

不同时间尺度下锂电池 SoC 估算研究

潘海鸿, 李君子, 吕治强, 林伟龙, 陈琳

(广西大学 机械工程学院, 南宁 530000)

摘要: 针对当前电池荷电状态 (SoC) 估算算法在处理器运算过程中计算量大, 耗费处理器资源多的问题, 提出在 SoC 估算中同时增大辨识时间尺度和估算时间尺度; 采用带遗忘因子递推最小二乘法辨识电池模型参数, 并探究不同大小的时间尺度对 SoC 估算精度的影响; 仿真结果表明, 随着辨识时间尺度和估算时间尺度增大, SoC 估算精度下降且计算量快速下降, 计算消耗时间呈指数减少; 当时间尺度过大时, SoC 估算精度难以保证, 计算消耗时间减少不明显, 收敛时间长; 在综合考虑估算精度和计算耗费时间情况下, 可以找到一个最优的时间尺度用于保证 SoC 估算精度同时大大降低计算量; 该方法为后续实现电动汽车 SoC 在线估算提供理论依据。

关键词: 锂离子电池; 电池荷电状态; 最小二乘法;

Research on Lithium-ion Battery State of Charge Estimation Under Different Time Scale

Pan Haihong, Li Junzi, Lü Zhiqiang, Lin Weilong, Chen Lin

(College of Mechanical Engineering, Guangxi University, Nanning 530000, China)

Abstract: In order to solve the problem of heavy calculation burden and large consumption of microcontroller cost that faced in current algorithm of state of charge (SoC) estimation. Increasing time scale of estimation and parameters identification is proposed to estimate SoC. The recursive least squares algorithm with forgetting factor is used to identify battery model and estimate the SoC. The influence of different sizes of time scales for the accuracy of SoC estimation is explored. Simulation results show with the increase of identified time scale and estimated time scale, the accuracy of SoC decrease and calculation burden decline rapidly, the computing time present an exponential decay. An oversize time scale can't guarantee SoC estimation accuracy, the computing time is not decay obviously and the convergence time is long. Comprehensive consideration of estimation accuracy and computing time, an optimal time scale can be achieved which can reduce calculation burden, and ensure accuracy of SoC estimation. The method provides theory basis for subsequent implementation of online SoC estimation in electric vehicles.

Keywords: lithium-ion battery; state of charge; least square method

0 引言

近年来, 环境污染和能源短缺带来的问题越发明显, 如何解决这些问题一直是工业发展中的重中之重, 电动汽车因其零排放, 结构简单受到越来越多的关注。世界各国都在大力发展电动汽车技术, 预计到 2050 年, 在世界范围内电动汽车的市场占有率将达到 60%^[1-2]。锂离子电池具有寿命长, 能量密度大、功率比高等特性^[3-4], 是电动汽车主要动力来源。但在电动汽车运行过程中, 复杂工况以及电池本身各自差异都对电池运行状态产生重大影响, 因此作为连接动力电池和电动汽车的重要纽带, 电池管理系统 (BMS) 必不可少^[5]。电池荷电状态 (SoC) 是 BMS 中实时监控的一个重要参数, 是电池管理核心技术之一, 它能够评判电池剩余电量多少, 它也是判断电池是否过充电或过放电的重要依据, 是电动汽车安全可靠运行的重要保障。为了提高 SoC 估算精度, 大量 SoC 估算方法被提出,

现有常用方法大致可以分为两类: 第一类将电池看作一个“黑箱”的模糊逻辑和机器学习类方法, 第二类是基于等效电路模型和电化学模型方法。在第一类方法中, 人工神经网络算法, 模糊逻辑算法和支持向量机^[6-8]等需要训练大量的数据, 数据需求量和计算量大, 难以应用于实际的 BMS 中。而第二类基于模型算法用电阻、电容等构成电路, 模拟电池在不同工况下的放电特性, 在其基础上提出有开路电压法, 卡尔曼滤波器算法, PI 观测器算法等^[9-11]。在基于模型算法中准确辨识出电池模型的参数至关重要, 一个正确电池模型才能实时反映出电池特性。确定电池模型参数后, 依据电池模型可以实施电池 SoC 估算。电池模型参数辨识和电池 SoC 估算往往是在同一时间尺度实行, 如双卡尔曼估算/联合扩展卡尔曼^[12]等。但电池参数是一个较为缓慢变化的量, 而电池状态如 SoC 具有快速时变特性。同一时间尺度下电池参数和状态估算如果都选取较小的时间尺度, 将耗费大量计算资源。因此不同时间尺度下电池参数和电池状态估算被提出^[13-14], 在这些文献中提出采用宏观时间尺度和微观时间尺度分别对应模型参数辨识时间尺度和电池状态更新时间尺度, 在估算 SoC 时通过改变辨识时间尺度 (宏观时间尺度) 的大小减小计算成本提高估算精度, 而状态估算时间尺度 (微观尺度) 选取较小的时间尺度来达到实时更新的效果, 但在 SoC 估算中, 较小的估算时间尺度带来的计算量大, 消耗处理器资源多。考虑到 SoC 虽然是一个迅速变化量, 在实际汽车应用中, 驾驶员对 SoC 观察往往都是

收稿日期: 2016-01-12; 修回日期: 2016-03-07。

基金项目: 国家自然科学基金 (51267002); 广西自然科学基金资助 (2015GXNSFAA139287)。

作者简介: 潘海鸿 (1966-), 男, 广西南宁人, 教授, 博士研究生导师, 主要从事高速高精度运动控制、数控技术、嵌入式控制系统和 IC 装备方面的研究。

通讯作者: 陈琳 (1973-), 女, 山东青岛人, 教授, 硕士研究生导师, 主要从事信号检测与处理方向的研究。

一个间断的不定时的量。适当降低 SoC 的更新频率符合驾驶习惯同时也能进一步减少计算量和占用的处理器资源。因此，在电池状态估算中，提出同时增大辨识时间尺度和估算时间尺度，基于电池 Thevenin 模型，采用带遗忘因子的最小二乘法 (FFRLS) 探究了在不同大小时间尺度对 SoC 的估算的影响。

1 锂离子电建模

Thevenin 等效电路即一阶 RC 模型，综合考虑到了电池模型的精确度和复杂程度。Thevenin 等效电路更适用于模拟锂离子电池的动态特性，电池模型具体如图 1 所示。

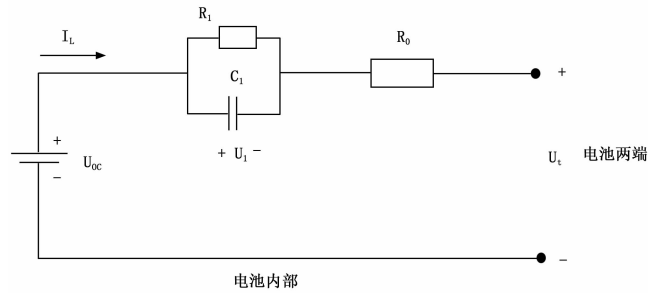


图 1 Thevenin 等效电路

图 1 中 I_L 为电池所受激励电流 (I_L 符号以电池放电时电流方向为正, 以电池充电时电流方向为负); U_{0c} 表示锂离子电池开路电压部分, 该部分常视为 $U_{0c} = f(SOC)$; U_t 为电池端电压; R_0 表示锂离子电池欧姆内阻部分; R_1 和 C_1 分别为极化内阻和极化电容;

Thevenin 模型等效电路方程表达式为 (1):

$$\begin{aligned} \dot{U}_1 &= \frac{I_L}{C_1} - \frac{U_1}{R_1 C_1} \\ U_t &= U_{0c} - U_1 - I_L R_0 \end{aligned} \quad (1)$$

为后续辨识模型参数，将等效电路模型改写为离散化时间序列形式，方程式 (1) 可改写为 (2):

$$\begin{aligned} U_t(k) &= (1 - a_1)U_{0c}(k) + a_1 U_t(k-1) + \\ & a_2 I_L(k) + a_3 I_L(k-1) \end{aligned} \quad (2)$$

其中: k 为采样序列时刻序号, $k=1, 2, 3, \dots, n$ 。

Thevenin 等效电路模型中的参数 R_1, C_1, R_0 可以从 a_1, a_2, a_3 中推导得出, 相关的计算关系式如 (3), (4):

$$\begin{cases} a_1 = -\frac{T - 2R_1 C_1}{T + 2R_1 C_1} \\ a_2 = -\frac{R_0 T + R_1 T + 2R_0 R_1 C_1}{T + 2R_1 C_1} \\ a_3 = -\frac{R_0 T + R_1 T - 2R_0 R_1 C_1}{T + 2R_1 C_1} \end{cases} \quad (3)$$

$$\begin{cases} R_0 = \frac{a_3 - a_2}{1 + a_1} \\ R_1 = \frac{2(a_3 - a_1 a_2)}{a_1^2 - 1} \\ C_1 = \frac{-(a_1 T - T)(a_1 + 1)}{4(a_3 + a_1 a_2)} \end{cases} \quad (4)$$

2 锂离子电建模模型参数辨识

递推最小二乘算法的提出源于最小二乘算法并结合自适应滤波理论，是一种在锂离子模型参数辨识上经典算法。带遗忘因子的递推最小二乘是最小二乘算法的改进，在对采样序列中旧数据乘以一个给定的遗忘因子，将老数据对参数估算的影响

权重降低，同时新信息对系统参数辨识影响程度较大，且保证数据越新权重越大。在使用算法做锂离子 Thevenin 模型参数辨识时，需先将系统数学表达式变换成如公式 (5) 所示:

$$Y(k) = \mathbf{H}(k)\boldsymbol{\theta}(k) + e(k) \quad (5)$$

其中: $e(k)$ 为算法对电池端电压值预测误差，其中 $Y(k)$ 为系统输出变量。系统数据矩阵 $\mathbf{H}(k)$ 与系统输出变量 $Y(k)$ 均可以通过对电池进行数据采集和记录获得，通过求解方程组即可求出系统参数矩阵 $\boldsymbol{\theta}(k)$ ，利用系统参数矩阵结果代入公式 (4) 计算得模型参数。

结合 Thevenin 等效电路模型，递推最小二乘法具体表达式为 (6):

$$\begin{cases} \mathbf{H}(k) = [1 \quad U_t(t-1) \quad I_L(k) \quad I_L(k-1)] \\ \boldsymbol{\theta}[(1 - a_1)U_{0c}(k) \quad a_1(k) \quad a_2(k) \quad a_3(k)] \end{cases} \quad (6)$$

FFRLS 算法表达式 (7):

$$\begin{cases} e(k) = U_t(k) - \mathbf{H}(k)\boldsymbol{\theta}(k-1) \\ \mathbf{K}(k) = \frac{\mathbf{P}(k-1) * \mathbf{H}^T(k)}{\mathbf{H}^T(k) * \mathbf{P}(k-1) * \mathbf{H}(k) + \lambda} \\ \mathbf{P}(k) = \frac{\mathbf{P}(k-1) - \mathbf{K}(k)\mathbf{H}^T(k)\mathbf{P}(k-1)}{\lambda} \\ \boldsymbol{\theta}(k) = \boldsymbol{\theta}(k-1) + \mathbf{K}(k)e(k) \end{cases} \quad (7)$$

式 (7) 中, $\mathbf{K}(k)$ 为算法增益矩阵在 k 时刻的值, $\mathbf{P}(k)$ 为算法协方差矩阵在 k 时刻的值, $\boldsymbol{\theta}(k)$ 为算法估算的 k 时刻系统参数矩阵, λ 为 FFRLS 遗忘因子系数, 通常其取值范围在 $[0.95, 1]$ 区间内。特别的, 当 λ 值为 1 时, FFRLS 算法变成标准递推最小二乘算法。利用 FFRLS 算法进行 1 阶 RC 模型辨识时递推求解出每一时刻 $\boldsymbol{\theta}(k)$ 值, 即可计算 1 阶 RC 模型式 (3) 中的参数。

3 实验结果分析

3.1 实验平台

该实验平台由锂离子电池 (18650-NMC)、一台直流电源、电子负载仪、恒温箱、中央控制电脑以及为搭建平台所必须的一些硬件辅助设备, 如导线等。

实验开始前每组电池先以 1.3 A 的恒定电流 (CC) 模式进行充电, 直到电压达到 4.2 V; 然后以一个恒定电压 (CV) 模式继续充电, 直到充电电流下降到 20 mA。根据不同放电工况放电, 截止电压为 2.75 V。


3.2 电池模型参数的验证

UDDS (urban dynamometer driving schedule) 工况是一种典型的动态工况, 选用 UDDS 工况 (Urban Dynamometer Driving Schedule) 动态工况来验证带遗忘因子的最小二乘法辨识电池模型在动态工况下的精度, 获得端电压试验结果与模型仿真结果及误差如图 2 所示


端电压误差统计结果图 2 (b) 所示, 其平均误差 0.6 mV; 误差标准差为 0.0185。等效电路模型误差在 1% 以内, 表明基于 FFRLS 辨识的 Thevenin 模型具有较高精度, 能够真实模拟锂离子动力电池的动态特性。

3.3 锂离子动力电池 SoC 估算

基于上述 FFRLS 辨识结果, 可从参数矩阵 $(1 - a_1)U_{0c}(K)$ 计算出电池实时开路电压, 依据开路电压与 SoC 关系 $U_{0c} = f(SOC)$, 通过查表法, 可以估算电池 SoC, 其中 $U_{0c} = f(SOC)$ 通过静置法放电法和插值获得相应的 OCV-SoC 关系。



(a) UDDS工况下端电压曲线



(b) 端电压误差

图 2 UDDS 工况下端电压结果及误差

3.4 不同时间尺度 SoC 估算结果

选用电池在 UDDS 工况下的放电结果，模型参数辨识时间尺度和 SoC 估算时间尺度设为同一时间尺度 L ， L 从 1 秒至 60 秒逐渐增大，间隔为 1 秒。均匀选取时间尺度为 $L=5, 20, 35, 50$ (s) 下 SoC 的结果为代表反应不同时间尺度下 SoC 估算结果如图 3 所示。

不同时间尺度下对应的 SoC 平均误差和估算消耗时间如图 4 所示。

从图 3 (a) ~ 3 (d)，可以看出，在不同时间尺度下 SoC 估算收敛时间随着时间尺度的增大而增大。FFRLS 辨识模型参数需要一定收敛时间，随着时间尺度增大，在同一段时间内，辨识时间尺度大包含数据量少，需要更多时间才能达到收敛。辨识所用时间尺度小，同一时间所含包含数据量更多，则

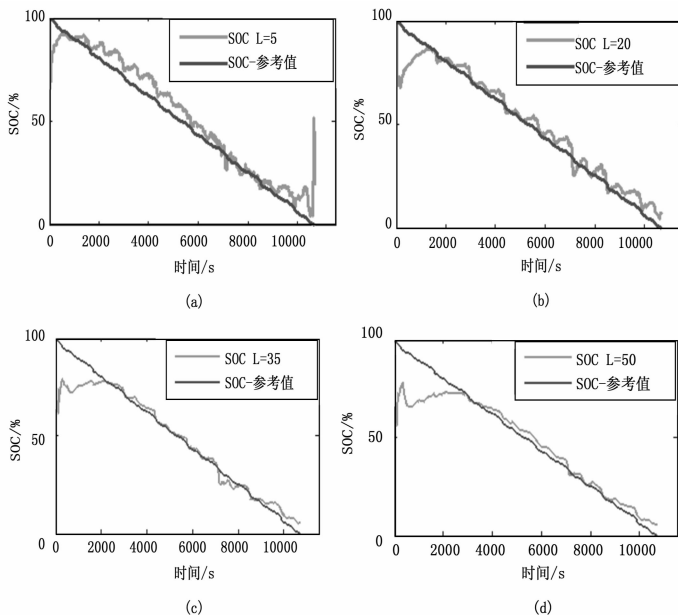


图 3 不同辨识时间尺度下 SoC 估算结果




图 4 不同时间尺度下 SoC 误差与估算消耗时间

能更快达到收敛，但计算量大。因此过大时间尺度导致算法收敛性变差。从图 4 可知，在不同时间尺度下 SoC 精度呈现非线性变化。时间尺度在 $1 \sim 10$ s 之间，SoC 误差呈现近似线性增长，但当选择辨识参数时间尺度继续增大时 ($L > 10$)，SoC 估算误差虽然有所下降但仍处于较大范围。较大时间尺度意味着在一段较长的时间内电池参数是固定的，相对于较小的时间尺度 (如 $L < 5$)，虽然参数较为稳定但估算精度下降。从计算消耗时间来看 (同一硬件处理器配置上，消耗时间少，计算量少，占用处理器资源少)，当时间尺度 ($L < 10$)，计算消耗时间随着时间尺度增大呈现指数衰减关系，当时间尺度 ($L > 10$) 时，计算消耗时间随着时间尺度的增长衰减速度不明显而估算精度仍处于误差较大范围。从图 3 (a) ~ 3 (d) 中也可以看出算法随着时间尺度增大，估算收敛时间增大。因此，综合考虑估算精度和计算成本，时间尺度选取应该在误差线和时间消耗线交点处 ($L=4$) 更合理，在这个范围内 SoC 估算精度虽然有所下降，但参数较为稳定，误差也在可接受范围，而计算量将大幅度减少，消耗处理器资源少。因此一个合适时间尺度不仅能跟踪电池特性变化，正确估算电池各项状态，同时也能够减少处理器计算量，释放处理器资源，更适用于电动汽车 BMS 状态计算监控等。

4 结论

针对电动车电池 SoC 算法在处理器运算过程中计算量大、消耗处理器资源多的问题，为进一步减少计算量，提出同时增大辨识时间尺度和估算时间尺度，建立并分析锂电池模型，辨识电池模型参数，在 UDDS 动态工况下验证了所使用的电池模型和辨识方法，探究了不同时间尺度下辨识和估算对 SoC 估算的精度影响，结果表明，时间尺度在 $1 \sim 10$ s 之间，SoC 误差呈现近似线性增长而计算成本几何指数减少，即随着时间尺度增大，SoC 精度下降但计算成本下降更快，而过大时间尺度，辨识结果不能够准确描述电池放电特性、估算结果误差增大、收敛时间长且计算成本减少不明显。因此综合考虑计算成本与估算精度，时间尺度选取 4 s 能够很好的模拟电池工况同时也能大大减少运算量，更有利于 SoC 的在线估算。

参考文献:

- [1] Sun B, Jiang J, Zheng F, et al. Practical state of health estimation of power batteries based on Delphi method and grey relational grade analysis [J]. Journal of Power Sources, 2015, 282: 146-157.
- [2] Barré A, Deguilhem B, Grolleau S, et al. A review on lithium-ion battery ageing mechanisms and estimations for automotive applications [J]. Journal of Power Sources, 2013, 241: 680-689.
- [3] 艾力, 房红征, 于功敬, 樊焕贞. 基于数据驱动卫星锂离子电池

池寿命预测方法 [J]. 计算机测量与控制, 2015, 23 (4): 1262-1265.

[4] 宋绍剑, 林庆芳, 林小峰. 纯电动汽车磷酸铁锂电池组的建模及优化 [J]. 计算机测量与控制, 2015, 23 (5): 1713-1716.

[5] Xing Y, Ma E W M, Tsui K L, et al. Battery Management Systems in Electric and Hybrid Vehicles [J]. Eenergies, 2011, 4 (11): 1840-1857.

[6] 尹安东, 张万兴, 赵 韩, 等. 基于神经网络的磷酸铁锂电池 SOC 预测研究 [J]. 电子测量与仪器学报, 2011, 25 (5), 433-437.

[7] 于 洋, 纪世忠, 魏克新. 基于 LS-SVM 算法动力电池 SOC 估计方法的研究 [J]. 电源技术, 2012, 36 (3): 349-351, 370.

[8] 石庆升. 纯电动汽车能量管理关键技术问题的研究 [D]. 济南: 山东大学, 2009.

[9] Tong S, Klein M P, Park J W. On-line optimization of battery open circuit voltage for improved state-of-charge and state-of-health estimation [J]. Journal of Power Sources, 2015, 293: 416-428.

[10] Xu J, Mi C C, Cao B, et al. The State of Charge Estimation of

Lithium-Ion Batteries Based on a Proportional-Integral Observer [J]. Vehicular Technology, IEEE Transactions on, 2014, 63 (4): 1614-1621.

[11] Junping W, Jingang G, Lei D. An adaptive Kalman filtering based State of Charge combined estimator for electric vehicle battery pack [J]. Energy Conversion and Management, 2009, 50 (12): 3182-3186.

[12] Plett G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs; Part 1. Background [J]. Journal of Power Sources, 2004, 134 (2): 252-261.

[13] Xiong R, Sun F, Chen Z, et al. A data-driven multi-scale extended Kalman filtering based parameter and state estimation approach of lithium-ion polymer battery in electric vehicles [J]. Applied Energy, 2014, 113 (0): 463-476.

[14] Hu C, Youn B D, Chung J. A multiscale framework with extended Kalman filter for lithium-ion battery SoC and capacity estimation [J]. Applied Energy, 2012, 92 (0): 694-704.

(上接第 248 页)

全景拼接效果如图 4。



图 4 全景拼接效果图

运用 Flash 实现全景过程中的关键环节是场景移动化, 需借助 FLASH 的动作脚本, 来实现漫游的效果。首先对 Flash 进行初始设置, 选择 Actionscript2.0 脚本环境, 移动过程如下:

```

q1_btn.onPress = function(){
    delete this._parent._root.tupian_mc.onEnterFrame;
    this._parent._root.tupian_mc.play();
};
q1_btn.onRelease = function(){
    _root.tupian_mc.stop();
};
h1_btn.onPress = function(){
    //this._parent._root.zjq_mc.stop();
    this._parent._root.tupian_mc.onEnterFrame = function()
    {
        this.prevFrame();
    };
};
h1_btn.onRelease = function(){
    delete this._parent._root.tupian_mc.onEnterFrame;
    tupian_mc.stop();
};

```

时间轴设置如图 5。

对监测系统设置监测按钮, 分别是场景观测的前进按钮和倒退按钮, 通过监测交互按钮的按下或抬起来进行场景的移动或停止, 首先在时间轴上进行整体全景图的漫游动画, 当前进按钮被按下时, 时间轴按已设定动画开始正向播放进行监测, 当前进按钮抬起后停止。当系统监测到后退按钮被按下时, 系统利用 prevFrame 函数使时间轴不断定位到当前帧的前一帧, 直到后退按钮抬起, 这样就实现了场景的倒序监测。



图 5 时间轴设置图

通过机舱内摄像机对机舱状况的定时监测拍摄, 将拍摄画面实时进行拼接并传输, Flash 通过调用不同时刻拼接的全景图像进行全景漫游, 进而实现对机舱内部不同时刻的状态监测。

5 结论

通过结合 Flash 技术与全景技术实现了全景监测虚拟系统, 解决了虚拟现实系统数据传输量大导致对硬件设备要求高的问题, 以及临场感差的问题, 并运用到了对风力发电机机舱内部的监测系统的开发, 由于机舱内部的某种异常状态出现后都会保持一定时间, 不可能实时发生变化, 故针对某一时刻拼接的场景画面进行全景漫游, 而不需要实时的存储记录大量冗余视频数据, 这种方式开发的虚拟系统拓宽了虚拟状态监测系统的开发思路。

参考文献:

[1] 苏建明, 张续红, 胡庆夕. 展望虚拟现实技术 [J]. 计算机仿真, 2004, 21 (1): 18-21.

[2] 王瑞闯, 林富洪. 风力发电机在线监测与诊断系统研究 [J]. 华东电力, 2009, 37 (1): 190-193.

[3] 刘 民, 万江平. 基于 Flash 3D 的在线虚拟漫游系统设计与实现 [J]. 计算机时代, 2014, (5): 36-41.

[4] 王凯湛, 马瑞峻. 虚拟现实技术及其在农业机械上的应用 [J]. 系统仿真学报, 2006, 18 (2): 500-503

[5] 戴 军, 张锋美. 基于 Flash 的实景虚拟漫游系统设计与实现 [J]. 实验室研究与探索, 2012, 31 (10): 78-80.

[6] 周亦鹏, 胡 娟. 基于三维全景技术的数字矿山漫游系统 [J]. 金属矿山, 2012, 5: 116-120

[7] 吴宪祥, 郭宝龙, 王 娟. 基于相位相关的柱面全景图像自动拼接算法 [J]. 光学学报, 2009, 29 (7): 1824-1829.