

基于信息融合的 LiFePO₄ 动力电池组 SOC 估计

何 耀, 张陈斌, 刘兴涛, 陈宗海

(中国科学技术大学 自动化系, 合肥 230027)

摘 要: 针对复杂工况下 LiFePO₄ 动力电池组 state-of-charge(SOC) 估计不准确的问题, 基于信息融合技术提出一种 SOC 估计信息融合架构和多模型切换估计 (MMSE) 算法. 该算法首先对充放电过程进行特征提取和模式分类, 针对特定的模式进行模型优化; 然后在系统运行时根据特征匹配结果切换估计模型, 实现优化估计; 最后通过纯电动客车实际运行数据的仿真实验验证了所提出 MMSE 算法的可行性和有效性.

关键词: LiFePO₄ 动力电池组; 荷电状态; 信息融合架构; 多模型切换估计

中图分类号: TM912

文献标志码: A

SOC estimation for LiFePO₄ high-power batteries based on information fusion

HE Yao, ZHANG Chen-bin, LIU Xing-tao, CHEN Zong-hai

(Department of Automation, University of Science and Technology of China, Hefei 230027, China.

Correspondent: CHEN Zong-hai, E-mail: chenzh@ustc.edu.cn)

Abstract: Aiming at the inaccuracy problem of state-of-charge(SOC) estimation under the complex conditions, an SOC estimation information fusion framework and a multi-model switch estimation(MMSE) algorithm based on the information fusion technology are proposed for LiFePO₄ high-power batteries. This algorithm carries out the feature extraction and the pattern classification of the charge and discharge processes, and then re-optimizes the estimation model according to the different patterns. The MMSE algorithm switches to the matching estimation model to acquire better performance based on the feature matching. The result of simulation with the running data of pure electric bus shows the feasibility and effectiveness of the SOC estimation based on the MMSE algorithm.

Key words: LiFePO₄ batteries; state-of-charge; information fusion framework; multi-model switch estimation

0 引 言

随着能源危机的加剧及环境的恶化, 电动汽车已成为全球交通能源转型的发展方向. 但动力电池组已成为阻碍纯电动汽车发展的瓶颈, 其安全性和续航能力是目前面临的核心问题. 在电池组管理方面, 对荷电状态 (SOC) 的精确估计是保障电池组安全性和续航能力的基础, 而电动汽车复杂的运行工况给 SOC 的精确估计带来了较大的困难. 目前的估计算法主要有安时积分法^[1-2]、开路电压法^[3]、神经网络方法^[4]、Kalman 系列滤波算法^[5-8]等. 安时积分法易受总容量误差、积分时间误差、电流传感器的漂移^[9]等影响, 导致算法不收敛, 虽然研究者提出了多种智能修正方法^[1-2], 但估计精度难以进一步提升. 开路电压法^[3]在运行过程中由于受到波动电流的影响, 应用效

果并不理想. 神经网络方法^[4]在训练系统参数的过程中需要大量的实时计算, 在工程实现上还有较大难度. 应用 Kalman 系列滤波算法^[5-8]对 SOC 进行估计时, 由于 LiFePO₄ 电池放电平台上的开路电压相对 SOC 的变化率极小, 实际运行时平台上的估计性能难以得到改善. 随着电池组系统的规模逐渐向外延伸, 受模型不确定性大、不易建模、非线性特性、复杂度高问题的制约, 单一的模型驱动方法很难描述系统的所有工作状态^[10], 需要多模型驱动与数据驱动相互融合才能更全面地反映系统的运行状态.

本文基于信息融合技术建立 SOC 估计的信息融合架构, 通过统计数据对电池组的充放电过程进行特征提取和模式划分, 建立不同模式下的优化模型. 在系统运行时根据模式特征实现估计模型的最佳切换,

收稿日期: 2012-09-27; 修回日期: 2013-01-25.

基金项目: 国家自然科学基金项目(61075073); 国家863计划项目(2009AA11A113).

作者简介: 何耀(1984—), 男, 博士, 从事新能源汽车、电池管理的研究; 陈宗海(1963—), 男, 教授, 博士生导师, 从事复杂系统的建模仿真与控制、机器人与智能系统、量子系统控制与量子态操纵等研究.

提高估计的精度和鲁棒性。

1 SOC估计信息融合架构

基于数据驱动的信息融合技术可以根据在线获得的数据对系统参数进行补充和修正, 并实现经验知识、理论模型和在线数据特征信息的协同处理, 完成多传感器采集信息的融合, 以获得复杂环境下目标状态更准确的认识^[10]。下面针对复杂运行环境下的动力电池组SOC估计提出一种基于数据驱动与模型驱动协同作用的多源信息融合架构, 并基于该架构实现了动力电池组SOC的多模型切换估计(MMSE)算法。

如图1所示, 数据驱动模块首先通过电池管理单元、整车CAN总线、充电CAN总线分别获取电池信息、整车信息和充电信息; 然后应用数据融合模块对各传感器实时采集信息进行融合; 最后通过特征提取和匹配模块筛选数据。模型驱动中通过先验知识和机理建模建立多个备选估计模型, 模型的关键参数通过特征匹配后的数据进行在线标定。数据驱动中经过筛选的数据与模型驱动选择的估计模型协作加工, 对电池组的SOC进行实时估计。融合性能的评价结果最终分别反馈回数据驱动模块和模型驱动模块, 及时调整、优化特征库和数据可信度评估准则。由于篇幅限制, 参数在线估计、特征库与数据可信度评估准则等将不在此文展开讨论。

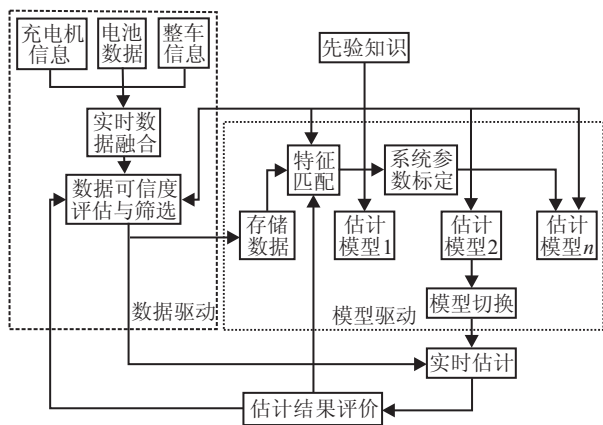


图1 动力电池组SOC估计信息融合框图

2 特征提取与模式划分

图2(a)为纯电动客车LiFePO₄电池组实际工况下从满电到放完电的一次完整运行过程的单体电压曲线, 其中小图为曲线的局部放大; 图2(b)为图2(a)中单体电压量测值滤除电流影响后的曲线与相对应SOC下的开路电压曲线的对比。从图2(b)中可以看出, 两者基本吻合。整个曲线分成3个比较明显的部分, 在A区域, 充、放电时电池的电压变化较快, 属于充电预充区间和放电保护区间; 在B区域, 除去电流因素的影响, 电池电压的变化非常缓慢, 此时电池处于稳定的工作状态, 通过电压量测值反馈修正

SOC比较困难; 在C区域, 充电时电压快速上升直到电池管理系统进入保护模式, 而放电时可以很快进入电压平台阶段。因此可以在SOC-OCV特征曲线基础上, 依据除去电流影响后的单体平均电压将整个充放电过程划分为5个模式, 如表1所示, 其中运行状态作为第1判断特征, 除去电流影响后的单体平均电压值作为第2判断特征。运行状态可通过整车CAN网络系统的信息共享取得。

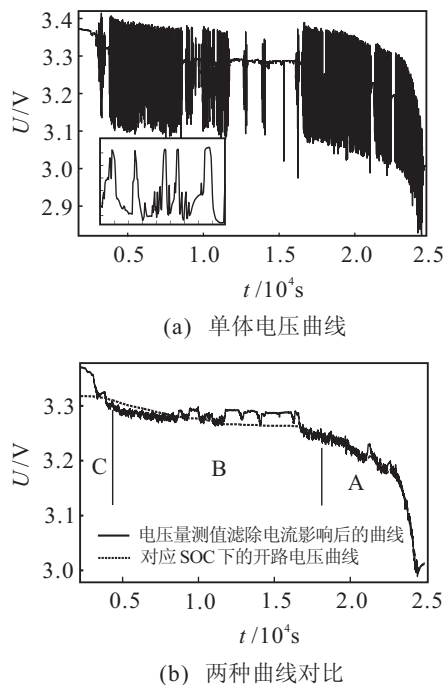


图2 动态运行过程中的LiFePO₄电池单体电压曲线

表1 锂电池组SOC估计初始特征提取及模式划分

模式	特征I	特征II	对应过程
模式1	充电	[2.5V 3.1V]	A区域(预充电阶段)
模式2	充电	(3.1V 3.5V)	B区域(充电平台)
模式3	充电	[3.5V 3.9V]	C区域(恒压充电阶段)
模式4	放电	(3.1V 3.9V)	B、C区域(放电平台)
模式5	放电	[2.5V 3.1V]	A区域(放电末端)

3 SOC多模型切换估计

3.1 SOC简化组合模型

在模式1和模式5中可以建立状态空间模型对SOC进行精确估计。由于组合模型(CM)^[7-8]是在SOC全区间应用, 在中间充放电平台上并不能取得较好的反馈效果, 反而降低了两端的估计性能。为了提升两端的拟合优度, 令系统状态变量为 $x(t) = SOC(t)$ 。在模式1和模式5中重新建模得到简化组合模型(SCM)的状态空间方程如下:

$$x_k = x_{k-1} + \frac{-\eta\Delta t}{C(T, \kappa, m)} i_{k-1} + w_{k-1}, \quad (1)$$

$$y_k = E_0 - Ri_k + \frac{K_1}{x_k} + K_2 \ln(x_k) + v_k. \quad (2)$$

式中: Δt 为系统采样周期, η 为库伦效率因子(充电时 $\eta < 1$, 放电时 $\eta = 1$), i_k 为 k 时刻的电流测量值, E_0 为

电池满电时的开路电压, R 为电池内阻, K_i 为电池的极化内阻, $C(T, \kappa, m)$ 为电池组实际工况下的实时总容量, T 为环境温度, κ 为充放电倍率, m 为电池组已行驶里程. 由于电池组的截止放电状态由单体最低电压确定, 在模式 1 和模式 5 中对电池组的 SOC 进行估计时, y_k 表示电池组的单体最低电压^[5]. w_k 和 v_k 是相互独立的高斯白噪声过程, $w_k \sim N(0, Q_w)$, $v_k \sim N(0, R_v)$. 该方法与全 SOC 范围内的状态空间方程建模方法相比, 需要的参数更少, 且进行参数估计时能够获得更精确的参数, 因此可以取得更优的估计结果.

在解决强非线性的估计问题时, EKF (extended Kalman filter) 方法呈现出性能下降甚至发散的缺陷, UKF (unscented Kalman filter) 方法则通过无迹变换生成样本点, 不需要对系统方程进行线性化, 能够对状态进行更精确的估计^[11]. 电池组系统在复杂工况下呈现出很强的非线性, 因此应用 UKF 方法能够取得更好的估计精度和鲁棒性能.

基于 SCM 的 UKF 算法如下:

Step 1: 初始化, $k = 0$, $x_0^+ = [\text{SOC}_0]$, $P_0^+ = P_0$.

Step 2: 对于 $k = 1, 2, \dots$, 有:

Step 2.1: Sigma 点集计算

$$\chi_{k-1}^+ = [x_{k-1}^+ \quad x_{k-1}^+ + \gamma \sqrt{P_{k-1}^+} \quad x_{k-1}^+ - \gamma \sqrt{P_{k-1}^+}],$$

其中 $\gamma = \sqrt{2 + \lambda}$, λ 为标量参数.

Step 2.2: 时间更新过程

$$\chi_{i,k}^- = \chi_{i,k-1}^+ + \frac{-\eta \Delta t}{C(T, \kappa, m)} i_{k-1}, \quad i = 0, 1, \dots, 4;$$

$$x_k^- = \sum_{i=0}^4 W_i^{(m)} \chi_{i,k}^-;$$

$$P_k^- = \sum_{i=0}^4 W_i^{(c)} (x_k^- - \chi_{i,k}^-)^2 + Q_w;$$

$$\varphi_{i,k}^- = E_0 - R i_k + K_1 / \chi_{i,k}^- + K_2 \ln(\chi_{i,k}^-);$$

$$y_k^- = \sum_{i=0}^4 W_i^{(m)} \varphi_{i,k}^-.$$

Step 2.3: 量测更新过程

$$P_{y_k y_k} = \sum_{i=0}^4 W_i^{(c)} (\varphi_{i,k}^- - y_k^-)^2 + R_v,$$

$$P_{x_k y_k} = \sum_{i=0}^4 W_i^{(c)} (\chi_{i,k}^- - x_k^-) (\varphi_{i,k}^- - y_k^-),$$


$$K_k = P_{x_k y_k} P_{y_k y_k}^{-1},$$

$$x_k^+ = x_k^- + K_k (y_k - y_k^-),$$


$$P_k^+ = P_k^- - K_k P_{y_k y_k} K_k^T.$$

其中 $W_i^{(m)}$, $W_i^{(c)}$ 为无迹变换权重因子, $i = 0, 1, \dots, 4$.

为验证 SCM 模型的有效性, 图 3 给出了某纯电动客车实际工况下在放电末端基于 CM 模型与 SCM 模型的 SOC 估计误差比较, 表 2 为相应的性能指标. 从图 3 和表 2 中可以看出, 基于 SCM 的 SOC 估计能够在 125 s 使误差绝对值控制在 2.5% 以内, 而基于 CM 的 SOC 估计在短时间内只能达到 4.35% 的指标, 同时, 基于 CM 的 SOC 估计均方根为 2.39%, 而基于 SCM 的 SOC 估计仅为 1.90%, 均方根误差性能提升了 20.5%. 因此 SCM 估计模型在电池组的放电末端具有更好的拟合效果.



(a) SOC 估计结果比较



(b) SOC 估计误差比较

图 3 基于 CM 和 SCM 的 SOC 估计性能比较

表 2 基于 CM 和 SCM 的 SOC 估计性能比较

模型	最大绝对误差/%	均方根误差/%	执行时间/s
UKF-CM	4.35	2.39	2.7292
UKF-SCM	2.52	1.90	2.7038

3.2 SOC MMSE 算法

通过前文的分析, 在不同的模式下选择适配的模型可以提高估计精度. 如图 4 所示, 在 t_0 时刻以前, LiFePO_4 电池组工作于充放电平台上, 此时不同 SOC 下的开路电压变化极小, 在 SOC 初值误差较大时, 应用 Kalman 系列滤波算法进行 SOC 估计的收敛速度较慢, 甚至由于检测数据误差较大, 有可能导致 SOC 出现较大幅度的抖动; 而在 t_1 时刻之后, 不同 SOC 下的开路电压相差较大, 应用 Kalman 系列滤波算法对 SOC 进行估计时, 可以将 SOC 迅速调整到真实值附近; 在充电末端持续时间较短, 且容易通过 SOC-OCV 表获得精确值, 可以直接查表求解. 因此结

合第 2 节的模式划分, 可以在模式 1 和模式 5 中建立基于 SCM 模型的状态空间方程对 SOC 进行精确估计, 在模式 2 和模式 4 中选择简单易实现的安时积分法进行估计, 而在模式 3 中应用单体最高开路电压值查询 SOC-OCV 表得到 SOC 值. 为了提高估计精度和鲁棒性能, 在电池组系统发生故障或单体电池一致性差异较大时, 仅使用安时积分法进行估计, 可以避免错误的检测信息影响到 SOC 的估计.




图 4 充放电平台上不同初值时 SOC 估计误差曲线

MMSE 算法的具体步骤如下:

Step 1: 初始化, $k = 0$, 从存储器中读取 SOC 的初值 SOC_0 .

Step 2: 对于 $k = 1, 2, \dots$, 获取电池组故障及一致性状态, 若正常则转 Step 2.1, 否则转 Step 2.2.

Step 2.1: 如果电池处于充电状态, 则转 Step 2.1.1, 否则转 Step 2.1.4;

Step 2.1.1: 如果滤除电流影响后的电压平均值 $\bar{V}_k \leq 3.1 \text{ V}$ (模式 1), 则切换到 SCM 模型, 利用检测电流 i_k 、单体最低电压值 V_{\min} 估计得到 SOC_k , 然后转入下一步迭代, 否则转 Step 2.1.2;

Step 2.1.2: 如果 $\bar{V}_k > 3.1 \text{ V}$ 且 $\bar{V}_k \leq 3.5 \text{ V}$ (模式 2), 则跳转 Step 2.2, 使用安时积分法计算 SOC_k , 否则转 Step 2.1.3;

Step 2.1.3: 如果 $\bar{V}_k > 3.5 \text{ V}$ (模式 3), 则通过电流值 i_k 和单体最高电压 V_{\max} 计算开路电压 $OCV_{\max} = V_{\max} + R_c i_{mk}$, 然后利用 OCV_{\max} 查询 SOC-OCV 表得到 SOC_k , 转入下一步迭代;

Step 2.1.4: 如果 $\bar{V}_k > 3.1 \text{ V}$ (模式 4), 则转 Step 2.2 使用安时积分法计算 SOC_k , 否则转 Step 2.1.5;


Step 2.1.5: 切换到 SCM 模型利用检测电流 i_k 、单体最低电压值 V_{\min} 进行 SOC 估计, 从而得到 SOC_k , 转入下一步迭代.

Step 2.2: 安时积分. 根据检测到的电流值 i_k 和采样间隔时间 Δt_k , 利用式 (1) 进行 SOC 估计得到 SOC_k , 转入 Step 2.


4 仿真与结果分析

为验证所提出的 MMSE SOC 估计算法的有效性, 以某纯电动客车从满电开始的一次完整行驶试验

数据进行 Matlab 仿真, 估计结果与单一模型的 UKF 估计算法从最大绝对估计误差、均方根误差、计算耗时等方面进行比较. 图 5(a) 为 SOC 估计曲线 (假设 SOC 初值误差为 2%, 总容量误差为 5%), 图 5(b) 为 SOC 估计误差曲线, 表 3 为关键指标比较. 从图 5(b) 中可以看出, 基于单一模型的 UKF 估计算法在中间放电平台上的最大绝对误差比较大, 这是由于在这一区间的 LiFePO₄ 电池开路电压相对 SOC 的变化率极小, 无法通过电压反馈实现 SOC 的精确校准, 在此处反而出现了 SOC 过调; 而安时积分方法的误差主要来源于初值误差和总容量的偏差 (电流漂移噪声和总容量已通过参数估计器动态估计^[9]), 因此不会出现大抖动. 在放电末端, 基于 SCM 的 UKF 估计算法可以将安时积分法中产生的估计误差迅速消除掉, 这主要得益于在电池放电末端 SCM 的精确建模. 同时由表 3 中可以看出, 基于 MMSE 的 SOC 估计算法的均方根误差和计算量都比较小.



(a) SOC 估计结果比较



(b) SOC 估计误差比较

图 5 单一模型 UKF 估计和 MMSE 的 SOC 估计性能比较

表 5 单一模型 UKF 估计算法和 MMSE 算法性能比较

模型	最大绝对误差/%	均方根误差/%	执行时间/s
UKF-CM	9.38	4.55	10.60
MMSE	4.61	3.28	3.814

5 结 论

LiFePO₄ 动力电池组 SOC 的精确估计受诸多因素的影响, 利用单一的估计模型难以取得较好的估计结果. 本文在融合整车信息、充电机信息和电池组信息的基础上结合 LiFePO₄ 电池组特征将充放电过程

划分为多个模式,在不同的运行模式下切换到适配的模型对 SOC 进行估计.通过实际工况下的运行数据进行 Matlab 仿真,验证了本文所提出的 MMSE 方法的可行性和有效性.当电池组一致性差异较大时,如何融合更多的整车信息以提升 LiFePO₄ 电池组 SOC 估计的精度有待进一步研究.

参考文献(References)

- [1] Piller S, Perrin M, Jossen A. Methods for state-of-charge determination and their applications[J]. J Power Sources, 2001, 96(1): 113-120.
- [2] Ng K S, Moo C S, Chen Y P, 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.
- [3] 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]. J Power Sources, 2008, 185(2): 1367-1373.
- [4] Charkhgard M, Farrokhi M. State-of-charge estimation for lithium-ion batteries using neural networks and EKF[J]. IEEE Trans on Industrial Electronics, 2010, 57(12): 4178-4187.
- [5] 刘新天, 刘兴涛, 何耀, 等. 基于 V_{\min} -EKF 的动力锂电池组 SOC 估计[J]. 控制与决策, 2010, 25(3): 445-448.
- (Liu X T, Liu X T, He Y, et al. Based- V_{\min} -EKF SOC estimation for power Li-ion battery pack[J]. Control and Decision, 2010, 25(3): 445-448.)
- [6] Plett G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs, Part 2: Modeling and identification[J]. J Power Sources, 2004, 134(2): 262-276.
- [7] Plett G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs, Part 3: State and parameter estimation[J]. J Power Sources, 2004, 134(2): 277-292.
- [8] Santhanagopalan S, White R E. State of charge estimation using an unscented filter for high power lithium ion cells[J]. Int J of Energy Research, 2010, 34(2): 152-163.
- [9] He Y, Liu X T, Zhang C B, et al. A new model for state-of-charge(SOC) estimation for high-power li-ion batteries[J]. Applied Energy, 2013, 101: 808-814.
- [10] 侯忠生, 许建新. 数据驱动控制理论及方法的回顾和展望[J]. 自动化学报, 2009, 35(6): 650-667.
(Hou Z S, Xu J X. On data-driven control theory: The state of the art and perspective[J]. Acta Automatica Sinica, 2009, 35(6): 650-667.)
- [11] Simon Haykin. Kalman filtering and neural networks[M]. New York: John Wiley & Sons, Inc, 2001.

(责任编辑: 孙艺红)