

基于等效模型和多时间尺度扩展卡尔曼滤波的 锂离子电池 SOC 预测

陈冰¹, 鲁刚², 房红征^{3,4}, 张明敏¹

(1. 海军工程大学 电子工程学院, 武汉 430033; 2. 海军装备部, 北京 100055;

3. 北京航天测控技术有限公司, 北京 100041;

4. 北京市高速交通工具智能诊断与健康重点实验室, 北京 100041)

摘要: 荷电状态 (SOC) 和最大可用电量估计是锂离子电池寿命预测中的两个最重要部分; 然而与快速时变的 SOC 比较, 最大可用电量的参数变化缓慢; 文章提出了一个基于等效模型和多时间尺度的扩展卡尔曼滤波 (EKF) 预测算法对 SOC 和最大可用容量分别在不同时间尺度上进行估计, 在宏观尺度上利用了 SOC 估计值作为观测量, 更新最大可用电量; 针对 NCA/C 卫星锂离子电池实验数据的仿真结果表明, 提出的多时间尺度 EKF 预测算法与 EKF 联合估计算法相比, SOC 和最大可用电量估计准确度更高, 同时提高了计算效率。

关键词: SOC; 最大可用电量; Thevenin 等效电路模型; 多时间尺度; EKF 预测算法

SOC Prediction of Lithium-ion Batteries Based on Equivalent Circuit model and Multi-time Scale Extended Kalman Filter

Chen Bing¹, Lu Gang², Fang Hongzheng^{3,4}, Zhang Mingmin¹

(1. College of Electronic Engineering, Naval University of Engineering, Wuhan 430033, China;

2. Equipment Department of Navy, Beijing 100055, China;

3. Beijing Aerospace Measure & Control Corp. Ltd. Beijing 100041, China;

4. Beijing Key Laboratory of High-speed Transport Intelligent Diagnostic and Health Management, Beijing 100041, China)

Abstract: The state of charge (SOC) and the maximum available electricity estimation are two of the most important parts of satellite lithium-ion battery life prediction. However, compared with the fast time-varying SOC, the parameters of the maximum available power change slowly. It proposed a multi-time scale extended Kalman filter (EKF) prediction algorithm based on the equivalent circuit model to estimate the SOC and the maximum available capacity at different time scales. The SOC estimation is used as an observation on the macroscopic scale to update the maximum available power. The simulation results of NCA/C lithium-ion battery show that the proposed multi-time scale EKF prediction algorithm has higher accuracy of SOC and maximum available power estimation compared with traditional EKF algorithm, and improves the computational efficiency.

Keywords: SOC; maximum available electricity; Thevenin equivalent circuit model; multi-time scale; EKF; prediction algorithm

0 引言

锂离子电池对卫星电源系统至关重要, 正在逐步替代传统电池成为第三代卫星用储能电源^[1]。由于锂电池自身存在充放电管理、性能衰退等问题, 对其工作状态监测、性能退化分析和剩余寿命 (RUL) 预测等已经成为卫星系统故障预测和健康管理 (PHM) 领域研究的关键^[2-4]。

电池的最大可用电量常被用作电池寿命的退化特征。准确的 SOC 估计不仅能用来评估设备的可靠性, 还能反映电池的剩余使用寿命等关键信息。除了传统的开路电压法、安时积分法等, 文献[5-7]对 Kalman 滤波方法应用于卫星锂电池的 SOC 估计进行了详细的分析。文献[8]改进了扩展卡尔曼 (EKF) 算法, 先利用状态量和方差矩阵构造 Sigma 点集, 这种基于 Sigma 点的 Kalman 滤波算法可以取得更好的精度。文

献[9]将 Kalman 滤波算法与安时积分法结合。文献[10]使用无损卡尔曼滤波对锂电池 SOC 进行预测。文献[11]提出的 EKF 联合估计算法能够进行具有噪声电压和电流测量的实时 SOC 和最大可用电量估计。

目前采用状态与参数联合估计技术的最大可用电量估计的准确性较差。原因有两点: 一是电池端电压是唯一测量数据, 但是最大可用电量与电池电压之间的联系非常弱; 另外由于 SOC 和最大可用电量之间的强相关性, 不准确的最大可用电量估计将会进一步导致不准确的 SOC 估计, 反之亦然。在计算效率方面, 最大可用电量是指示系统健康状态 (SOH) 的缓慢时变量, 如果最大可用电量估计与快速时变量 SOC 在相同的时间尺度上执行, 将导致高计算复杂性。为了解决这些困难, 本文提出了一种基于等效电路模型和多时间尺度 EKF 预测算法对 SOC 和最大可用电量分别进行估计, 贡献主要有: (1) 设计了多时间尺度的 SOC 和最大可用电量的时间尺度分离估计算法; (2) 采用 SOC 估计值动态更新最大可用电量的预测值。作为一种安时积分法和 EKF 滤波混合的技术, 该算法实现了比 EKF 联合估计算法更高的精度和效率。

收稿日期: 2017-03-10; 修回日期: 2017-03-17。

作者简介: 陈冰 (1979-), 女, 黑龙江哈尔滨人, 副教授, 主要从事装备维修保障技术方向的研究。

1 卫星锂离子电池等效电路模型和多时间尺度离散化模型

1.1 Thevenin 等效电路模型

卫星锂离子电池的等效电路模型有 Rint 模型, RC 模型, Thevenin 模型和 PNGV 模型^[6]等。Thevenin 等效电路模型^[12]考虑了电池电压在电流激励下的突变和渐变, 结构见图 1。该模型参数描述如下: U_{oc} 表示电池的开路电压 (OCV); R_i 用于描述电池欧姆电阻在双电层中的电荷的累积和耗散; R_p 表示电池极化电阻, C_p 表示电池极化电容, 它们构成的 RC 网络用于模拟卫星锂电池在极化现象的产生和消除过程中所表现出的动态特性; U_p 表示 RC 网络上的极化电压; U 表示电池的端电压; I 表示电池负载电流 (假定放电为正, 充电为负)。




图 1 锂离子电池 Thevenin 等效电路模型

SOC 定义为可用电量与额定电量的比值, 相当于锂电池的电量计。环境温度确定时, OCV 与 SOC 间关系是锂电池的静态特性的反映^[13], 并且是可辨识的。

令 $z = SOC$, 此处使用 $f(z)$ 来描述 OCV 与 SOC 之间这种确定关系。需要指出的是, 电池 SOC 与其端电压的联系已经通过 $f(z)$ 增强, 这对于提高 SOC 预测精度非常重要。由图可知 Thevenin 模型各参数数学关系式可以表述为:

$$U = U_{oc} - U_p - IR_i = f(z) - U_p - IR_i \quad (1)$$

$$\bar{U}_p = -U_p / (R_p C_p) + I / C_p \quad (2)$$

按时积分法是最简单的 SOC 估计方法, 也是目前应用较多的 SOC 估计算法。它通过对运行时间内流过电池的电流进行积分, 计算流入或者流出电池的电量, 如果已知电池的初始 SOC 值, 便可用初始 SOC 值加上或减去流过电池的电量, 得到电池剩余电量公式 (3) 是得到 SOC 状态方程的基础:

$$SOC = 1 - \left(\int i \cdot \eta \cdot dt \right) / Q \quad (3)$$

其中 i 为电流, Q 为电池最大可用电量, t 为时间, (为库伦有效因子, 定义为恢复到最初电量所需充电和放电能量的比值。(小于或等于 1。例如, 在放电模式中, 当达到最小放电电压时, 认为电池已经完全放电, 则 SOC 为 0。通过 Thevenin 等效电路模型与按时积分法的结合, 将电池参数和 SOC 与其端电压联系起来。以荷电状态 SOC、极化电压 U_p 为状态变量, 得到状态方程为:

$$\begin{cases} SOC = 1 - \left(\int i \cdot \eta \cdot dt \right) / Q \\ \bar{U}_p = -U_p / (R_p C_p) + I / C_p \end{cases} \quad (4)$$

以端电压 U 为量测值, 则观测方程为:

$$U = f(z) - U_p - IR_i \quad (5)$$

1.2 多时间尺度的离散化模型

EKF 应用对象是非线性离散系统, 因而需要对上节提出的连续模型离散化。对于参数变化快慢差别很大的系统, 我们

可以设置两个时标: 宏观时标和微观时标。处于宏观时标中的系统量往往随着时间变化而缓慢变化, 而微观时标上则表现为系统量随着时间快速变化。

为了方便表述, 分别使用 k 和 l 作为宏观时间尺度和微观时间尺度的时间指标。任意时刻均可以表示为 $t_{k,l}$, 并且存在这样的关系: $t_{k,l} = t_{k,0} + l \cdot T$, $t_{k,0} = t_{k-1,L}$ ($l = 1, 2, \dots, L$; $k = 1, 2, \dots, \infty$), T 是两个相邻测量点之间的固定时间间隔。值得注意的是, L 代表时标分离的水平。根据系统参数的变化情况, 确定宏观时间尺度的宏观仿真时间步数 k ; 在 k 与 $k+1$ 时间步之间, 根据系统状态量的变化情况, 确定采样周期 T , 即得到宏观仿真时间步数 l 。考虑到模型参数是慢时变的, 因而假设电池是时不变系统, 并且负载电流在每个采样间隔 T 内保持恒定, 进而可以得到方程 (2) 的解析解, 如下所示:

$$U_p((l+1)T) = \exp\left(-\frac{T}{R_p C_p}\right) U_p(lT) + \int_0^T \exp\left(-\frac{t}{R_p C_p}\right) dt \cdot \frac{I(lT)}{C_p} \quad (6)$$

图 1 所示电池模型以荷电状态 z 、极化电压 U_p 为状态变量, 负载电流 I 为输入量, 端电压 U 为输出量, 在多时间尺度上离散化后得到:

$$U_{k,l}^z = \exp\left(-\frac{T}{R_p C_p}\right) \cdot U_{k,l-1}^z + \left(1 - \exp\left(-\frac{T}{R_p C_p}\right)\right) \cdot R_p I_{k,l} \quad (7)$$

令 $z_{k,l} = SOC$, 由式 (3) 得到:

$$z_{k,l} = z_{k,l-1} - \frac{\eta I_{k,l-1} T}{Q} \quad (8)$$

令 $\tau_p = R_p \cdot C_p$, 由式 (4) 到式 (8) 可以得到:

$$\begin{bmatrix} U_{k,l}^z \\ z_{k,l} \end{bmatrix} = \begin{bmatrix} \exp\left(-\frac{T}{\tau_p}\right) & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} U_{k,l-1}^z \\ z_{k,l-1} \end{bmatrix} + \begin{bmatrix} \left(1 - \exp\left(-\frac{T}{\tau_p}\right)\right) R_p \\ -\eta T / Q \end{bmatrix} I_{k,l} \quad (9)$$

多时间尺度上的离散化状态转移和测量方程为:

$$\begin{cases} x_{k,l+1} = \begin{bmatrix} \exp\left(-\frac{T}{\tau_p}\right) & 0 \\ 0 & 1 \end{bmatrix} x_{k,l} + \begin{bmatrix} \left(1 - \exp\left(-\frac{T}{\tau_p}\right)\right) R_p \\ -\eta T / Q \end{bmatrix} u_{k,l} \\ y_{k,l} = f(z_{k,l}) - U_{k,l}^z - R_i u_{k,l} \end{cases} \quad (10)$$

其中, $x_{k,l} = [z_{k,l} \ U_{k,l}^z]^T$, $\theta_k = Q_k$, $u_{k,l} = I_{k,l}$, $y_{k,l} = U_{k,l}$ 。并且 $U_{k,l}$ 是在时刻 $t_{k,l}$ 的电池端电压量测值。

为了使接下来的讨论更具有一般性, 将式 (10) 改写为以下非线性状态空间模型:

$$\begin{aligned} \text{传递: } & x_{k,l+1} = F(x_{k,l}, u_{k,l}, \theta_k) + w_{k,l}, \quad \theta_{k+1} = \theta_k + r_k \\ \text{测量: } & y_{k,l} = G(x_{k,l}, u_{k,l}, \theta_k) + v_{k,l} \end{aligned} \quad (11)$$

其中, $x_{k,l}$ 是在时间为 $t_{k,l} = t_{k,0} + l \cdot T$, $l = 1, 2, \dots, L$ 时的系统状态矢量, T 是两个相邻测量点之间的固定时间间隔, k, l 表示宏观和微观时标的序号。值得注意的是, L 代表时标分离的水平, 且 $x_{k,0} = x_{k-1,L}$ 。 θ_k 是时间为 $t_{k,0}$ 时系统模型参数的矢量; $u_{k,l}$ 是外部观测源的输入; $y_{k,l}$ 是系统观察值 (或者量测值) 的矢量。 $w_{k,l}$ 和 r_k 分别是状态和模型参数的过程噪声矢量; $v_{k,l}$ 是测量噪声的矢量; $F()$ 和 $G()$ 分别是状态传递和状态测量函数。

2 多时间尺度的 EKF 预测算法

针对系统在多时间尺度上的离散模型, 使用多时间尺度的

EKF 预测算法来预测 SOC 与最大可用容量。多时间尺度算法预测过程共分为六步, 宏观 EKF 和微观 EKF 一起以嵌套循环的形式执行。在每个宏观时间步 k 内, 宏观 EKF 进行时间更新、状态预测和测量更新。每个微观时间步 l 内, 微观 EKF 执行时间更新和测量更新。当 $l = 1$ 循环到 $l = L$ 时, 该宏观时间步 k 结束, 进入下一个宏观时间步 $k + 1$ 。无论宏观或微观 EKF, 开始执行前均需要通过把基于先验信息的经验值赋予模型参数 θ 和状态 x 来进行初始化。估计误差的协方差矩阵 \sum_{θ} 和 \sum_x 也根据先验信息进行初始化。基本步骤总结如下:

第一步: 初始化。

$$\begin{aligned} \hat{\theta}_0 &= E[\hat{\theta}_0], \quad \sum_{\theta_{k,l}}^- = E[(\theta_0 - \hat{\theta}_0)(\theta_0 - \hat{\theta}_0)^T] \\ \hat{x}_{0,0} &= E[x_{0,0}], \quad \sum_{x_{k,l}}^- = E[(x_{0,0} - \hat{x}_{0,0})(x_{0,0} - \hat{x}_{0,0})^T] \end{aligned} \quad (12)$$

在宏观尺度上:

第二步: 宏观 EKF 的时间更新。

$$\hat{\theta}_k^- = \hat{\theta}_{k-1}, \quad \sum_{\theta_k}^- = \sum_{\theta_{k-1}}^- + \sum_{r_{k-1}} \quad (13)$$

第三步: 宏观 EKF 的状态预测。

$$\hat{x}_{k-1,L}^- = F_{0 \rightarrow L}(\hat{x}_{k-1,0}, u_{k-1,L-1}, \hat{\theta}_k^-) \quad (14)$$

第四步: 宏观 EKF 的测量更新。

$$K_k^{\theta} = \sum_{\theta_k}^- (C_k^{\theta})^T [C_k^{\theta} \sum_{\theta_k}^- (C_k^{\theta})^T + \sum_{n_k}]^{-1} \quad (15)$$

$$\hat{\theta}_k = \hat{\theta}_k^- + K_k^{\theta} [x_{k-1,L} - \hat{x}_{k-1,L}^-], \quad \sum_{\theta_k}^- = (1 - K_k^{\theta} C_k^{\theta}) \sum_{\theta_k}^- \quad (16)$$

在微观尺度上如下。

第五步: 微观 EKF 的时间更新。

$$\begin{aligned} \hat{x}_{k,l}^- &= F(\hat{x}_{k,l-1}^-, u_{k,l-1}, \hat{\theta}_{k-1}), \quad \sum_{x_{k,l}}^- = A_{k,l-1} \sum_{x_{k,l-1}}^- \\ &A_{k,l-1}^T + \sum_{w_{k,l-1}} \end{aligned} \quad (17)$$

第六步: 微观 EKF 的测量更新。

$$K_{k,l}^x = \sum_{x_{k,l}}^- (C_{k,l}^x)^T [C_{k,l}^x \sum_{x_{k,l}}^- (C_{k,l}^x)^T + \sum_{v_{k,l}}]^{-1} \quad (18)$$

$$\begin{aligned} \hat{x}_{k,l} &= \hat{x}_{k,l}^- + K_{k,l}^x [y_{k,l} - G(\hat{x}_{k,l}^-, u_{k,l}, \hat{\theta}_{k-1})], \quad \sum_{x_{k,l}}^- \\ &= (I - K_{k,l}^x C_{k,l}^x) \sum_{x_{k,l}}^- \end{aligned} \quad (19)$$

其中, 定义以下 Yacobi 矩阵:

$$A_{k,l-1} = \left. \frac{\partial F(x, u_{k,l-1}, \hat{\theta}_{k-1})}{\partial x} \right|_{x = \hat{x}_{k,l-1}^-}, \quad (20)$$

$$C_{k,l}^x = \left. \frac{\partial G(x, u_{k,l}, \hat{\theta}_{k-1})}{\partial x} \right|_{x = \hat{x}_{k,l}^-} \quad (20)$$

$$C_k^{\theta} = \left. \frac{dF_{0 \rightarrow L}(\hat{x}_{k-1,0}, u_{k-1,0:L-1}, \theta)}{d\theta} \right|_{\theta = \hat{\theta}_k^-} \quad (21)$$

接下来介绍卫星锂电池系统多时间尺度的 EKF 预测算法执行过程。流程图见图 2。算法包括两个并行运行的扩展式卡尔曼滤波器: 上半部分(微观 EKF)在微观时标上修正 SOC, 下半部分(宏观 EKF)在宏观时标上修正可用电量。微观 EKF 发送 SOC 估计值到宏观 EKF 并从宏观 EKF 接收最大可用电量估计值。

3 实例验证

3.1 实验过程

实验采用了最大可用电量为 1.6 Ah 的 NCA/C 星载锂离子电。测试系统包括卫星锂电池综合测试设备、温度传感器

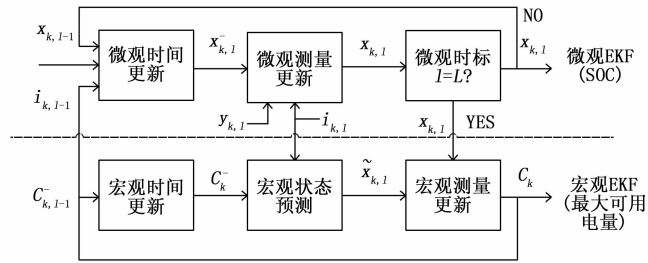


图 2 基于 EKF 的卫星锂电池 SOC 多时间尺度估算流程图

组件、NCA/C 星载锂电池以及专用安装夹具等。根据本地试验效果用 37 号电池的数据进行辨识和仿真。实验所用的 NCA/C 星载卫星锂电池及实验设备见图 3。






图 3 卫星锂离子电池及实验设备

3.2 实验结果及分析

在 MATLAB 软件中建立 Thevenin 等效电路模型, 自定义工况电流作为输入信号, 进行仿真实验。使用 EKF 联合估计算法^[13]得到的 SOC 以及最大可用电量估计曲线如图 4 所示。



(a) 端电压预测值与测量值关系 (b) SOC 估计值与真值关系



(c) 系统参数 Q 估计值与真值关系

图 4 EKF 联合估计算法仿真结果

使用多时间尺度的 EKF 预测算法得到的 NCA/C 星载锂电池 SOC 以及最大可用电量估计曲线如图 5 所示。

关于最大可用电量估计, 两种方法设置的初始值均小于真实值, 见图 4 (c) 和图 5 (c)。从图 4 (c) 可以明显看出估




图 5 多时间尺度算法仿真结果

计最大可用电量未能密切跟踪真实最大可用电量，最终收敛到真实最大可用电量大约 4.3% 的误差范围内，且包含较大的噪声。而图 5 (c) 随着仿真步数增加逐渐收敛到真实最大可用电量。EKF 联合估计算法的精度较低归因于在 SOC 和最大可用电量估计方面的测量和时间尺度耦合。为修正最大可用电量预测值，EKF 联合估计算法使用电池端电压作为量测值对最大可用电量进行修正，见公式 (22)。

$$\hat{\theta}_{k,l} = \hat{\theta}_{k,l} + K_{k,l}^q (y_{k,l} - G(\hat{x}_{k,l}, u_{k,l})) \quad (22)$$

不同的是，多时间尺度算法在宏观尺度上按照公式 (23) 和 (24) 对最大可用电量进行估计，避免了并行的 SOC 和最大可用电量估计过程仅依赖于量测值（电池端电压）。

$$\hat{x}_{k-1,L} = F_{0 \rightarrow L} (\hat{x}_{k-1,0}, u_{k-1,L-1}, \hat{\theta}_k) \quad (23)$$

$$\hat{\theta}_k = \hat{\theta}_k + K_k [\hat{x}_{k-1,L} - \tilde{x}_{k-1,L}] \quad (24)$$

并且，观测方程 $G(\hat{x}_{k,l}, u_{k,l})$ 与最大可用电量之间并没有直接函数关系，使用观测值对最大可用电量进行更新时，只是单纯依靠测量的高斯白噪声对其进行卡尔曼滤波处理，因而效果有限。而状态量 $x_{k,l} = [z_{k,l} \ U_{k,l}^q]^T$ 与最大可用电量有直接联系，使用状态量对参数进行更新能够产生更可靠的最大可用电量估计值。对比图 4 (a) 和图 5 (a) 可看出，使用多时间尺度的 EKF 预测，端电压仿真值更紧密跟随量测值变化，包含的噪声更少。图 5 (a) 中 SOC 估计值比图 4 (a) 中 SOC 估计值误差更小。由于 SOC 估计对最大可用容量的依赖性很强，最大可用容量估计的精度不足会降低 SOC 估计的准确性。多时间尺度的 EKF 预测算法提供了更为准确的最大可用容量估计值，SOC 估计值也更准确。多时间尺度的 EKF 预测算法比 EKF 联合估计算法在一定程度上提高了预测性能。

除准确性比较外，在计算效率方面也比较了两种方法，如表 1 所示。

表 1 计算效率对比

算法类型	计算时间/s	效率提高(%)
EKF 联合估计算法	0.552	——
多时间尺度的 EKF 预测算法	0.522	5.43%

为将随机性的影响减到最小，将上述两种方法执行了 10 次，取均值进行比较。表 1 总结了平均计算的时间，可以观察到多时间尺度的 EKF 预测算法比 EKF 联合估计算法消耗了较少的计算时间。这有助于在卫星故障预测和健康管理 (PHM) 系统中减少计算量以及硬件的负担，有利于提高 PHM 系统应用灵活性和效率。

4 结论

多时间尺度的 EKF 预测算法是针对时标分离的工程系统有效的、准确的状态及参数估计方法。本文基于等效模型，利用多时间尺度 EKF 算法在微观尺度上对锂离子电池 SOC 进行预测，并在宏观尺度上利用了 SOC 估计值作为观测量对最大可用电量进行预测，效果优于 EKF 联合估计，同时提高了计算效率。下一步工作将在建立锂离子电池的等效模型以及 OCV 与 SOC 关系模型时，考虑温度对 SOC 的影响、电量对 OCV 的影响等，提高模型精度以获得更准确的估计值。

参考文献:

- [1] 吴宇平, 万春荣, 姜长印. 锂离子二次电池 [M]. 北京: 化学工业出版社, 2002.
- [2] 艾力, 房红征, 于功敬, 等. 基于数据驱动的卫星锂离子电池寿命预测方法 [J]. 计算机测量与控制, 2015, 23 (4): 1262 - 1265; 1272.
- [3] 陈冰, 鲁刚, 房红征, 等. 基于最小二乘支持向量机的卫星异常检测方法 [J]. 计算机测量与控制, 2014, 22 (3): 690 - 692.
- [4] Goebel Kai, et al. Prognostics in battery health management [J]. IEEE instrumentation & measurement magazine [J]. 2008, 11 (4): 33 - 40.
- [5] Plett Gregory L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background [J]. Journal of Power Sources, 2006 (2): 262 - 276.
- [6] Plett Gregory L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 2. Modeling and identification [J]. Journal of power sources, 2004 (2): 262 - 276.
- [7] Plett Gregory L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 3. State and parameter estimation [J]. Journal of Power sources, 2004 (2): 277 - 292.
- [8] Plett Gregory L. Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1: Introduction and state estimation [J]. Journal of Power Sources, 2006 (2): 1356 - 1368.
- [9] 胡运飞. 混合动力汽车用镍氢电池建模及其 SOC 估计研究 [R]. 中国科学院电工研究所, 2008.
- [10] He Wei, et al. State of charge estimation for Li-ion batteries using neural network modeling and unscented Kalman filter-based error cancellation [J]. International Journal of Electrical Power & Energy Systems, 2014, 62: 783 - 791.
- [11] Lee Seongjun, 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 (2): 1367 - 1373.
- [12] Rahimi-Eichi, Baronti H F, Chow M Y. Modeling and online parameter identification of Li-Polymer battery cells for SOC estimation [C]. Industrial Electronics (ISIE), 2012 IEEE International Symposium on. IEEE, 2012.
- [13] Simon D. Optimal state estimation: Kalman, H-infinity, and nonlinear approaches [M]. John Wiley & Sons, 2006.