

DOI: 10.19783/j.cnki.pspc.240296

基于改进自适应卡尔曼滤波算法的锂离子电池荷电状态估计

宋海飞, 王乐红, 原义栋, 赵天挺, 陈捷

(北京智芯微电子科技有限公司, 北京 102299)

摘要: 针对锂离子电池荷电状态(state of charge, SOC)估计过程中传统卡尔曼滤波算法噪声特性难以确定、收敛速度慢及精度差等一系列问题, 提出了一种改进自适应卡尔曼滤波算法。首先, 建立了电池等效电路模型, 并在不同温度和SOC状态下, 对模型参数进行了辨识和精度验证。然后, 对传统自适应卡尔曼滤波算法系统过程噪声协方差矩阵计算方式进行了正定性优化。此外, 在状态估计结果的修正过程中, 引入了对模型等误差变化进行补偿的增益因子。最后, 通过实验电池的仿真和测试验证了所提算法的有效性。结果表明, 在不同温度和工况条件下, SOC的估计误差均在4%以内, 改进自适应卡尔曼滤波算法的估计精度和收敛速度均优于改进前的算法和常用的扩展卡尔曼滤波(extended kalman filter, EKF)算法, 具有较强的实用性。

关键词: 锂离子电池; 荷电状态; 卡尔曼滤波算法; 增益因子; 实用性

State of charge estimation of lithium-ion batteries based on improved adaptive Kalman filter algorithm

SONG Haifei, WANG Lehong, YUAN Yidong, ZHAO Tianting, CHEN Jie

(Beijing Smartchip Microelectronics Technology Company Limited, Beijing 102299, China)

Abstract: An improved adaptive Kalman filter algorithm is proposed to tackle a series of issues in estimating the state of charge (SOC) for lithium-ion batteries, including the uncertainty of noise characteristics, sluggish convergence, and poor accuracy in traditional Kalman filter methods. First, an equivalent circuit model of batteries is established, with the model parameters identified and accuracy verified across various temperature and SOC states. Subsequently, positive definiteness optimization is conducted on the calculation method of the covariance matrix for process noise in the traditional adaptive Kalman filter algorithm. In addition, a gain factor is introduced to compensate for the change of model error in correcting the state estimation results. Finally, the effectiveness of the proposed algorithm is verified through simulation and testing of experimental batteries. The results indicate that the SOC estimation error is within 4% in different temperature and operating conditions. Compared with the algorithm before improvement and common extended Kalman filter (EKF) algorithm, the improved adaptive Kalman filter algorithm shows better estimation accuracy and convergence speed with relatively strong applicability.

This work is supported by the National Key Research and Development Program of China (No. 2021YFB3201305).

Key words: lithium-ion batteries; state of charge; Kalman filter algorithm; gain factor; applicability

0 引言

由于太阳能和风能等均是间歇性能源, 其资源的分布具有不确定性和不稳定性, 这些新型能源并不方便直接被使用, 需要配备储能系统才能对其进行合理分配、管理和高效利用^[1-4]。以锂离子电池为能源载体的新型储能技术成为近几年发展最为迅猛的储能方式之一, 其装机量占有新型储能技术装

机总量的90%以上^[5]。此外, 由于锂离子电池的性能优势和成本优势, 其目前仍是新能源汽车主要的动力输出载体^[6-7]。

随着储能和新能源汽车行业对锂离子电池需求量的不断攀升, 锂离子电池的安全问题变得越来越突出^[8-10]。近几年由于锂离子电池起火、爆炸等导致的储能系统和电动汽车安全事故时有发生, 而这些事故大部分都与电池的过充、过放等因素有关^[11]。因此对锂离子电池荷电状态(state of charge, SOC)进行准确的在线估计与监测, 对于电池安全管

基金项目: 国家重点研发计划项目资助(2021YFB3201305)

理至关重要。

锂离子电池的 SOC 估计是电池管理的重点, 同时也是目前行业的难点^[12]。由于卡尔曼滤波算法可以从带有噪声的输入信号中依据测量值对未知的状态参数进行不断地估计和修正, 并将噪声进行量化处理和计算, 是目前较常用的 SOC 估计算法。

文献[13]结合扩展卡尔曼滤波(extended kalman filter, EKF), 提出了应用于电池管理系统的 SOC 估计方法; 文献[14]提出了一种安时积分法和 EKF 算法相结合的电池 SOC 估计方法; 文献[15]提出了一种基于观测方程重组的增强型扩展卡尔曼滤波算法对电池 SOC 进行估计; 文献[16]提出了一种基于二阶近似 EKF 算法来估计电池 SOC; 文献[17]提出了一种联合 EKF 与无迹卡尔曼滤波(unscented kalman filter, UKF)的算法, 在不同的阶段分别采用 EKF 算法和 UKF 算法来估计 SOC; 文献[18]提出了一种基于双 EKF 的电池 SOC 估算方法。

虽然这些方法能够实现电池 SOC 的在线估计, 但是 EKF 算法对噪声的处理较为理想化, 当噪声已知且为理想的高斯白噪声时其效果较好。而在实际 SOC 估计过程中, 噪声特性不容易确定, 且系统状态也是时刻变化的, 对于噪声统计特性未知的情况, EKF 的精度和鲁棒性较差^[19]。

Sage-Husa 自适应卡尔曼滤波(后文简称自适应卡尔曼滤波)是一种基于极大后验估计的算法^[20], 其原理较为简单, 理论上在实现对系统状态进行估计的同时, 还能够根据测量值对噪声统计特性进行自适应地调整, 减小对不确定噪声的依赖。但是其在实际应用中存在以下问题。

1) 相关研究表明, 在系统过程噪声和量测噪声统计特性均未知的情况下, 系统过程噪声协方差矩阵和量测噪声协方差矩阵不能很好地被自适应卡尔曼滤波算法精确分离, 难以同时动态更新^[21-22]。

2) 随着迭代次数的增加, 自适应卡尔曼滤波算法容易出现噪声协方差矩阵非正定的情况, 导致滤波结果发散^[22]。

3) 在模型初始值不准确的情况下, 算法收敛速度慢, 计算结果容易波动, 甚至会出现滤波异常^[23]; 此外, 目前通过等效电路模型对电池 SOC 进行估计时, 很少会同时考虑 SOC 和温度对模型参数的影响^[24]。

为了解决以上问题, 本文对传统自适应卡尔曼滤波算法模型进行了改进。首先, 在模型参数辨识过程中, 同时考虑了 SOC 和温度对模型参数的影响; 然后, 对自适应算法系统噪声协方差矩阵估计过程进行了优化, 使得噪声协方差矩阵能够保持正

定性, 防止滤波发散, 且能简化计算过程; 最后, 在对系统状态变量进行最优估计修正过程中, 引入了增益因子, 增益因子会随着模型等误差变化调节修正值和先验估计值的权重, 提高自适应算法的实用性。

基于以上分析, 为了验证所提出的改进自适应卡尔曼滤波算法在电池 SOC 估算过程中的效果, 本文以磷酸铁锂电池为研究对象, 建立了电池等效电路模型, 并在不同温度和 SOC 条件下对模型参数进行了辨识和验证。基于以上改进的自适应卡尔曼滤波算法在不同工况条件下对电池 SOC 进行估计, 同时与改进前算法和 EKF 算法估算结果进行对比, 分析所提出的改进算法在 SOC 估算过程中的估算精度和收敛性。

1 锂离子电池建模及参数辨识

1.1 锂离子电池建模

等效电路模型使用电阻、电容等电学元器件能够较好地模拟电池电压的外在特性, 且参数能够通过实验辨识得到。这里考虑到模型精度与计算复杂度之间的平衡关系, 选取二阶 RC 等效电路模型作为此次电池 SOC 估计的模型, 如图 1 所示。

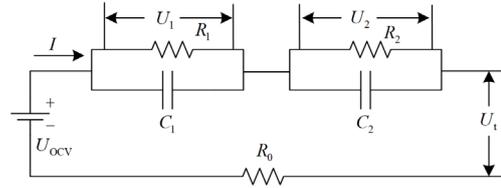


图 1 二阶 RC 等效电路模型

Fig. 1 Second-order RC equivalent circuit model

与此同时, 本文同时考虑了电池温度和 SOC 对模型参数的影响。RC 结构可以用来模拟电池电压的弛豫过程, 这里将电池的极化过程进行了区分。

根据图 1 的等效电路模型, 列出电池系统离散化的状态方程及 SOC 递推计算公式。

$$U_1(k) = \exp\left(\frac{-T_s}{R_1 \times C_1}\right) \times U_1(k-1) + R_1 \times \left[1 - \exp\left(\frac{-T_s}{R_1 \times C_1}\right)\right] \times I(k-1) \quad (1)$$

$$U_2(k) = \exp\left(\frac{-T_s}{R_2 \times C_2}\right) \times U_2(k-1) + R_2 \times \left[1 - \exp\left(\frac{-T_s}{R_2 \times C_2}\right)\right] \times I(k-1) \quad (2)$$

$$U_t(k) = U_{ocv}(k) - U_1(k) - U_2(k) - R_0 \times I(k) \quad (3)$$

$$S_{oc}(k) = S_{oc}(k-1) - \frac{T_s \times I(k)}{C_a} \times 100\% \quad (4)$$

式中： $U_1(k)$ 为 k 时刻的电化学极化电压； T_s 为采样时间； R_1 为电化学极化电阻； C_1 为电化学极化电容； $U_1(k-1)$ 为 $k-1$ 时刻的电化学极化电压； $I(k-1)$ 为 $k-1$ 时刻的电流； $U_2(k)$ 为 k 时刻浓差极化电压； R_2 为浓差极化电阻； C_2 为浓差极化电容； $U_2(k-1)$ 为 $k-1$ 时刻的浓差极化电压； $U_1(k)$ 为 k 时刻电池输出的端电压； $U_{ocv}(k)$ 为 k 时刻电池的开路电压； R_0 为欧姆内阻； $I(k)$ 为 k 时刻的电流； $S_{oc}(k)$ 为 k 时刻电池荷电状态量； $S_{oc}(k-1)$ 为 $k-1$ 时刻电池荷电状态量； C_a 为电池容量。

1.2 模型参数辨识

本文的实验平台如下：①磷酸铁锂电池，其基本信息如表 1 所示；②高低温电池防爆箱(ECT-112TR-40-CP-SD)，主要是给实验电池提供不同的温度环境，同时还起到防爆作用；③电芯充放电测试系统(JHAI-C)，主要是对实验电池进行充放电测试；④电池测试控制上位机，主要是对电池充放电过程进行控制，同时记录电池测试数据。平台架构如图 2 所示。

表 1 实验电池信息

Table 1 Experimental batteries information

工作电压/V	最大放电流	最大充电电流	额定容量/Ah
2.6~3.65	6 C (1 C=26 A)	1 C(15~60 °C)	26
		0.5 C(10~15 °C)	
		0.2 C(5~10 °C)	
		0.1 C(0~5 °C)	
		0.02 C(-10~0 °C)	

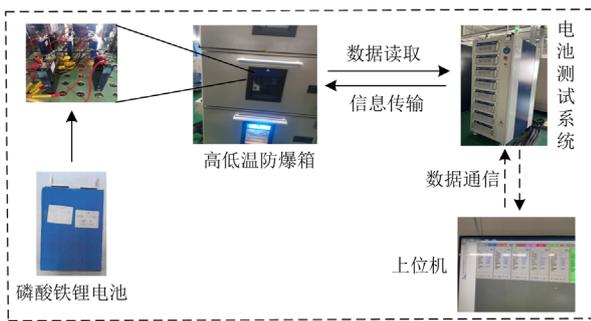


图 2 实验平台架构

Fig. 2 Architecture of experimental platform

首先，对磷酸铁锂电池进行充放电测试，得到电池在不同温度条件下的实际容量。测试得到的不同温度条件下的电池容量如图 3 所示。

再将测试温度与电池实际容量数据进行拟合，得到电池容量与温度之间的函数关系 C_a 。

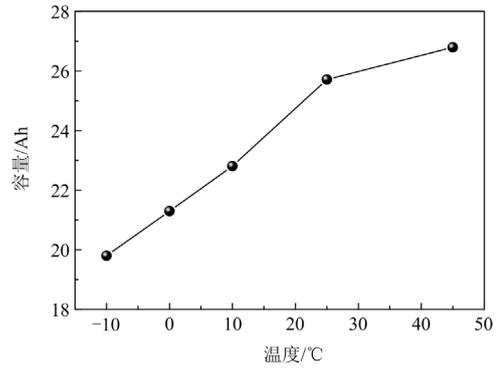


图 3 实验电池在不同温度条件下的实际容量

Fig. 3 Actual capacity of experimental batteries under different temperature conditions

$$C_a = -7.501 \times 10^{-5} \times T^3 + 2.531 \times 10^{-3} \times T^2 + 0.1636 \times T + 21.15 \quad (5)$$

式中， T 为电池温度。

电池的 SOC 与开路电压的关系是电池状态计算过程中需要用到的重要参数信息，不同温度条件下电池的 SOC 与开路电压的关系也会有所不同。因此，本文在进行 SOC 与开路电压关系测试时，设置了-10 °C、0 °C、25 °C、45 °C 不同温度条件。不同温度条件下的测试结果如图 4 所示。

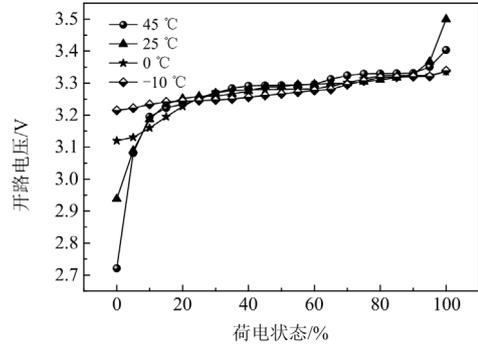


图 4 电池 SOC 与开路电压关系图

Fig. 4 Diagram of the relationship between SOC and open circuit voltage

将 U_{ocv} 作为因变量，将 T 和 S_{oc} 作为自变量，进行多元函数拟合，得到如式(6)所示的关系。

$$U_{ocv} = 3.12 - 0.005614 \times T + 1.448 \times S_{oc} + 0.04657 \times T \times S_{oc} - 6.348 \times S_{oc}^2 - 0.1175 \times T \times S_{oc}^2 + 13.55 \times S_{oc}^3 + 0.1163 \times T \times S_{oc}^3 - 13.22 \times S_{oc}^4 - 0.03854 \times T \times S_{oc}^4 + 4.802 \times S_{oc}^5 \quad (6)$$

为了对电池等效电路模型的容阻参数进行辨识，需要对实验电池进行脉冲充放电测试，然后对

输出的电压和电流数据进行处理, 利用最小二乘法辨识得到电池的容阻参数。对电池进行脉冲放电测试过程中, 电池的瞬时压降和压升主要是由欧姆极化引起的, 且由于脉冲时间很短, 故脉冲放电开始时的瞬时压降和结束时产生的瞬时压升相差不大。在计算中, 为减小误差, 取同一 SOC 点的压升和压降的平均值, 然后除以脉冲电流 I 得到电池欧姆内阻 R_0 。

$$R_0 = \frac{\Delta U_p + \Delta U_d}{2I} \quad (7)$$

式中: ΔU_p 为压升; ΔU_d 为压降。

在脉冲放电阶段和静置过程中, 受电池内部极化的影响, 电压在瞬时变化之后有一个缓慢的变化过程, 可以根据电池模型的状态方程, 并通过最小二乘非线性拟合的方式计算出模型参数。在放电之后的静置过程中, RC 电路在这个过程中为零输入响应, 电池系统的输出方程为

$$U_t = U_{ocv} - U_1 \times \exp\left(\frac{-t}{\tau_1}\right) - U_2 \times \exp\left(\frac{-t}{\tau_2}\right) \quad (8)$$

式中: t 为时间; $\tau_1 = R_1 \times C_1$; $\tau_2 = R_2 \times C_2$ 。将该过程中电压随时间的变化曲线按照式(9)的指数公式进行拟合。

$$U_t = a - b \times \exp\left(\frac{-t}{c}\right) - d \times \exp\left(\frac{-t}{m}\right) \quad (9)$$

式中, a 、 b 、 c 、 d 、 m 均为待拟合辨识参数。经过拟合之后即可得到这些参数的取值, 再根据其式(8)中的参数对应关系: $c = \tau_1$, $m = \tau_2$ 就可以得到此时 τ_1 和 τ_2 的值。

在电池放电电压缓慢变化的阶段, RC 电路在这个过程中为零状态响应, 电池系统输出方程为

$$U_t = U_{ocv} - I \times \left\{ R_1 \times \left[1 - \exp\left(\frac{-t}{\tau_1}\right) \right] + R_2 \times \left[1 - \exp\left(\frac{-t}{\tau_2}\right) \right] \right\} - I \times R_0 \quad (10)$$

将计算出的 R_0 、 τ_1 和 τ_2 的值代入式(10), 再将该阶段电池端电压 U_t 随时间的响应曲线按照式(11)进行拟合。

$$U_t = n - I \times \left\{ o \times \left[1 - \exp\left(\frac{-t}{\tau_1}\right) \right] + j \times \left[1 - \exp\left(\frac{-t}{\tau_2}\right) \right] \right\} - I \times R_0 \quad (11)$$

式中, n 、 o 、 j 均为待拟合辨识参数。拟合之后

即可得到这些参数的取值, 根据式(10)可知, 参数 $o = R_1$, $j = R_2$, 再根据 τ_1 、 τ_2 的值就可以得到模型参数 R_1 、 R_2 、 C_1 、 C_2 的值。

通过在不同 SOC 和温度条件下进行脉冲充放电测试, 可以辨识得到电池模型在不同 SOC 和温度条件下的容阻参数, 其中欧姆内阻的变化情况如图 5 所示。

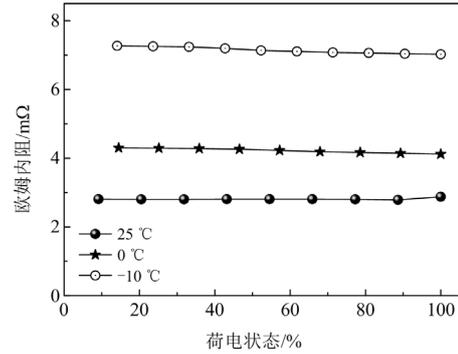


图 5 不同温度和 SOC 条件下模型欧姆内阻

Fig. 5 Ohmic internal resistance of the model under different temperature and SOC conditions

由图 5 可以看出, 电池模型的欧姆内阻参数会随着电池温度和 SOC 的变化而变化。因此, 在对电池模型进行参数辨识时需要同时考虑 SOC 和温度对模型参数的影响。

将 R_0 作为因变量、 S_{oc} 和 T 作为自变量进行多元函数拟合, 得到如式(12)所示的关系。

$$R_0 = 4.351 - 0.2307 \times T - 0.2625 \times S_{oc} + 0.006751 \times T^2 + 0.01007 \times T \times S_{oc} + 0.0405 \times S_{oc}^2 \quad (12)$$

除了欧姆内阻外, 模型的其他容阻参数很难直接进行多元函数拟合, 因此在模型计算过程中这些参数可通过查表来获取。

为了验证模型精度, 本文分别对实验电池在 25 °C、-10 °C 温度条件下进行测试。将测试得到的电池端电压与相同工况下模型仿真输出得到的端电压进行比较, 并将同一时刻实际测试的电池端电压减去模型输出的端电压, 得到模型的电压误差, 具体结果如图 6 所示。

由图 6 可以看出, 25 °C 条件下模型的电压误差在 ± 7 mV 以内; -10 °C 条件下模型的电压误差在 ± 1 mV 以内。为了更加准确地描述模型的误差情况, 分别对不同温度条件下电压误差绝对值的平均值进行了计算。经过计算得出, 25 °C 条件下的电压误差绝对值的平均值为 0.24 mV; -10 °C 条件下的电压误

差绝对值的平均值仅为 0.06 mV，表明该模型具有较好的精度，能够很好地模拟电池的端电压特性。

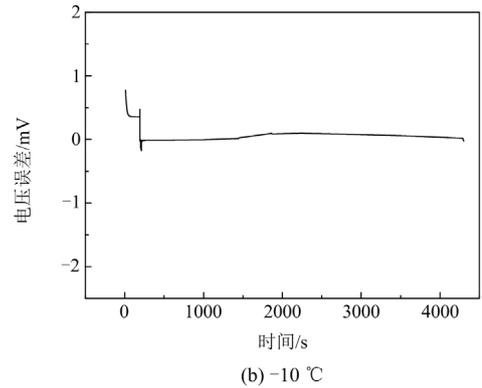
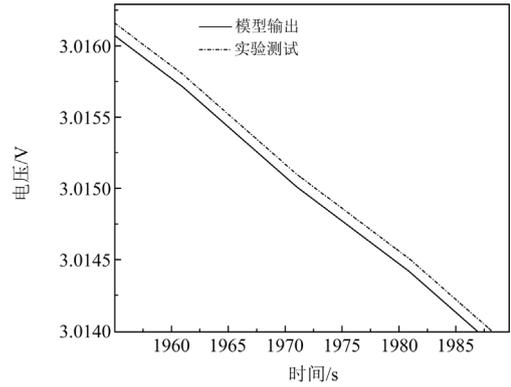
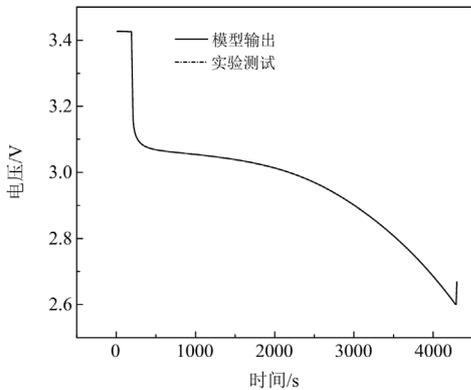
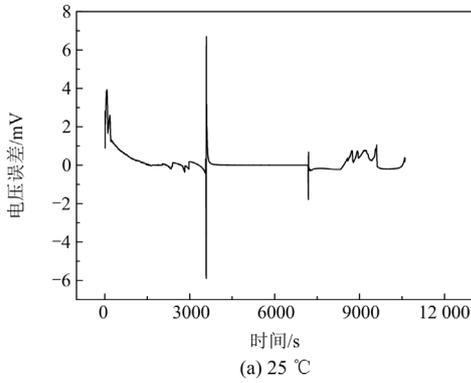
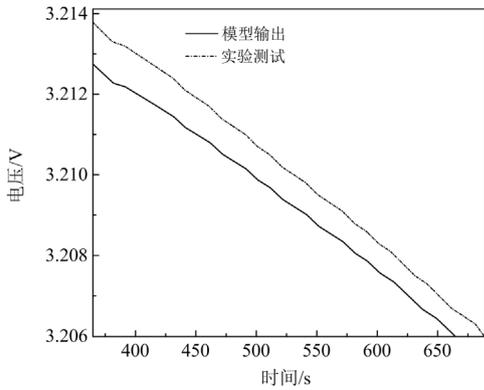
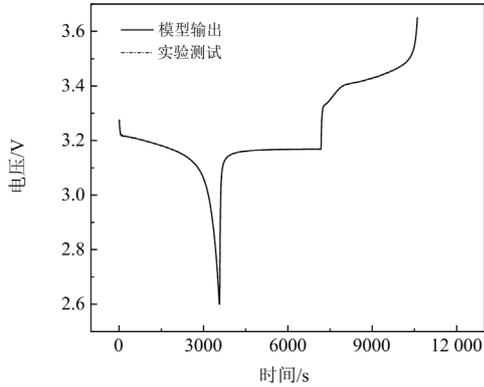


图 6 电池模型仿真与电池实测端电压对比图

Fig. 6 Comparison diagram of battery model simulation and measured terminal voltage

2 改进自适应卡尔曼滤波算法

2.1 传统自适应卡尔曼滤波算法

自适应卡尔曼滤波算法可以看作是在 EKF 算法基础上加入了系统过程噪声与量测噪声估算过程^[20]。在进行电池 SOC 估计时，针对离散的非线性系统列出如下状态空间方程。

$$\mathbf{X}(k/k-1) = f[\mathbf{X}(k-1/k-1), U(k-1)] + \boldsymbol{\omega}(k-1) \quad (13)$$

$$\mathbf{Y}(k) = g[\mathbf{X}(k/k-1), U(k)] + \mathbf{v}(k) \quad (14)$$

式中： $\mathbf{X}(k/k-1)$ 为 k 时刻状态变量 \mathbf{X} 的先验估计； $f(\cdot)$ 和 $g(\cdot)$ 均为非线性函数； $\mathbf{X}(k-1/k-1)$ 为 $k-1$ 时刻的状态变量； $U(k-1)$ 为 $k-1$ 时刻外在激励； $\boldsymbol{\omega}(k-1)$ 为 $k-1$ 时刻系统过程噪声向量； $\mathbf{Y}(k)$ 为 k 时刻系统观测向量； $U(k)$ 为 k 时刻外在激励； $\mathbf{v}(k)$ 为 k 时刻系统量测噪声向量。

对 $f(\cdot)$ 和 $g(\cdot)$ 进行线性化处理。

$$\mathbf{A} = \frac{df}{d\mathbf{X}} \quad (15)$$

$$\mathbf{C} = \frac{dg}{d\mathbf{X}} \quad (16)$$

式中： \mathbf{A} 为状态转移矩阵； \mathbf{C} 为观测方程对 \mathbf{X} 求

偏导之后的雅克比矩阵。

自适应卡尔曼滤波算法的基本过程如下。

首先, 根据系统上一时刻的状态对下一时刻的状态进行预测, 计算系统状态先验估计。

$$\mathbf{X}(k/k-1) = f[\mathbf{X}(k-1/k-1), U(k-1)] + \mathbf{q}(k-1) \quad (17)$$

式中, $\mathbf{q}(k-1)$ 为 $k-1$ 时刻系统过程噪声均值向量。

完成系统状态预测之后, 为了后续对预测值进行修正, 需要对误差协方差进行计算。

$$\mathbf{P}(k/k-1) = \mathbf{A} \times \mathbf{P}(k-1/k-1) \times \mathbf{A}^T + \mathbf{Q}(k-1) \quad (18)$$

式中: $\mathbf{P}(k/k-1)$ 为 k 时刻先验估计误差协方差矩阵; $\mathbf{P}(k-1/k-1)$ 为 $k-1$ 时刻的误差协方差矩阵;

$\mathbf{Q}(k/k-1)$ 为 $k-1$ 时刻系统过程噪声协方差矩阵。

再计算卡尔曼增益, 表示为

$$\mathbf{K}_g(k) = \mathbf{P}(k/k-1) \times \mathbf{C}^T / [\mathbf{C} \times \mathbf{P}(k/k-1) \times \mathbf{C}^T + \mathbf{R}_s(k-1)] \quad (19)$$

式中: $\mathbf{K}_g(k)$ 为 k 时刻卡尔曼增益矩阵; $\mathbf{R}_s(k-1)$ 为 $k-1$ 时刻量测噪声协方差矩阵。

为了根据观测量实现对系统状态先验估计的修正, 需对测量新息进行计算, 有

$$\boldsymbol{\varepsilon}(k) = \mathbf{Y}(k) - \mathbf{g}[\mathbf{X}(k/k-1), U(k)] - \mathbf{r}(k-1) \quad (20)$$

式中: $\boldsymbol{\varepsilon}(k)$ 为 k 时刻测量新息向量; $\mathbf{r}(k-1)$ 为 $k-1$ 时刻量测噪声均值向量。

再根据测量新息对系统状态预测值进行修正。

$$\mathbf{X}(k/k) = \mathbf{X}(k/k-1) + \mathbf{K}_g(k) \times \boldsymbol{\varepsilon}(k) \quad (21)$$

式中, $\mathbf{X}(k/k)$ 为 k 时刻状态变量 \mathbf{X} 的后验估计。

最后对误差协方差矩阵进行更新。

$$\mathbf{P}(k/k) = [\mathbf{E} - \mathbf{K}_g(k) \times \mathbf{C}] \times \mathbf{P}(k/k-1) \quad (22)$$

式中: $\mathbf{P}(k/k)$ 为 k 时刻后验估计误差协方差矩阵; \mathbf{E} 为单位矩阵。

相较于 EKF 算法, 自适应卡尔曼滤波算法最大的特点就是增加了噪声更新计算公式, 如式(23)~式(27)所示。

$$\mathbf{q}(k) = [1 - d(k-1)] \times \mathbf{q}(k-1) + d(k-1) \times \{\mathbf{X}(k/k-1) - f[\mathbf{X}(k-1/k-1), U(k-1)]\} \quad (23)$$

$$\mathbf{Q}(k) = [1 - d(k-1)] \times \mathbf{Q}(k-1) + d(k-1) \times \mathbf{K}_g(k) \times \boldsymbol{\varepsilon}(k) \times \boldsymbol{\varepsilon}(k)^T \times \mathbf{K}_g(k)^T + \mathbf{P}(k/k-1) - \mathbf{A} \times \mathbf{P}(k-1/k-1) \times \mathbf{A}^T \quad (24)$$

$$\mathbf{r}(k) = [1 - d(k-1)] \times \mathbf{r}(k-1) + d(k-1) \times \{\mathbf{Y}(k) - \mathbf{g}[\mathbf{X}(k/k-1), U(k)]\} \quad (25)$$

$$\mathbf{R}_s(k) = [1 - d(k-1)] \times \mathbf{R}_s(k-1) + d(k-1) \times \{\boldsymbol{\varepsilon}(k) \times \boldsymbol{\varepsilon}(k)^T - \mathbf{C} \times \mathbf{P}(k/k) \times \mathbf{C}^T\} \quad (26)$$

$$d(k) = \frac{1-b}{1-b^{k+1}} \quad (27)$$

式中: $\mathbf{q}(k)$ 为 k 时刻系统过程噪声均值向量; $d(k-1)$ 为 $k-1$ 时刻加权系数; $\mathbf{Q}(k)$ 为 k 时刻系统过程噪声协方差矩阵; $\mathbf{r}(k)$ 为 k 时刻量测噪声均值向量; $\mathbf{R}_s(k)$ 为 k 时刻量测噪声协方差矩阵; $d(k)$ 为 k 时刻加权系数; b 为遗忘因子, 用来调整新旧数据的权重, 一般取 0.9~1。

设定初始值之后, 根据式(17)~式(27)进行迭代, 即可实现对系统状态和系统噪声统计特性的预测和更新。

从式(23)~式(27)可以看出, 每一次迭代都需要重新计算系统噪声特性, 计算量很大, 影响实时计算效率。而且在复杂工况下, 系统误差波动较大, 会同时影响系统过程噪声和量测噪声的更新, 很容易引起噪声协方差矩阵出现非正定的情况, 导致滤波发散。此外, 电池的初始 SOC 一般较难准确确定, 会使得系统模型等误差在初始时刻较大, 而自适应算法由于需要对噪声统计特性进行不断地计算更新, 不能像 EKF 算法一样对系统目标状态进行快速跟踪, 使得在模型等误差较大的情况下很容易出现估计结果波动甚至发散的问题, 影响算法的实际应用效果^[22]。

针对以上问题, 本文对自适应卡尔曼滤波算法的噪声和状态更新过程进行了改进, 以提高算法在电池 SOC 估计过程中的准确性和鲁棒性。

2.2 改进自适应卡尔曼滤波算法

首先, 为了防止同时更新系统过程噪声和量测噪声统计特性导致滤波结果发散的问题, 本文只对系统过程噪声的协方差矩阵进行自适应调整。

然后, 为了避免在对系统过程噪声协方差进行更新过程中出现矩阵非正定的情况, 导致滤波发散, 本文将系统过程噪声协方差的更新计算公式进行了改进。随着运算迭代的进行, 误差协方差矩阵会逐渐减小, 甚至趋于零, 因此将式(24)改为

$$\mathbf{Q}(k) = [1 - d(k-1)] \times \mathbf{Q}(k-1) + d(k-1) \times \mathbf{K}_g(k) \times \boldsymbol{\varepsilon}(k) \times \boldsymbol{\varepsilon}(k)^T \times \mathbf{K}_g(k)^T \quad (28)$$

其次, 为了防止由于初始值等不准确导致模型误差变化, 进而引起估计结果误差增大甚至发散的问题, 本文在对系统状态预测值进行修正的过程中引入了增益因子 θ 。为了描述增益因子, 本文定义了新息误差。

$$e(k) = |\boldsymbol{\varepsilon}(k) / \mathbf{Y}(k)| \times 100\% \quad (29)$$

式中, $e(k)$ 为 k 时刻的新息误差。

如果新息误差过大, 则加强实际测量值对估计

结果的修正, 反之, 则削弱实际测量值对结果的修正, 以改变状态估计结果与测量结果的权重。通过增益因子来弥补模型等误差增大导致估计结果不准确的问题, 保证最后状态估计结果的准确性和稳定性。增益因子的大小根据新息误差及温度的变化进行调整, 定义为

$$\theta(k) = h[e(k), T] \quad (30)$$

式中: $\theta(k)$ 为 k 时刻的增益因子; h 为增益因子与新息误差和温度之间的关系函数。

最后, 为了实现增益因子对估计结果的修正, 本文将传统自适应卡尔曼滤波算法中的式(21)改为式(31)所示形式。

$$\mathbf{X}(k/k) = \mathbf{X}(k/k-1) + \theta(k) \times \mathbf{K}_g(k) \times \boldsymbol{\varepsilon}(k) \quad (31)$$

本文中改进的自适应卡尔曼滤波算法对系统状态进行先验估计的过程与改进前的一样。首先设定初始值, 根据式(17)、式(18)对系统状态进行先验估计及误差协方差计算; 再根据式(19)、式(20)计算卡尔曼增益与测量新息; 然后根据改进自适应卡尔曼滤波算法式(29)、式(30)计算新息误差 $e(k)$ 和增益因子 $\theta(k)$; 再将增益因子代入式(31)中对系统先验估计状态量进行修正; 最后根据式(22)对误差协方差矩阵进行更新。在上述计算过程中会同时对系统过程噪声特性进行估计更新。将遗忘因子 b 代入式(27)实时计算加权系数 $d(k)$; 再根据式(23)、式(28)分别对系统过程噪声均值 $\mathbf{q}(k)$ 和协方差矩阵 $\mathbf{Q}(k)$ 进行更新。

通过以上过程的迭代计算, 既能够实现同时对系统状态和过程噪声特性进行预测和更新, 又能够保证噪声协方差矩阵的正定性, 减小滤波发散和减小模型等误差变化带来的影响, 提高锂离子电池 SOC 估计的精度和强鲁棒性, 同时简化计算过程, 提高计算效率, 进一步增强自适应卡尔曼滤波算法的实用性。

3 基于改进自适应算法的 SOC 估计

3.1 SOC 估计设置

选择图 1 模型中两个 RC 端的端电压及电池的荷电状态量 S_{oc} 作为系统状态变量, 电流 I 为系统控制量, 以电池端电压作为系统观测量, 列出系统离散状态空间方程, 如式(33)所示。

$$\begin{bmatrix} U_1(k) \\ U_2(k) \\ S_{oc}(k) \end{bmatrix} = \mathbf{A} \times \begin{bmatrix} U_1(k-1) \\ U_2(k-1) \\ S_{oc}(k-1) \end{bmatrix} + \mathbf{B} \times I(k-1) + \mathbf{q}(k-1) \quad (32)$$

$$U_1(k) = U_{ocv}(k) - U_1(k) - U_2(k) - I(k) \times R_0 + \mathbf{v}(k) = \mathbf{C} \times \begin{bmatrix} U_1(k) \\ U_2(k) \\ S_{oc}(k) \end{bmatrix} - I(k) \times R_0 + \mathbf{v}(k) \quad (33)$$

$$\mathbf{A} = \begin{bmatrix} \exp\left(\frac{-T_s}{\tau_1}\right) & 0 & 0 \\ 0 & \exp\left(\frac{-T_s}{\tau_2}\right) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (34)$$

$$\mathbf{B} = \begin{bmatrix} R_1 \times [1 - \exp\left(\frac{-T_s}{\tau_1}\right)] \\ R_2 \times [1 - \exp\left(\frac{-T_s}{\tau_2}\right)] \\ \frac{-T_s}{C_a} \end{bmatrix} \quad (35)$$

$$\mathbf{C} = \begin{bmatrix} \frac{dU_{ocv}}{dS_{oc}} \\ -1 \\ -1 \end{bmatrix} \quad (36)$$

式中, \mathbf{B} 为外在激励系数矩阵。

在此次 SOC 估计过程中将增益因子 $\theta(k)$ 设置如下。

$$\theta(k) = h[e(k), T] = \begin{cases} 0.2 & e(k) \leq 0.05\% \text{ 且 } T < 10^\circ\text{C} \\ 1 & e(k) \leq 0.05\% \text{ 且 } T \geq 10^\circ\text{C} \\ 1.5 & 0.05\% < e(k) < 0.1\% \text{ 且 } T < 10^\circ\text{C} \\ 1.2 & 0.05\% < e(k) < 0.1\% \text{ 且 } T \geq 10^\circ\text{C} \\ 2 & e(k) \geq 0.1\% \text{ 且 } T < 10^\circ\text{C} \\ 1.5 & e(k) \geq 0.1\% \text{ 且 } T \geq 10^\circ\text{C} \end{cases} \quad (37)$$

新息误差 $e(k)$ 过大, 表明模型等误差较大, 状态估计结果不准确, 此时应加强实际测量值对状态估计结果的修正, 因此可以将增益因子 θ 设置为大于等于 1 的值; 反之, 新息误差 $e(k)$ 过小, 则说明状态结果比较准确, 此时应该削弱实际测量值对估计结果的修正, 可以将增益因子 θ 设置为小于 1 的值。此外, 不同温度条件下模型误差也会不同, 因此, 不同温度条件下增益因子有所不同。

为了使得 SOC 估计结果不会因为模型等误差变化而出现较大波动甚至滤波发散, 保障估计结果的准确性和稳定性, 同时又不会使得计算过程过于复杂, 因此将此次计算的增益因子定义为式(37)所示形式。

在 Simulink 中搭建算法模型进行仿真验证, 并

与基于改进前的自适应卡尔曼滤波算法和常用的 EKF 算法的计算结果及实测的 SOC 结果进行对比分析^[23], 验证本文算法模型的有效性。

3.2 估计结果分析

首先在 25 °C 下, 以 1 C 倍率对电池进行恒流充电, 充电到 3.65 V 截止电压之后, 改为恒压充电到电流降低至 0.05 C, 静置 1 h 之后, 再以 1 C 倍率进行恒流放电到 2.6 V 截止, 如此循环 4 圈, 最后一圈改为 3 C 倍率放电, 将此工况记为工况 1。然后将此工况条件分别作为改进后自适应卡尔曼滤波算法、改进前的算法及 EKF 算法模型的输入, 将 3 种算法中 SOC 的初始值均设置为 20%, 电池实际的 SOC 初始值为 0, 仿真测试得到 SOC 计算结果, 并与电池实测的 SOC 结果进行对比分析, 结果如图 7 所示。

由图 7 可以看出, 采用 3 种算法计算得到的 SOC 均能在一定时间内收敛至真实 SOC 附近。通过对收敛时间进一步分析, 发现 EKF 算法收敛时间约为 200 s, 改进前算法的收敛时间约为 20 s, 而本文改进自适应算法的收敛时间约为 5 s, 后两者的收敛速度要明显优于前者, 且改进后的自适应算法收敛速度相比于改进前的算法收敛速度提高了 3 倍, 比 EKF 算法的收敛速度提高了近 40 倍, 效果显著。

由图 7 可以进一步看出, 在整个测试过程中, 本文改进自适应卡尔曼滤波算法和 EKF 算法计算得到的 SOC 均能保持较好的稳定性, 而改进前算法计算得到的 SOC 在收敛之后又出现了发散, 导致后面计算得到的结果出现了异常。进一步对发散的原因进行分析, 发现预测的噪声协方差矩阵出现了非正定的情况, 从而导致滤波计算结果异常。

这里将 SOC 误差定义为实测 SOC 与算法估计 SOC 之间的差值。由于采用改进前的自适应算法计算得到的 SOC 已经出现了滤波发散, 因此这里不再对比分析其误差情况。从图 7 中可以看出, EKF 算法较本文改进自适应算法计算得到的 SOC 误差波动要大。随着充放电的进行, 前者的最大误差接近 6%, 而后者在收敛之后的整个过程中误差一直维持

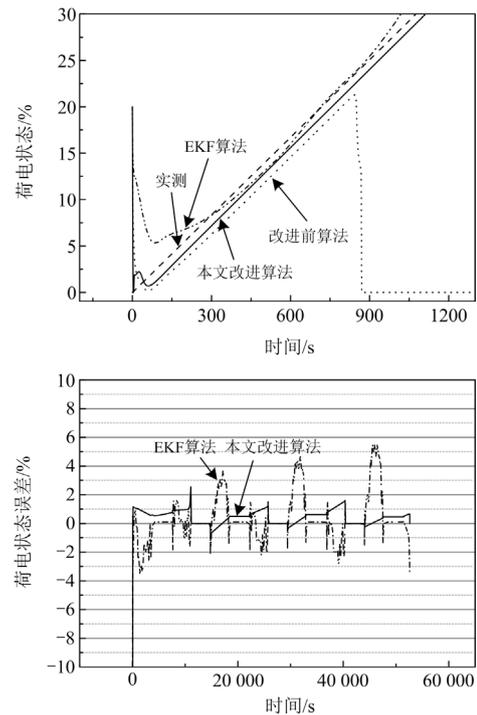


图 7 工况 1 条件下估计结果

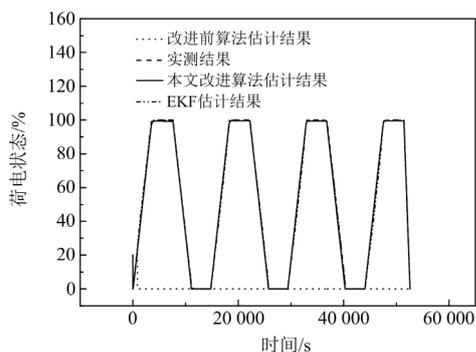
Fig. 7 Estimation results under condition 1

在 3% 以内, 本文改进自适应算法的最大误差相对于 EKF 算法减小 3%, 其精度和鲁棒性要明显优于 EKF 算法和改进前的算法。

进一步地, 将电池置于 25 °C 环境中, 以 25 A 电流放电 5 min, 再以 10 A 电流放电 2 min 的变电流交替放电方式进行测试, 采集到的电池电流及端电压均带有噪声, 3 种算法中 SOC 的初始值均设置为 20%, 电池实际的 SOC 初始值为 97%, 将此工况记为工况 2。在此条件下进行仿真测试, 得到基于 3 种算法的 SOC 计算结果, 并与电池实测的 SOC 结果进行对比分析, 结果如图 8 所示。

由图 8 可以看出, 在此工况下, 改进前算法计算得到的 SOC 结果难以收敛, 其在很长一段时期内都维持在初始值状态, 后期直接降到了 10% 左右; EKF 算法计算得到的 SOC 结果虽然能够收敛至真实值附近, 但是直到 1238 s 才开始收敛, 收敛时间较长, 而且在收敛之后, 其估计结果波动较大; 而采用本文改进的自适应卡尔曼滤波算法计算得到的 SOC 在 192 s 时就迅速收敛至真实值, 其收敛速度相比于 EKF 提高了 5 倍以上, 在收敛之后其结果依然稳定在真实值附近。

从图 8 中可以进一步看出, EKF 算法计算得到的 SOC 结果在收敛之后的误差最大能够达到 17% 左右; 而采用本文改进自适应卡尔曼滤波算法计算



得到的 SOC 误差在收敛之后依然保持在 3%以内，其最大误差相对于 EKF 算法减小了 14%，具有较高的准确性和稳定性。

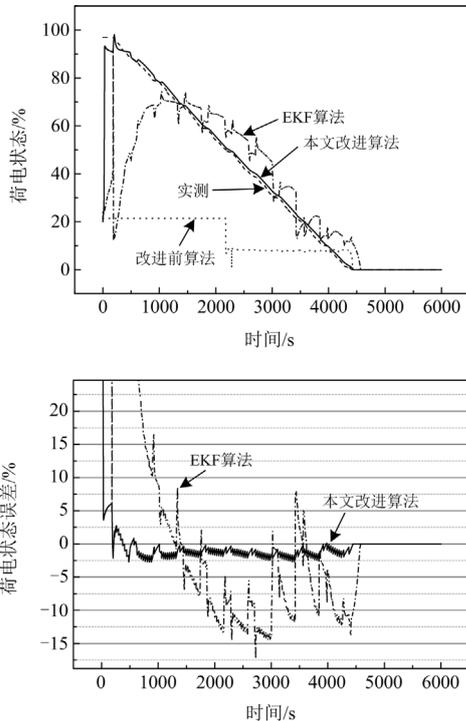


图 8 工况 2 条件下估计结果
Fig. 8 Estimation results under condition 2

为了进一步验证分析算法模型的低温实用性，将电池置于-10℃的环境中，以 25 A 电流放电 5 min，再以 10 A 电流放电 2 min 的变电流交替放电方式进行测试，采集到的电池电流及端电压均带有噪声，3 种算法中 SOC 的初始值均设置为 75%，电池实际的 SOC 初始值为 97%，将此工况记为工况 3。在此条件下，仿真测试得到基于 3 种算法的 SOC 计算结果，并与电池实测的 SOC 结果进行对比分析，结果如图 9 所示。

由图 9 可以看出，在此工况下，改进前算法计算得到的 SOC 值一开始就已经发散，后期一直处于异常状态。EKF 算法计算得到的 SOC 结果同样难

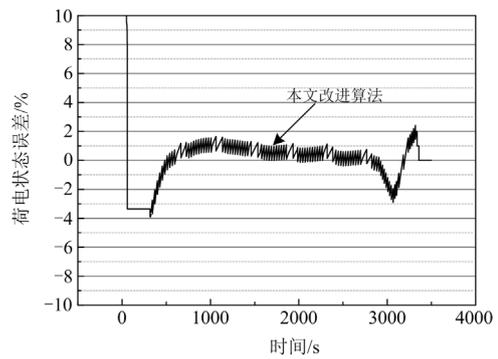
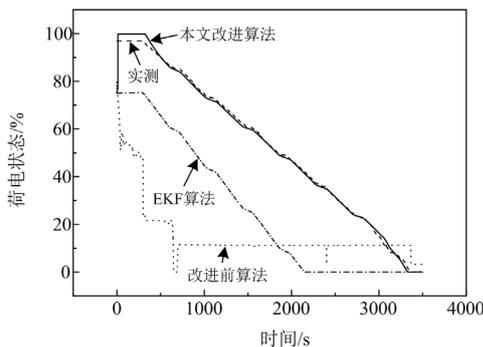


图 9 工况 3 条件下估计结果
Fig. 9 Estimation results under condition 3

以收敛，因此，这里不再分析二者的误差情况。而本文中改进的自适应卡尔曼滤波算法计算得到的 SOC 结果，仍然能够在 12 s 左右就从不准确的初始状态迅速收敛至真实值，而且其后期也一直稳定在真实 SOC 值附近。

进一步地，从改进自适应卡尔曼滤波算法计算得到的 SOC 误差分析结果中也可以看出，本文改进自适应卡尔曼滤波算法计算得到的 SOC 误差一直维持在 4%以内。

在以上 3 种不同工况下，改进前自适应卡尔曼滤波算法、EKF 算法及本文改进自适应卡尔曼滤波算法的 SOC 估计收敛情况，最大误差对比分析结果汇总如表 2 所示。

表 2 3 种不同算法 SOC 估计情况汇总表

Table 2 Summary of the SOC estimation results based on three different algorithms

项目	工况 1		工况 2		工况 3	
	收敛时间/s	最大误差/%	收敛时间/s	最大误差/%	收敛时间/s	最大误差/%
改进前自适应卡尔曼滤波算法	20	后期发散	不收敛	—	不收敛	—
EKF 算法	200	6	1238	17	不收敛	—
改进自适应卡尔曼滤波算法	5	3	192	3	12	4

由表 2 可以看出，本文的改进自适应卡尔曼滤波算法在 SOC 估计过程中的收敛速度、精度、鲁棒性均要明显优于改进前的自适应卡尔曼滤波算法和传统 EKF 算法。

4 结论

1) 本文对锂离子电池的二阶 RC 等效电路模型进行了改进，同时考虑了电池温度和 SOC 对模型参数的影响，并在不同温度条件下对模型的精度进行了验证。结果表明，该二阶 RC 等效电路模型在

模拟电池端电压特性时, 在 25 °C 条件下电压误差绝对值的平均值为 0.24 mV, 在-10 °C 条件下仅为 0.06 mV, 具有较高的精度。

2) 在电池 SOC 估计过程中, 本文对传统的自适应卡尔曼滤波算法进行了改进, 对噪声协方差计算公式进行了优化, 保证了协方差矩阵的正定性, 防止滤波发散, 提高计算效率。

3) 在系统状态先验估计修正过程中, 引入了增益因子, 增益因子的大小会根据观测量新息及温度的变化调整状态估计结果与测量结果的权重。基于改进自适应算法对磷酸铁锂电池在不同工况下的 SOC 进行了在线估计和验证。结果表明, 在常温不同工况下的 SOC 估计过程中, 本文改进的自适应算法收敛速度相比于 EKF 算法提高了 5~40 倍, 最大误差减小了 3%~14%; 即使在-10 °C 条件下, 改进自适应算法也能够在 12 s 内快速收敛, 误差维持在 4%以内, 而改进前的算法和 EKF 算法则均出现了滤波发散。本文提出的算法模型能够进一步提高电池 SOC 估计的精度和鲁棒性, 具有较好的实用性, 对电池的安全管理设计具有一定的指导意义和参考价值。

参考文献

- [1] XIE Zhengkun, YANG Zeying, AN Xiaowei, et al. An organosulfide-based energetic liquid as the catholyte in high-energy density lithium metal batteries for large-scale grid energy storage[J]. *Nano Research*, 2022, 15(7): 1-10.
- [2] 蒋子傲, 崔双喜. 基于混合储能系统的高电压穿越控制策略[J]. *电测与仪表*, 2022, 59(3): 125-130.
JIANG Ziao, CUI Shuangxi. High voltage ride through control strategy based on hybrid energy storage system[J]. *Electrical Measurement & Instrumentation*, 2022, 59(3): 125-130.
- [3] 陈金玉, 陈大玮, 张抒凌, 等. 面向风电功率波动平抑的储能系统鲁棒模型预测控制[J]. *供用电*, 2023, 40(8): 28-33.
CHEN Jinyu, CHEN Dawei, ZHANG Shuling, et al. Robust model predictive control of energy storage system for wind power fluctuation smoothing[J]. *Distribution & Utilization*, 2023, 40(8): 28-33.
- [4] 张雪菲, 孙阔, 张章, 等. 考虑源荷不确定性与碳减排的复合储能系统优化配置模型[J]. *电测与仪表*, 2022, 59(5): 42-49.
ZHANG Xuefei, SUN Kuo, ZHANG Zhang, et al. An optimal configuration model of composite energy storage system considering source-load uncertainty and carbon emission reduction[J]. *Electrical Measurement & Instrumentation*, 2022, 59(5): 42-49.
- [5] GIORGIA P, ZHANG Ning, KANG Chongqing, et al. Transmission planning with battery-based energy storage transportation for power systems with high penetration of renewable energy[J]. *IEEE Transactions on Power Systems*, 2021, 36(6): 4928-4940.
- [6] 薄利明, 郑惠萍, 张世锋, 等. 锂电池健康状态均衡技术综述[J]. *电测与仪表*, 2023, 60(4): 11-18.
BO Liming, ZHENG Huiping, ZHANG Shifeng, et al. Review on health state equalization technology for lithium batteries[J]. *Electrical Measurement & Instrumentation*, 2023, 60(4): 11-18.
- [7] YI Zhenxiao, CHEN Zhaoliang, YIN Kai, et al. Sensing as the key to the safety and sustainability of new energy storage devices[J]. *Protection and Control of Modern Power Systems*, 2023, 8(1): 2-22.
- [8] 李航洋, 阳同光. 计及动态非均匀热特性的储能软包锂电池充放电热路模型[J]. *电力系统保护与控制*, 2023, 51(19): 104-113.
LI Hangyang, YANG Tongguang. A charging/discharging thermal circuit model for energy storage pouch lithium batteries considering dynamic and non-uniform characteristics[J]. *Power System Protection and Control*, 2023, 51(19): 104-113.
- [9] 黄志亮, 王怀兴, 阳同光, 等. 储能锂离子电池包单体内部温度压力模拟[J]. *电力系统保护与控制*, 2022, 50(15): 138-146.
HUANG Zhiliang, WANG Huaixing, YANG Tongguang, et al. Simulation of internal temperature and pressure for cells in an energy storage lithium-ion battery[J]. *Power System Protection and Control*, 2022, 50(15): 138-146.
- [10] 蔡涛, 张钊诚, 袁奥特, 等. 锂离子电池储能安全管理中的机器学习方法综述[J]. *电力系统保护与控制*, 2022, 50(24): 178-187.
CAI Tao, ZHANG Zhaocheng, YUAN Aote, et al. Review of machine learning for safety management of li-ion battery energy storage[J]. *Power System Protection and Control*, 2022, 50(24): 178-187.
- [11] WANG Yu, FENG Xuning, PENG Yong, et al. Reductive gas manipulation at early self-heating stage enables controllable battery thermal failure[J]. *Joule*, 2022, 6(12): 2810-2820.
- [12] LI Ning, ZHANG Yu, HE Fuxing, et al. Review of lithium-ion battery state of charge estimation[J]. *Global Energy Interconnection*, 2021, 4(6): 619-630.
- [13] PLETT G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs[J]. *Journal of Power Sources*, 2004, 134(2): 277-292.

- [14] 龙振弘. 安时积分法和EKF结合的锂电池SOC估计[J]. 微处理机, 2024, 45(1): 39-43.
LONG Zhenhong. SOC estimation of lithium battery by combining ampere-hour integration method with EKF[J]. Microprocessors, 2024, 45(1): 39-43.
- [15] 黄凯, 孙恺, 郭永芳, 等. 基于观测方程重构滤波算法的锂离子电池荷电状态估计[J]. 电工技术学报, 2024, 39(7): 2214-2224.
HUANG Kai, SUN Kai, GUO Yongfang, et al. State of charge estimation of lithium-ion battery based on enhanced extended Kalman filter algorithm with observation equation reconstruction[J]. Transactions of China Electrotechnical Society, 2024, 39(7): 2214-2224.
- [16] 段林超, 张旭刚, 张华, 等. 基于二阶近似扩展卡尔曼滤波的锂离子电池SOC估计[J]. 中国机械工程, 2023, 34(15): 1797-1804.
DUAN Linchao, ZHANG Xugang, ZHANG Hua, et al. SOC estimation of lithium-ion batteries based on second-order approximation extended Kalman filter[J]. China Mechanical Engineering, 2023, 34(15): 1797-1804.
- [17] 海涛, 范攀龙, 王钧. 基于联合EKF-UKF算法的锂电池SOC预估研究[J]. 电源技术, 2023, 47(11): 1424-1428.
HAI Tao, FAN Panlong, WANG Jun. SOC estimation of lithium battery based on joint EKF-UKF algorithm[J]. Chinese Journal of Power Sources, 2023, 47(11): 1424-1428.
- [18] 李练兵, 孙坤, 季亮, 等. 基于双卡尔曼滤波的电池SOC估算[J]. 计算机工程与设计, 2021, 42(11): 3218-3224.
LI Lianbing, SUN Kun, JI Liang, et al. Battery SOC estimation based on double Kalman filter[J]. Computer Engineering and Design, 2021, 42(11): 3218-3224.
- [19] 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.
- [20] 柏菁, 刘建业, 袁信. 模糊自适应卡尔曼滤波技术研究[J]. 信息与控制, 2002, 31(3): 193-197.
BAI Jing, LIU Jianye, YUAN Xin. Study of fuzzy adaptive Kalman filtering technique[J]. Information and Control, 2002, 31(3): 193-197.
- [21] 卞鸿巍, 金志华, 王俊璞, 等. 组合导航系统新息自适应卡尔曼滤波算法[J]. 上海交通大学学报, 2006, 40(6): 1000-1009.
BIAN Hongwei, JIN Zhihua, WANG Junpu, et al. The innovation-based estimation adaptive Kalman filter algorithm for INS/GPS integrated navigation system[J]. Journal of Shanghai Jiaotong University, 2006, 40(6): 1000-1009.
- [22] 肖业伟, 谢小刚. 强跟踪抗差自适应滤波算法及其在无人机导航定位中的应用[J]. 测绘通报, 2021(4): 64-67.
XIAO Yewei, XIE Xiaogang. Strong tracking robust adaptive filtering algorithm and its application on UAV navigation and positioning[J]. Bulletin of Surveying and Mapping, 2021(4): 64-67.
- [23] 邱劲松, 王顺利, 范永存, 等. 基于改进Sage-Husa算法的锂电池SOC估算方法研究[J]. 控制工程, 2023, 30(4): 613-619, 628.
QIU Jingsong, WANG Shunli, FAN Yongcun, et al. Research on lithium battery SOC estimation method based on improved Sage-Husa algorithm[J]. Control Engineering of China, 2023, 30(4): 613-619, 628.
- [24] 潘正军, 袁兴有, 邓飞虎, 等. 基于扩展卡尔曼滤波的动力电池SOC估算[J]. 汽车实用技术, 2023, 48(22): 23-27.
PAN Zhengjun, YUAN Xingyou, DENG Feihu, et al. Power battery SOC estimation based on extended Kalman filter[J]. Automobile Applied Technology, 2023, 48(22): 23-27.

收稿日期: 2024-03-14; 修回日期: 2024-06-28

作者简介:

宋海飞(1984—), 男, 通信作者, 硕士, 副高级工程师, 主要研究方向为电池管理系统; E-mail: songhaifei@sgchip.sgcc.com.cn

王乐红(1990—), 男, 硕士, 主要研究方向为电池安全管理。E-mail: wanglehong@sgchip.sgcc.com.cn

(编辑 许威)