

基于Drift-Ah积分法的CKF估算锂电池SOC

刘新天¹, 李涵琪¹, 魏增福², 何耀^{1†}, 曾国建¹

(1. 合肥工业大学 汽车工程技术研究院, 合肥 230009;

2. 广东电科院能源科技有限责任公司, 广州 510080)

摘要: 锂电池荷电状态(SOC)是反映电池使用情况的重要参数之一. 在锂电池实际工作过程中, 电流传感器测量时的漂移电流会对SOC估计精度造成很大影响. 对此, 提出一种加入漂移电流的Drift-Ah积分法, 建立SOC的噪声组合模型, 并采用容积卡尔曼滤波算法(CKF)实现锂电池的SOC估计. 最后, 对锂电池进行模拟工况实验, 仿真结果表明, 所提出的估计算法可以有效抑制漂移电流的干扰, 精度高且复杂度低.

关键词: 锂电池; 荷电状态; 漂移电流; Drift-Ah积分法; 噪声组合模型; 容积卡尔曼滤波器

中图分类号: TP27

文献标志码: A

CKF estimation Li-ion battery SOC based on Drift-Ah integral method

LIU Xin-tian¹, LI Han-qi¹, WEI Zeng-fu², HE Yao^{1†}, ZENG Guo-jian¹

(1. Automotive Engineering Technology Institute, Hefei University of Technology, Hefei 230009, China; 2. Guangdong Diankeyuan Energy Technology Co. Ltd, Guangzhou 510080, China)

Abstract: State of charge(SOC) is one of the important parameters that reflects battery usage. In the actual work process of lithium battery, the drift current measured by current sensor will have great influence on the accuracy of SOC estimation. For this problem, the Drift-Ah integral method is proposed with drift current, the noise combination model is established, and the SOC estimation of lithium battery is achieved by using the cubature Kalman filter (CKF). Finally, the simulation experiment of lithium battery is carried out. Simulation results show that the proposed method can effectively suppress disturbance of drift current, with the advantages of high filtering accuracy and low complexity.

Keywords: lithium battery; state of charge; drift current; Drift-Ah integral method; noise combination model; cubature Kalman filter

0 引言

电池作为储存电能的便捷工具, 具有充放电速度快、响应速度快、环境适应性较强的优点, 已成为电动汽车的理想动力装置^[1]. 精准的荷电状态(State of charge, SOC)可以有效防止蓄电池过充、过放, 保障电池的可靠应用, 并为后续的主动均衡^[2]研究提供数据方案.

当前, 对于电池SOC估算方法有Ah(安时)积分法、开路电压法、神经网络法、卡尔曼滤波(Kalman filter, KF)估算^[3]等. Ah积分法简单易行, 但由于是开环控制存在误差累积的缺陷, 不适用于复杂工况. 开路电压法可由电池端电压的变化来映射SOC的增减量, 使用方便且工作量较小, 但需要长时间的静置, 不适用于在线估算. 神经网络法具有足够神经元时, 理

论上可以无限逼近真实的SOC, 因此, 基于神经网络的SOC估算得到了深入研究. 文献[4]以BP神经网络估算SOC, 使最大误差降到了5%以内, 但神经网络法估算精度受样本数量选择的影响^[5], 需要保证训练样本尽量涵盖电池的所有工作范围, 适用性较窄. 由文献[6]以300组训练样本取得1.5%的估算误差对比文献[7]以48组训练样本取得3.2%的误差结果, 可得到不同训练样本数对估算精度的影响. 卡尔曼滤波估算是一种基于状态空间模型的时域递推估计方法^[8], 能对非线性状态进行处理, 实现SOC的最小方差估算^[9], 具有反馈修正、估算精度高的优点. 对非线性状态方程处理方式的不同, 各种卡尔曼滤波器取得滤波效果也不同. 文献[10]基于等效电路模型以BP-EKF估算SOC, 使误差降到了2.78%.

收稿日期: 2017-09-13; 修回日期: 2018-01-19.

基金项目: 国家自然科学基金项目(61603120).

责任编委: 孙秋野.

作者简介: 刘新天(1981—), 男, 副研究员, 博士, 从事自动控制理论与电源管理系统等研究; 李涵琪(1993—), 男, 硕士生, 从事电池SOC预测算法与电池检测技术的研究.

[†]通讯作者. E-mail: xintian.liu@hfut.edu.cn.

除以上常见方法之外,文献[11]提出了 Gaussian mixture regression 估算 SOC; 文献[12]提出了基于多模型切换的 H_∞ 估算方法,有效降低了估算误差; 文献[13]提出了 Modified Luenberger observer, 并通过 Matlab 仿真验证了该方案可以提高估算精度。

当前估算方法的实验数据均来自于理想化无误差的传感器检测。在实际使用过程中由于传感器精度有限^[14],实际测量时存在着漂移电流值,即非零的均值噪声,如果不考虑漂移电流值,则会使 SOC 估算值与实际值相差甚远。文献[15]通过研究不同误差电流对 EKF 估算结果的影响,得出了估算误差与误差电流之间存在着线性增长关系。

为了能在接近实际使用情况下,准确描述电池状态估计,并实现精确估算,本文在 Ah 积分法基础上加入漂移电流噪声,提出 Drift-Ah 积分法,并以 Drift-Ah 积分法作为状态模块来估算当前电池 SOC。同时,建立电池电压-SOC-电流之间的函数关系,并以此作为观测模块,进而利用 CKF(Cubature Kalman filter)对电池 SOC 进行估算更新,可有效地减少漂移电流对估算精度的影响。

1 锂电池 Drift-Ah 积分法

1.1 漂移电流分析

目前常用的 SOC 定义为: 电池当前剩余容量占电池额定容量的比值, SOC 的状态方程为

$$\text{SOC}(t) = \text{SOC}_0 - \eta \cdot \int_0^t i(t) dt / Q_n. \quad (1)$$

其中: $\text{SOC}(t)$ 表示 t 时刻的 SOC 值; SOC_0 表示初始值; η 表示库伦效率,通常取值为 1^[16]; $i(t)$ 表示 t 时刻的电流; Q_n 表示电池的额定容量。式(1)的原理就是 Ah 积分法,电流与时间的积分即为所放容量。

电动汽车传感器大都采用霍尔传感器,测量误差主要存在于温漂、零漂、磁漂和增益误差^[7]等参数中,导致测量值与实际真实电流值存在偏差,即漂移电流^[17]。式(1)的 Ah 积分法以及其他 SOC 估算方法都直接以当前传感器测量电流作为实际电流,将当前电流与时间的积分视为放电容量,忽视了漂移电流与时间积分所得的容量,这也是 Ah 积分法估算误差的一个来源。

1.2 Drift-Ah 积分法

由 1.1 节可将实际电流分为测量电流和漂移电流,根据生产厂家的不同,当前霍尔电流传感器存在着 0.1%~0.5% 的误差电流^[14],因此,可建立如下关系式:

$$i_{\text{real}}(t) = i_D(t) - i_d(t) - q(t). \quad (2)$$

其中: $i_{\text{real}}(t)$ 表示 t 时刻实际电流; $i_D(t)$ 表示 t 时刻测量电流; $i_d(t)$ 表示 t 时刻漂移电流,数值由传感器出厂标定参数得到; $q(t)$ 表示漂移电流的噪声。将式(2)代入(1)便得到 Drift-Ah 积分法

$$\text{SOC}(t) = \text{SOC}_0 - \frac{\eta \cdot \int_0^t (i_D(t) - i_d(t) - q(t)) dt}{Q_n}. \quad (3)$$

式(3)的原理依旧是 Ah 积分法,通过对测量值与漂移值之差进行时间积分从而得到放电容量,以初始 SOC 值减去放电容量与额定容量之比即为当前 SOC。该方法对电池规格没有特别要求,仅需设定电池的额定容量和漂移电流。将式(3)离散化可得

$$\begin{aligned} x_k = x_0 - \eta \cdot \sum_{t=0}^k (i_t - i_d - q_k) \cdot \Delta t / Q_n = \\ \left(x_0 - \eta \cdot \sum_{t=0}^{k-1} (i_t - i_d - q_k) \cdot \Delta t / Q_n \right) - \\ \eta \cdot (i_t - i_d - q_k) \cdot \Delta t / Q_n. \end{aligned} \quad (4)$$

将式(4)化简后得到系统状态方程

$$x_k = x_{k-1} - \eta \cdot (i_k - i_d - q_k) \cdot \Delta t / Q_n. \quad (5)$$

Ah 积分法具有简单易行的优势,但由于是开环控制,当存在漂移电流的情况时, Ah 积分法存在累积误差的缺陷。而电池的 SOC 与端电压存在着映射关系,因此,可建立相应的函数关系并以此对 Ah 积分法进行校正。文献[18]提出了组合模型,可以反映电池当前电压与 SOC 间的关系,即

$$\begin{aligned} V(t) = E_0 - R \cdot i(t) - K_0 / \text{SOC}(t) - \\ K_1 \cdot \text{SOC}(t) + K_2 \cdot \ln(\text{SOC}(t)) + \\ K_3 \cdot \ln(1 - \text{SOC}(t)). \end{aligned} \quad (6)$$

其中: $V(t)$ 表示电池 t 时刻端电压, E_0 表示电池初始电动势, R 表示电池内阻, $\text{SOC}(t)$ 表示 t 时刻荷电状态, K_0 、 K_1 、 K_2 、 K_3 为待匹配的模型参数。组合模型解释了电池端电压、SOC、电流之间的关系,可以很好地描述在不同电流下 SOC 与端电压的对应关系。

将式(2)代入该组合模型中,建立修正后的漂移电流组合模型

$$\begin{aligned} V(t) = E_0 - R \cdot (i_D(t) - i_d(t) - q(t)) - \\ K_0 / \text{SOC}(t) - K_1 \cdot \text{SOC}(t) + \\ K_2 \cdot \ln(\text{SOC}(t)) + K_3 \cdot \ln(1 - \text{SOC}(t)). \end{aligned} \quad (7)$$

将式(7)离散化后得到系统观测方程

$$\begin{aligned} y_k = E_0 - R \cdot (i_k - i_d - q_k) - K_1 / x_k - \\ K_2 \cdot x_k + K_3 \cdot \ln(x_k) + K_4 \cdot \ln(1 - x_k). \end{aligned} \quad (8)$$

其中: q_k 表示漂移电流的零均值高斯白噪声, K_0 、 K_1 、 K_2 、 K_3 相关参数可在 Matlab 中由最小二乘法进行辨识。

2 基于CKF的SOC估算

2.1 SOC估算偏差分析

在预测电池 SOC 的过程中, SOC 估算值与实际值间必然存在着一定偏差, 主要原因有以下两点:

1) 漂移电流存在着噪声. 漂移电流值并不始终为定值, 实际使用中同时受电磁、温度等因素干扰, 漂移电流也存在着零均值的高斯白噪声。

2) 对非线性模型的处理方式. 卡尔曼滤波器可以用来解决非线性系统的最优状态估计, 因此, 基于 EKF 和 UKF 估算 SOC 得到了深入研究. 当系统状态突变时, EKF 在处理非线性模型时引入了截断误差, 导致 EKF 的滤波效果下降, 容易失去对突变目标的跟踪能力; UKF 以确定性采样的方式保证了非线性模型的准确性达到三阶, 滤波精度高于 EKF, 但其计算量偏大, 并且没有严格的理论依据, 所以数值有可能不稳定。

显然, 在处理带有漂移电流的电池模型时, 不仅要求滤波器具有较好的稳定性, 更要在降低系统计算量的同时保持滤波精度。

2.2 CKF估算过程

电池的状态空间模型是非线性的, 在处理非线性滤波问题时, 近似非线性函数的概率密度分布要比近似非线性函数更容易^[19]. 针对贝叶斯估计中需要求解非线性函数与高斯概率密度乘积积分的问题, 有学者提出了 CKF(Cubature Kalman filter)^[20]. CKF 原理是采用球面-相径容积规则^[5]近似非线性函数传递的后验均值和协方差, 无需对非线性模型线性化, 采样点的权值永远保持为正, 从而保证了数值稳定性, 其计算量更小、滤波精度高。

由式(5)和(8)可得电池的离散状态空间

$$\begin{cases} x_k = f(i_k, x_{k-1}) + w_k = \\ x_{k-1} - \eta \cdot (i_k - i_d) \cdot \Delta t / Q_n + w_k, \\ y_k = h(i_k, x_k) + v_k = \\ E_0 - R \cdot (i_k - i_d) - K_1 / x_k - K_2 \cdot x_k + \\ K_3 \cdot \ln(x_k) + K_4 \cdot \ln(1 - x_k) + v_k. \end{cases} \quad (9)$$

其中: 电流 i_k 表示系统的输入变量; i_d 表示漂移电流; w_k 是系统噪声; v_k 是量测噪声; 系统噪声和量测噪声为零均值的相互独立的高斯白噪声, 而且均将电流漂移值的噪声 q_k 包含在内. CKF 滤波流程如下。

1) 初始化. 设 $E(x)$ 为随机变量的期望值, 给定初

始值 $\hat{x}_0 = E[x_0]$, 则有

$$P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T]. \quad (10)$$

2) 计算 Cubature 点和权重数

$$\begin{cases} \chi_{k-1}^i = \hat{x}_{k-1} + \sqrt{n P_{k-1}} e_i, & i = 1, 2, \dots, n; \\ \chi_{k-1}^i = \hat{x}_{k-1} - \sqrt{n P_{k-1}} e_i, & i = n+1, n+2, \dots, 2n; \\ w_i = \frac{1}{2n}. \end{cases} \quad (11)$$

其中 e_i 表示第 i 个元素为 1 的单位向量。

3) 预测模块. k 时刻 Cubature 点预测为

$$\begin{cases} \chi_{k|k-1}^i = f(\chi_{k-1}^i), \\ \hat{x}_k^- = \sum_{i=0}^L w_i \chi_{k|k-1}^i, \\ P_{x,k}^- = \sum_{i=0}^L w_i (\chi_{k|k-1}^i - \hat{x}_k^-)(\chi_{k|k-1}^i - \hat{x}_k^-)^T + Q_k. \end{cases} \quad (12)$$

4) 更新模块

$$\begin{cases} \hat{y}_k^- = \sum_{i=0}^{2n} w_i h(\chi_{k|k-1}^i), \\ P_{y,k} = \sum_{i=0}^L w_i [h(\chi_{k|k-1}^i) - \hat{y}_k^-][h(\chi_{k|k-1}^i) - \hat{y}_k^-]^T + Q_k, \\ P_{xy,k} = \sum_{i=0}^L w_i [f(\chi_{k-1}^i) - \hat{x}_k^-][f(\chi_{k-1}^i) - \hat{x}_k^-]^T, \\ K = P_{xy,k} P_{y,k}^{-1}, \\ \hat{x}_k = \hat{x}_k^- + K(y_k - \hat{y}_k^-), \\ P_{x,k} = P_{x,k}^- - K P_{y,k} K^T. \end{cases} \quad (13)$$

CKF 估算 SOC 流程以当前电流作为系统输入量, 将 Drift-Ah 积分法作为系统预测模块, 根据 k 时刻输入电流对当前 SOC 进行一步预测, 以更新模块对 SOC 一步预测值进行修正, 得到 SOC 的最优估计值, 将其作为输出量并反馈给预测模块, 在此基础上对下一阶段的 SOC 继续进行一步预测。

2.3 CKF算法验证分析

任何非线性采样型滤波算法都是由积分公式所得^[21], 积分公式稳定性需同时具备点集位于积分区间和权重为正数这两个条件. 显然, CKF 的点集都位于积分区间. 针对权值为正数这一条件, 定义稳定性

因子

$$I = \sum_i |w_i| / \sum_i w_i, \quad (14)$$

其中 w_i 为点集的权值. 文献[21]将该式作为判断算法数值稳定的标准: I 数值越接近 1, 稳定性越好; 而当 $I > 1$ 时, 积分公式将引入大量的舍入误差, 导致系统发散.

本文中 $w_i = 1/(2n) > 0$, 因而 $|w_i| = w_i$, 所以 CKF 的稳定因子 $I_{\text{CKF}} = 1$, 具有完全的数值稳定性.

作为对比, 在 UKF 算法中由于 $n + \kappa = 3$, 当 $n > 3$ 时, 参数 $\kappa < 0$, 因而权值

$$w_0 = \frac{\kappa}{\kappa + n} = 1 - \frac{n}{3} < 0. \quad (15)$$

于是 UKF 的稳定因子 I_{UKF} 可表示为

$$I_{\text{UKF}} = \frac{\sum_i |w_i|}{\sum_i w_i} = |w_0| + \sum_{i=1}^{2n} w_i = \frac{2n}{3} - 1 > 1. \quad (16)$$

由式(16)可知, 稳定因子随着 n 呈线性增长, 导致 UKF 积分公式计算精度变差.

针对采样型卡尔曼滤波器的收敛条件, 文献[22-23]给出了误差有界的充分条件. CKF 和 UKF 采用相同的滤波框架, 故收敛性结论也可扩展到证明 CKF.

CKF 收敛性证明 定义状态向量的估计误差 e_{x_k} 和预测误差 $e_{x_{k|k-1}}$ 分别为

$$\begin{cases} e_{x_k} = x_k - \hat{x}_k, \\ e_{x_{k|k-1}} = x_k - \hat{x}_{k|k-1}. \end{cases} \quad (17)$$

为保证 CKF 收敛, 即 e_{x_k} 和 $e_{x_{k|k-1}}$ 均收敛到 0, 将式(9)第 1 步和式(12)第 2 步在 $\hat{x}_{k-1}$ 处进行泰勒式展开, 有

$$x_k = f(\hat{x}_{k-1}) + f'(\hat{x}_{k-1})e_{x_{k-1}} + \frac{1}{2}f''(\hat{x}_k)e_{x_{k-1}}^2 + \cdots, \quad (18)$$

$$\hat{x}_{k|k-1} = f(\hat{x}_{k-1}) + \frac{1}{2}f''(\hat{x}_{k-1})P_{k-1} + \cdots. \quad (19)$$

将式(18)和(19)代入(17)第 2 步, 基于式(17)第 1 步, 可得预测误差的近似值为

$$e_{x_{k|k-1}} = F_k e_{x_{k-1}}, \quad (20)$$

其中 $F_k = f'(\hat{x}_{k-1})$ 为非奇异矩阵. 因式(20)采用一阶泰勒式近似, 预测误差存在着残差, 故式(20)可准确表示为

$$e_{x_{k|k-1}} = A_k F_k e_{x_{k-1}}, \quad (21)$$

其中 $A_k = \text{diag}([a_{1,k}, a_{2,k}, \cdots, a_{n,k}])$ 表示与残差相关的未知矩阵, 近似为单位矩阵. 若 F_k 为非奇异矩阵, 且矩阵 A 满足下列条件^[8]:

$$\lambda(A_k) \leq \frac{1}{1+c} \left[\frac{\lambda_{\min}(F_k^{-T} F_k^{-1})}{\lambda_{\max}(T_k)} \right]^{\frac{1}{2}}, \quad (22)$$

$$T_k = [I - P_{xy,k|k-1} P_{y,k|k-1}^{-1} B_k H_k]^T \times [I - P_{xy,k|k-1} P_{y,k|k-1}^{-1} B_k H_k]. \quad (23)$$

其中: 常数 $c > 0$, $\lambda_{\max}$ 和 $\lambda_{\min}$ 分别表示矩阵特征最大值和最小值, $B_k = \text{diag}([b_{1,k}, b_{2,k}, \cdots, b_{n,k}])$. 则估计误差 e_{x_k} 收敛到 0, 即

$$\lim_{k \rightarrow \infty} e_{x_k} = 0. \quad (24)$$

式(9)第 1 步 SOC 状态方程 $f(\cdot)$ 为取值 $[0, 1]$ 的有界函数, 受电池倍率性能及实际工况限制, SOC 变化率 F_k 也为有界函数, 则有

$$\lim_{k \rightarrow \infty} e_{x_{k|k-1}} = \lim_{k \rightarrow \infty} F_k e_{x_{k-1}} = 0. \quad (25)$$

从而, CKF 收敛性得证. $\square$


由此得知 CKF 算法在随机系统中受参数影响较少, 在数值稳定性上有明显优势. 对于本次使用的电池模型, CKF 算法能保持一定条件下的收敛性, 在工程上具有实用意义.

3 实验结果与分析


为检验基于 Drift-Ah 积分法 CKF 估算 SOC 的优越性, 选用天津力神公司生产的钛酸锂电池作为实验对象. 该电池额定容量 16 Ah, 充电截止电压 2.7 V, 放电截止电压 1.5 V, 放电倍率可达 10 C 以上.

漂移电流大小受传感器测量范围和测量精度的影响, 本次实验中所使用的外部传感器测量范围为 0~100 A, 精度为 0.2%, 因此, 存在着范围为 -0.2~0.2 A 的漂移电流.

目前, 主流充电模式有恒流恒压模式、恒功率模



(a) SOC 变化曲线



(b) SOC 估算误差

图 1 充电时存在漂移电流的估算结果

式、截止电压模式等。本次实验采用最常用的恒流恒压充电模式,将完全放电的电池在 $20^{\circ}\text{C} \pm 2^{\circ}\text{C}$ 的温度下先以恒流 $1/2\text{C}(8\text{A})$ 充至截止电压,随后转为恒压充电直至实际 $\text{SOC} = 100\%$ 。充电时存在漂移电流干扰,CKF的估算结果如图1所示。

充电时含有一定量的漂移电流,CKF和UKF算法的SOC估计误差都较小,充电末期误差大约为 0.75% 。EKF方法估计误差为 2.11% ,这是由于它对漂移电流的抑制能力有限,导致估计误差相对较大。

建立Drift-Ah积分法后的估算结果如图2所示。




图2 充电时抑制漂移电流的估算结果

加入Drift-Ah积分法后,估测结果更接近于真实SOC,其中EKF最大误差降到 0.80% ,UKF和CKF最大误差分别只有 0.51% 和 0.49% ,3种算法的精确度均有了一定提升,估计误差围绕 0% 有轻微波动。仿真结果表明,Drift-Ah积分法降低了漂移电流的干扰,从而得到更为精确的荷电状态。

参照《电动汽车用锂离子蓄电池》(QC/T743-2006)^[24]提供的电池模拟工况试验步骤,将电池在 $20^{\circ}\text{C} \pm 2^{\circ}\text{C}$ 的环境中进行放电试验,放电直至 $\text{SOC} = 10\%$,图3是实际放电电流。




图3 实际放电电流

在忽视漂移电流影响的情况下以CKF估算电池SOC,图4是3种算法的估算结果。




图4 放电时存在漂移电流的估算结果

由图4可以看出,在有漂移电流干扰的情况下,3种非线性卡尔曼滤波器均能起到估算作用,截至放电结束时,估计误差均有不同的发散趋势,其中EKF和UKF最大误差明显超过CKF,而EKF的最大误差达到了 4.83% 。表1是3种算法的估算结果。

表1 存在漂移电流的估算结果 %		
估计方法	最大误差	平均误差
EKF估计	4.83	1.73
UKF估计	4.17	1.01
CKF估计	1.71	0.76




图5 放电时抑制漂移电流的估算结果

用 Drift-Ah 积分法抑制漂移电流后,3 种算法估算结果如图 5 所示. 由图 5 可以看出,考虑到漂移电流后,EKF、UKF、CKF 能更好地跟踪 SOC 的变化,整体误差围绕 0 % 上下波动,EKF 的波动幅度相对较大,其中 CKF 的估算精度最高,最大误差由 1.71 % 降到了 0.47 %,平均误差由 0.76 % 降到了 0.20 %.

目前,一些文献采用不同的方案取得了较好的估算结果,这种比较是在不同的电池模型假设和工作环境下实现的. 表 2 是相关文献的结果与本文方案的对比结果.

表2 SOC 估计算法对比 %

估计方法	最大误差	平均误差
EKF(本文)	3.33	0.92
UKF(本文)	1.48	0.36
CKF(本文)	0.47	0.20
Neural network ^[4]	3.475	
Adaptive EKF ^[12]	2	
Dual-scale estimator ^[12]	1	
H_{∞} switched observer ^[12]	1.49	
H_{∞} nonswitched observer ^[12]	11.31	
贝叶斯正则化-BP 神经网络 ^[6]	< 1.5	
Discrete-time nonlinear observer ^[25]	2.98	
Dynamically driven recurrent network ^[26]	< 2	
Gaussian mixture regression ^[11]	1.61	

在用 Drift-Ah 积分法抑制漂移电流干扰后,对比近年的多种估计算法,CKF 算法在估计精度上同样具有优势.

根据已发表文献中提供的计算复杂度,多种 SOC 估计算法执行时间如表 3 所示.

表3 SOC 算法执行时间对比 s

估计方法	执行时间
EKF(本文)	0.318 7
UKF(本文)	0.956 2
CKF(本文)	0.333 6
Gaussian mixture regression ^[11]	1.15
H_{∞} switched observer ^[12]	0.90
H_{∞} nonswitched observer ^[12]	0.55
Improved BP neural network ^[27]	3
Dynamically driven recurrent network ^[26]	25

由表 3 可见:CKF 和 EKF 的计算量最低,这是因为 CKF 权值为一常数且不需要重新计算权重,采样点少于 UKF,因而系统复杂度低于 UKF;神经网络算法虽然通过改进结构和增加样本数量可以提高估算精度,但系统计算量过大;此外,电池在汽车上实际放电工况远比实验室复杂,为保证 SOC 估算精度,神经网络法还需进一步增加样本数量,因此实际价值较低;Gaussian mixture regression 和 Dynamically driven

recurrent network 虽然取得了较为准确的估算结果,但其较大的计算量显然不利于工程应用. 因而考虑计算成本等因素,可采用 Drift-Ah 积分法抑制漂移电流的干扰,再以 CKF 算法实现精确估算.

4 结 论

本文通过分析漂移电流的干扰,对 Ah 积分法加以改进,并以 CKF 对 SOC 进行了估算. 主要做了如下工作:

1) 将漂移电流加入到 Ah 积分法与组合模型中,由此提出的 Drift-Ah 积分法简单易行,具有实际应用价值,为降低漂移电流的干扰提供了新的解决方案.

2) CKF 在处理强非线性系统时能有效保持数值稳定性,提高滤波精度,本文对 CKF 的稳定性和收敛性做了一定深度的分析,证明了 CKF 算法的可靠性.

3) 加入 Drift-Ah 积分法后,充电时 CKF 估计误差由 0.75 % 降到 0.49 %,模拟工况放电时的最大误差由 1.71 % 降到 0.47 %,不仅低于 EKF 和 UKF 的估计误差,也优于当前已有的算法.

4) 对比 UKF 算法、 H_{∞} switched observer、BP neural network 等方法,本文基于 Drift-Ah 积分法的 CKF 估算 SOC 方案有着更低的系统计算量,适用于工程应用.

5) 当前对于非线性卡尔曼滤波器的收敛性证明较为保守、方法复杂且有限制条件,因此,有必要展开针对非线性卡尔曼滤波器的相关研究.

参考文献(References)

[1] 刘胜永,于跃,罗文广,等. 基于自适应无迹卡尔曼滤波的锂电池 SOC 估计[J]. 控制工程, 2017, 24(8): 1611-1616.
(Liu S Y, Yu Y, Luo W G, et al. Estimation of state of charge for lithium battery based on adaptive unscented Kalman filter[J]. Control Engineering of China, 2017, 24(8): 1611-1616.)

[2] 刘红锐,张昭怀. 锂离子电池组充放电均衡器及均衡策略[J]. 电工技术学报, 2015, 30(8): 186-192.
(Liu H R, Zhang Z H. The equalizer of charging and discharging and the banlancing strategies for lithium-ion battery pack[J]. Trans of China Electrotechnical Society, 2015, 30(8): 186-192.)

[3] Nejad S, Gladwin D T, Stone D A. A systematic review of lumped-parameter equivalent circuit models for real-time estimation of lithium-ion battery states[J]. J of Power Sources, 2016, 316: 183-196.

[4] Yan Qiyan, Wang Yanning. Predicting for power battery SOC based on neural network[C]. The 36th Chinese Control Conf. Dalian, 2017: 4140-4143.

[5] 袁学庆,张阳,赵林,等. 基于 EKF 的锂电池 SOC 估算与试验研究[J]. 电源技术, 2015, 139(12): 2587-2589.

- (Yuan X Q, Zhang Y, Zhao L, et al. Li-ion battery SOC estimation and test research based on EKF[J]. Power Technology, 2015, 139(12): 2587-2589.)
- [6] 杨春生, 牛红涛, 隋良红, 等. 基于贝叶斯正则化算法BP神经网络锂电池SOC预测[J]. 现代电子技术, 2016, 39(8): 158-161.
(Yang C S, Niu H T, Sui L H, et al. Application of BP neural network improved by Bayesian regularization algorithm in VRB SOC prediction[J]. Modern Electronics Technique, 2016, 39(8): 158-161.)
- [7] 刘征宇, 杨俊斌, 张庆, 等. 基于QPSO-BP神经网络的锂电池SOC预测[J]. 电子测量与仪器学报, 2013, 27(3): 224-228.
(Liu Z Y, Yang J B, Zhang Q, et al. Estimation for SOC of lithium battery based on QPSO-BP neural network[J]. J of Electronic Measurement and Instrument, 2013, 27(3): 224-228.)
- [8] 王世元, 黄锦旺, 谢智刚, 等. 非线性卡尔曼滤波器原理及应用[M]. 北京: 电子工业出版社, 2015: 22-25, 64-66.
(Wang S Y, Huang J W, Xie Z G, et al. Principles of nonlinear Kalman filters and their applications[M]. Beijing: Publishing House of Electronics Industry, 2015: 22-25, 64-66.)
- [9] Tian Y, Xia B, Sun W, et al. A modified model based state of charge estimation of power lithium-ion batteries using unscented Kalman filter[J]. J of Power Sources, 2014, 270: 619-626.
- [10] 孔祥创, 赵万忠, 王春燕. 基于BP-EKF算法的锂电池SOC联合估计[J]. 汽车工程, 2017, 39(6): 648-652.
(Kong X C, Zhao W Z, Wang C Y. Co-estimation of lithium battery SOC based on BP-EKF algorithm[J]. Automotive Engineering, 2017, 39(6): 648-652.)
- [11] Sheng Hanmin, Xiao Jian, Wang Peng. Lithium iron phosphate battery electric vehicle state-of-charge estimation based on evolutionary gaussian mixture regression[J]. IEEE Trans on Industrial Electronics, 2017, 64(1): 544-551.)
- [12] Liu Cong-zhi, Zhu Qiao, Li Liang, et al. A state of charge estimation method based on H_∞ observer for switched systems of lithium-ion nickel-manganese-cobalt batteries[J]. IEEE Trans on Industrial Electronics, 2017, 64(10): 8128-8137.
- [13] He Ting, Li Donghai, Wu Zhenlong, et al. A modified luenberger observer for SOC estimation of lithium-ion battery[C]. The 36th Chinese Control Conf. Dalian, 2017: 927-928.
- [14] 何晓兰. 开环霍尔直流电流传感器及其校正方法设计[D]. 北京: 中国科学院大学工程科学学院, 2015.
(He X L. Open loop hall effect DC current sensor design and calibration[D]. Beijing: College of Engineering Sciences, University of Chinese Academy of Sciences, 2015.)
- [15] 郑岳久, 许霜霜, 张振东. 三元锂电池荷电状态估计的传感器误差影响[J]. 汽车安全与节能学报, 2017, 8(2): 198-204.
- (Zheng Y J, Xu S S, Zhang Z D. Effect of sensor errors on state of charge estimation for ternary lithiumion cells[J]. J of Automotive Safety and Energy, 2017, 8(2): 198-204.)
- [16] 刘新天, 刘兴涛, 何耀, 等. 基于Vmin-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 Vmin-EKF SOC estimation for power li-ion battery pack[J]. Control and Decision, 2010, 25(3): 445-448.)
- [17] Li J H, Barillas J K, Guenther C, et al. A comparative study of state of charge estimation algorithms for LiFePO₄ batteries used in electric vehicles[J]. J of Power Sources, 2013, 230(10): 244-250.
- [18] Plett G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery pack[J]. J of Power Sources, 2004, 134(2): 277-292.
- [19] 王小旭, 潘泉, 黄鹤, 等. 非线性系统确定采样型滤波算法综述[J]. 控制与决策, 2012, 27(6): 801-812.
(Wang X X, Pan Q, Huang H, et al. Overview of deterministic sampling filtering algorithms for nonlinear system[J]. Control and Decision, 2012, 27(6): 801-812.)
- [20] Arasaratnam I, Haykin S. Cubature Kalman filtering[J]. IEEE Trans on Automatic Control, 2009, 54(6): 1254-1269.
- [21] 丁国强. 非线性系统建模与滤波方法[M]. 北京: 北京航空航天大学出版社, 2017: 150-153.
(Ding G Q. Modeling and filtering methods for nonlinear system[M]. Beijing: Beihang University Press, 2017: 150-153.)
- [22] Xiong K, Zhang H Y, Chan C W. Performance evaluation of UKF-based nonlinear filtering[J]. Automatica, 2006, 42(2): 261-270.
- [23] Xiong K, Zhang H Y, Chan C W. Author's reply to "Comments on 'Performance evaluation of UKF-based nonlinear filtering'" [J]. Automatica, 2007, 43(3): 569-570.
- [24] QC/T 743-2006, 电动汽车用锂离子蓄电池[S]. QC/T 743-2006, Lithium-ion batteries for electric vehicles[S].
- [25] Li W L, Liang L, Liu W J, et al. State of charge estimation of lithium-ion batteries using a discrete-time nonlinear observer[J]. IEEE Trans on Industrial Electronics, 2017, 64(11): 8557-8565.
- [26] Chaoui H, Ibe-Ekeocha C C. State of charge and state of health estimation for lithium batteries using recurrent neural networks[J]. IEEE Trans on Vehicular Technology, 2017, 66(10): 8773-8783.
- [27] Guo Yifeng, Zhao Zeshuang, Huang Limin. SoC estimation of lithium battery based on improved BP neural network[C]. The 8th Int Conf on Applied Engery. Beijing, 2017: 4153-4158.
- [28] Wang Baojin, Liu Zhiyuan, Shengbo Eben Li, et al. State-of-charge estimation for lithium-ion batteries based on a nonlinear fractional model[J]. IEEE Trans on Control System Technology, 2017, 25(1): 3-11.