛速度变快和误差范围整体缩小,同时解决 AEKF 的超调问题,收敛后的整体误差小于 2%。

4 结 论

本文提出了一种双自适应衰减扩展卡尔曼滤波 (DAFEKF) 算法来估计锂离子电池 SOC。首先采用了等效电路模型对锂离子电池进行建模分析,并使用含自适应遗忘因子的递推最小二乘法在线辨识模型参数,然后利用所提出的 DAFEKF 算法估计电池 SOC。为了验证本文所提算法的有效性,将本文算法的估计结果与安时积分法、EKF 和 AEKF 算法的估计结果进行比较,实验结果表明:本文所提算法可以提高锂电池 SOC 的估计精度,使 SOC 估计误差小于 2%;本文所提算法可以提高锂电池 SOC 估计的收敛速度,进而有利于快速获得准确的 SOC 估计值。

参考文献:

- [1] XU Jun, CAO Binggang, CHEN Zheng, et al. An on-line state of charge estimation method with reduced prior battery testing information [J]. International Journal of Electrical Power & Energy Systems, 2014, 63: 178-184.
- [2] 王霄, 徐俊, 曹秉刚, 等. 小波降噪卡尔曼滤波锂电池荷电状态估计 [J]. 西安交通大学学报, 2017, 51 (10): 71-76.
WANG Xiao, XU Jun, CAO Binggang, et al. A Kalman filter SOC estimation method for lithium-ion batteries based on discrete wavelet transform denoising [J]. Journal of Xi'an Jiaotong University, 2017, 51 (10): 71-76.
- [3] NG K S, MOO C S, CHEN Yiping, et al. Enhanced coulomb counting method for estimating state-of-

charge and state-of-health of lithium-ion batteries [J]. Applied Energy, 2009, 86(9): 1506-1511.

- [4] LEE S, KIM J, LEE J, et al. State-of-charge and capacity estimation of lithium-ion battery using a new open-circuit voltage versus state-of-charge [J]. Journal of Power Sources, 2008, 185(2): 1367-1373.
- [5] HU Xiaosong, SUN Fengchun, ZOU Yuan. Estimation of state of charge of a lithium-ion battery pack for electric vehicles using an adaptive Luenberger observer [J]. Energies, 2010, 3(9): 1586-1603.
- [6] XU Jun, CAO Binggang, CAO Junyi, et al. A comparison study of the model based SOC estimation methods for lithium-ion batteries [C]// Proceedings of 2013 9th IEEE Vehicle Power and Propulsion Conference. Piscataway, NJ, USA: IEEE, 2013: 1-3.
- [7] XU Jun, MI C C, CAO Binggang, et al. The state of charge estimation of lithium-ion batteries based on a proportional-integral observer [J]. IEEE Transactions on Vehicular Technology, 2014, 63(4): 1614-1621.
- [8] 赵义群, 周晓凤, 刘英杰. 基于扩展卡尔曼粒子滤波算法的锂电池 SOC 估计 [J]. 中国机械工程, 2015, 26(3): 394-397.
ZHAO Youqun, ZHOU Xiaofeng, LIU Yingjie. SOC estimation for li-ion battery based on extended Kalman particle filter [J]. China Mechanical Engineering, 2015, 26(3): 394-397.
- [9] HE Hongwen, XIONG Rui, ZHANG Xiaowei, et al. State-of-charge estimation of the lithium-ion battery using an adaptive extended Kalman filter based on an improved Thevenin model [J]. IEEE Transactions on Vehicular Technology, 2011, 60(4): 1461-1469.
- [10] SUN Fengchun, HU Xiaosong, ZHOU Yuan, et al. Adaptive unscented Kalman filtering for state of charge estimation of a lithium-ion battery for electric vehicles [J]. Energy, 2011, 36(5): 3531-3540.
- [11] 熊瑞, 孙逢春, 何洪文. 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 [J]. 高技术通讯, 2012, 22(2): 198-204.
XIONG Rui, SUN Fengchun, HE Hongwen. State-of-charge estimation of lithium-ion batteries in electric vehicles based on an adaptive extended Kalman filter [J]. Chinese High Technology Letters, 2012, 22(2): 198-204.
- [12] XIONG Rui, HE Hongwen, SUN Fengchun, et al. Evaluation on state of charge estimation of batteries with adaptive extended Kalman filter by experiment approach [J]. IEEE Transactions on Vehicular Technology, 2013, 62(1): 108-117.

- [13] YAO L W, AZIZ J A, IDRIS N R, et al. Online battery modeling for state-of-charge estimation using extended Kalman filter with Busse's adaptive rule [C]// Proceedings of 41st Annual Conference of the IEEE Industrial Electronics Society. Piscataway, NJ, USA: IEEE, 2015: 4742-4747.
- [14] 戴海峰, 魏学哲, 孙泽昌. 基于等效电路的内阻自适应锂离子电池模型 [J]. 同济大学学报(自然科学版), 2010, 38(1): 98-102.
- DAI Haifeng, WEI Xuezhe, SUN Zechang. An inner resistance adaptive model based on equivalent circuit of lithium-ion batteries [J]. Journal of Tongji University (Natural Science), 2010, 38(1): 98-102.
- [15] RAHIMI-EICHI H, CHOW M Y. Adaptive parameter identification and state-of-charge estimation of lithium-ion batteries [C]// Proceedings of Conference on IEEE Industrial Electronics Society. Piscataway, NJ, USA: IEEE, 2012: 4012-4017.
- [16] PALEOLOGU C, BENESTY J, CIOCHIN S. A robust variable forgetting factor recursive least-squares algorithm for system identification [J]. IEEE Signal Processing Letters, 2008, 15: 597-600.
- [17] RIJANTO E, ROZAQI L, NUGROHO A, et al. RLS with optimum multiple adaptive forgetting factors for SOC and SOH estimation of li-ion battery [C]// Proceedings of the 2017 5th International Conference on Instrumentation, Control, and Automation. Piscataway, NJ, USA: IEEE, 2017: 73-77.
- [18] KAZEMI M, AREFI M M. A fast iterative recursive least squares algorithm for Wiener model identification of highly nonlinear systems [J]. ISA Transactions, 2017, 67: 382-388.

(编辑 刘杨)

(上接第 43 页)

- IEEE Conference on Energy Internet and Energy System Integration. Piscataway, NJ, USA: IEEE, 2017: 1-5.
- [12] 晏夏瑜, 韦彬, 李训聿, 等. 有源电力滤波器的双环模糊自适应 PI 控制 [J]. 电力电子技术, 2017, 51(7): 105-108.
- YAN Xiayu, WEI Bin, LI Xunyu, et al. Double loop fuzzy adaptive PI control for active power filter [J]. Power Electronics, 2017, 51(7): 105-108.
- [13] YANG W P, ZHANG A M, LI J G, et al. Integral plus resonant sliding mode direct power control for VSC-HVDC systems under unbalanced grid voltage conditions [J]. Energies, 2017, 10(10): 1528-1545.
- [14] KWAK S, PARK J C. Model-predictive direct power control with vector pre-selection technique for highly efficient active rectifiers [J]. IEEE Transactions on Industrial Informatics, 2017, 11(1): 44-52.
- [15] SUN D, WANG X, FANG Y. Backstepping direct power control without phase-locked loop of AC/DC converter under both balanced and unbalanced grid conditions [J]. IET Power Electronics, 2016, 9(8): 1614-1624.
- [16] CAMACHO A, CASTILLA M, MIRET J, et al. Active and reactive power strategies with peak current limitation for distributed generation inverters during unbalanced grid faults [J]. IEEE Transactions on Industrial Electronics, 2015, 62(3): 1515-1525.
- [17] BORDONS C, MONTERO C. Basic principles of MPC for power converters: bridging the gap between theory and practice [J]. IEEE Industrial Electronics Magazine, 2015, 9(3): 31-43.
- [18] VAZQUEZ S, MONTERO C, BORDONS C, et al. Design and experimental validation of a model predictive control strategy for a VSI with long prediction horizon [C]//39th Annual Conference of the IEEE Industrial Electronics Society. Piscataway, NJ, USA: IEEE, 2013: 5788-5793.
- [19] BETZ R E, SUMMERS T J. Using a cascaded H-bridge STATCOM for rebalancing unbalanced voltages [C]//7th International Conference on Power Electronics. Piscataway, NJ, USA: IEEE, 2007: 1219-1224.

(编辑 刘杨)