

基于 FFRLS-UKF 的储能电池荷电状态在线评估

罗飞¹, 饶俊星¹, 王江林², 李立秋¹, 陈瑶¹, 肖军¹, 张波¹, 袁啟鋒¹

(1. 国网四川省电力公司自贡供电公司, 四川 自贡 643000;

2. 重庆邮电大学自动化学院, 重庆 400065)

摘要: 对储能锂离子电池荷电状态(state of charge, SOC)的准确估计, 能保障储能锂电池系统安全稳定运行。针对储能锂电池等效电路模型参数不准确以及储能复杂环境噪声不确定的问题, 基于戴维南等效电路模型, 在实际测得的间隔恒流放电数据基础上利用带遗忘因子的递推最小二乘法进行等效电路参数辨识, 将辨识后参数计算得到的电压与试验电压进行比较分析, 验证所辨识模型的优劣并获取模型最优参数, 在此基础上, 提出一种基于无迹卡尔曼滤波算法对电池 SOC 进行准确估计。将所提算法与扩展卡尔曼滤波算法和安培小时积分法进行比较, 并分析不同初始 SOC 对估计结果的影响。结果表明, 所提方法在不同初始 SOC 条件下均可快速收敛并准确估计 SOC, 在初始 SOC 与模型参数无误差的条件下, 估计精度高达 99.2%。

关键词: 储能系统; 荷电状态; 模型驱动; 无迹卡尔曼滤波

中图分类号: TM 91 文献标志码: A 文章编号: 1003-6954(2025)01-0047-10

DOI: 10.16527/j.issn.1003-6954.20250107

Online Assessment for State of Charge of Energy Storage Battery Based on FFRLS-UKF

LUO Fei¹, RAO Junxing¹, WANG Jianglin², LI Liqiu¹, CHEN Yao¹,

XIAO Jun¹, ZHANG Bo¹, YUAN Qifeng¹

(1. State Grid Zigong Electric Power Supply Company, Zigong 643000, Sichuan, China; 2. School of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: The accurate estimation of state of charge (SOC) can make the battery management system more stable and reliable, which is of great significance to ensure the safe and stable operation of lithium ion battery system for energy storage. For the problems of inaccurate parameters of equivalent circuit model of energy storage lithium battery and uncertain complex environmental noise of energy storage, first of all, the interval constant current discharge data is measured, and recursive least square method with forgetting factor is used for parameter recognition of Thevenin equivalent circuit. Comparing the calculated voltage after recognition with the test voltage, the advantages and disadvantages of the recognition model are verified and the best parameters of the model are obtained. The algorithm based on unscented Kalman filtering is proposed for accurate estimation of battery SOC. The proposed method is compared with the extended Kalman filter algorithm and the Ampere-hour integration method, and the effects of different initial SOC on the estimation results are analyzed. The experimental results show that the proposed method can quickly converge at different initial SOC, and under the conditions without errors of initial SOC and model parameters, the estimated accuracy is as high as 99.2%.

Key words: energy storage system; state of charge; model-driven; unscented Kalman filtering

0 引言

随着工业社会的进步,风电、光伏等清洁能源近年来不断发展,但新能源发电存在电能质量较差和供电可靠性不高的问题,这使得储能技术受到了广泛关注^[1]。锂离子电池以其高安全性、优良电化学性能、长循环寿命以及环境友好性已成为储能单元的主要选择^[2]。由于集装箱式锂离子电池储能系统相对密闭的工作环境及有限的散热条件,使得锂离子电池在过充和过放后极容易产生热量的积聚,造成储能电站安全事故^[3]。因此,准确估计储能系统锂离子电池荷电状态(state of charge, SOC)这一关键指标,对掌握锂离子电池的工作状态,保障电站及电网安全稳定运行有着积极的意义^[4]。

目前,针对于锂离子电池 SOC 估计的方法主要分为开路电压法^[5]、安培小时积分法^[6]、神经网络算法^[7]、卡尔曼滤波(Kalman filter, KF)^[8]等。开路电压法可以通过查表法获得较高的精度,但测量集装箱式储能电站开路电压(open circuit voltage, OCV)需要其长时间静置,占用电池储能系统大量时间^[9]。安培小时积分法简单易行且适应低功耗条件,但在实际应用中依赖于集装箱式储能电站初始 SOC 的准确性和传感器精度,容易受到电流测量误差和积分漂移等因素的影响,导致累积误差的叠加,使得结果严重偏离实际值^[10]。常用的锂离子电池神经网络方法主要包括支持向量机(support vector machines, SVM)、浅层神经网络和深度学习。虽然 SVM 和浅层神经网络在简单非线性关系方面表现出色,但不适用于电池高度非线性系统^[11];而基于深度学习的方法依赖于大规模长时间运行数据,需要对电池进行大量的实验数据训练^[12]。

KF 通常结合电池等效电路模型进行 SOC 估计,但传统 KF 适用于一般线性问题,在锂离子电池高度非线性系统的应用效果不理想。为此,文献[13]在 KF 的基础上利用扩展卡尔曼滤波(extended Kalman filter, EKF)处理电池非线性进行 SOC 估算;文献[14]将双 EKF 合并联合 OCV-SOC 曲线,以准确估计电池 SOC;文献[15]将神经网络与 EKF 相结合,大大提高了 SOC 估计精度;文献[16]对 EKF 方法进行了改进,提高了 EKF 的估计精度。然而,由于在非线性近似中忽略了高阶项,EKF 类

方法在处理较强的非线性系统时存在着较大的系统误差。

无迹卡尔曼滤波(unscented Kalman filter, UKF)算法因其能对非线性系统准确描述,广泛应用于电池 SOC 估计。文献[17]提出的 OCV+UKF 方法使用了电流脉冲测试和 OCV 数据识别参数,但未能实现在线辨识。文献[18]利用 UKF 结合高斯回归算法获得 SOC 估计值,但未充分考虑模型参数对结果的影响。文献[19]提出了基于蚁狮优化器(ant lion optimizer, ALO)的 ALO+UKF 方法实现电池模型参数辨识,但由于涉及参数过多,模型结构过于复杂。文献[20]采用鲸鱼优化(whale optimization algorithm, WOA)与 UKF 相结合的方法对电池模型参数进行识别,但该方法对初始种群选择过于依赖,易导致收敛速度较慢或陷入局部最优解。文献[21]提出了多群粒子群优化(multi-swarm particle swarm optimization, MPSO)与 UKF 相结合的方法,尽管能够优化模型参数,但对初始条件敏感,可能导致收敛到局部最优解而非全局最优。为考虑模型参数影响,通常采用最小二乘法(least square, LS)及其改进算法等对电池等效电路模型的参数进行辨识。文献[22]利用 EKF 和递推最小二乘法(recursive least square, RLS)相结合来估算特种机器人锂离子电池 SOC,获得了较好的精度。

考虑现有方法所存在的问题,下面搭建了储能锂离子电池戴维南等效电路模型,使用带遗忘因子的递推最小二乘法(forgetting factor recursive least square, FFRLS)进行模型辨识,基于戴维南模型和 FFRLS-UKF 算法对储能电池进行 SOC 估计研究。通过对比实验,以广泛使用的电流积分法和 EKF 作为对比方法,结合平均误差(mean error, ME)、均方误差(mean square error, MSE)和准确率等评价指标验证了模型的准确率,并利用实验分析不同初始 SOC 误差下的估计结果,验证模型鲁棒性。

1 等效电路模型建立与参数辨识

1.1 OCV-SOC 曲线

电池的开路电压即电池经过充放电充分稳定后所测得的电池端电压值。电池的开路电压与所需要估计的 SOC 具有对应的关系。因此,研究开路电压特性,得到电池 OCV-SOC 曲线对模型参数辨识和

SOC 准确估计具有数据支撑作用。

在室温下对电池进行恒流脉冲间隔放电,放电后将电池静置足够时间以获取电池充分弛豫之后的开路电压。首先,将电池充满至截止电压,并静置足够长时间以获得 SOC 为 1.00 时的开路电压;然后,采用 1 倍率额定容量的恒流脉冲电流进行 20 次放电,每次放出 5% 的额定容量,静置 900 s 后,得到 SOC 为 0.95、0.90、0.85、…、0 时电池充分弛豫后的开路电压。实验中电池放电时的 SOC 变化及电流、电压波形如图 1 和图 2 所示。




图 1 恒流间隔放电 SOC 曲线

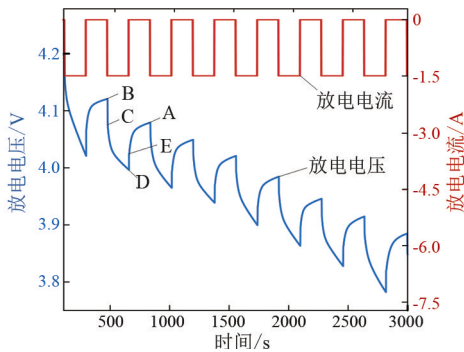


图 2 恒流间隔放电电压电流曲线

根据以上实验数据,绘制得到 OCV-SOC 关系的散点图和拟合曲线如图 3 所示。利用散点图对这些散点进行多项式拟合,所得到的 OCV-SOC 的六阶多项式函数关系为

$$V_{OCV} = A + A_0 S_{OC}^0 + A_1 S_{OC}^1 + A_2 S_{OC}^2 + A_3 S_{OC}^3 + A_4 S_{OC}^4 + A_5 S_{OC}^5 + A_6 S_{OC}^6 \quad (1)$$




图 3 OCV-SOC 关系拟合曲线

式中: S_{OC} 为荷电状态; V_{OCV} 为电池开路电压; A 、 A_0 、 A_1 、 A_2 、 A_3 、 A_4 、 A_5 、 A_6 分别为多项式拟合的系数。根据数据点拟合得到的多项式系数为: $A = 240.465 3$, $A_0 = 2.482 3$, $A_1 = 21.539 9$, $A_2 = -162.546 3$, $A_3 = 622.987 8$, $A_4 = 1 308.538 9$, $A_5 = 1 538.686 9$, $A_6 = -950.874 9$ 。

OCV-SOC 曲线可以用于基于模型驱动方法中等效模型参数辨识。如从图 2 可得,在 1 个 5% 额定容量的放电周期内,B 点为上一个放电周期结束后电池稳定的状态,同时也是下一个放电周期开始点,直至 A 点结束。在 BC 段和 DE 段出现直线下降以及直线上升的趋势,这是由于电池内部欧姆内阻的作用,而由于电池极化内阻的作用,导致电压出现“迟滞效应”,使得电池在放电阶段 CD 和 EA 段呈现缓慢减小或增加的趋势。因此,建立等效模型时,可以将电池的内阻等效为欧姆内阻与极化阻抗的某种组合,并利用不同阶段的电压辨识出对应时刻欧姆内阻和极化内阻的具体数值。

1.2 一阶戴维南模型建立

电池系统参数辨识及电池 SOC 估计需要基于准确的电池模型。目前常用的锂离子电池模型包括 n -RC 模型、PNGV 模型、Rint 模型和戴维南模型等。等效电路模型中并联的 RC 环节的数目越多,模型的精度越高;但计算成本也会需要更多,且在复杂环境下易出现不收敛和辨识精度提高不显著的问题。其中,Rint 模型未考虑极化效应,导致模型估计精度不准确;而二阶 RC 及 PNGV 模型需要辨识的参数较多,结合所采集的集装箱式储能电站数据以及实际建模情况,效果较差且无法实现收敛。相比之下,戴维南模型具有计算成本较低,能够满足实时性要求较高的储能应用场景,且戴维南模型在稳态和瞬态响应方面表现良好,能够准确反映电池的静态和动态特性,能有效描述上述欧姆内阻和极化内阻产生的电池特性。因此,选用戴维南模型作为电池等效电路模型。

戴维南模型是在 Rint 模型上增加了 RC 电路,解决了 Rint 模型未考虑到电池极化效应的问题,能够直接反映抽象的动态响应问题,其电路方程如式(2)、式(3)所示。图 4 为戴维南等效电路模型原理图,在模型中电容 C_1 用来描述电池在充放电过程中的瞬态响应。




图 4 戴维南等效电路模型

$$\dot{U}_1 = \frac{I}{C_1} + \left(-\frac{U_1}{R_1 C_1}\right) \quad (2)$$

$$U = V_{ocv} - IR_0 - U_1 \quad (3)$$

式中: R_1 为电池的极化内阻; U_1 为极化电容两端的电压; U 为电池的端电压; I 为电池负载电流; R_0 为电池内阻。

等效模型中未确定的参数有 R_0 、 R_1 、 C_1 , 需通过算法对模型进行参数辨识。

1.3 等效模型参数辨识

集装箱式储能锂离子电池在实际参与电网调度及应急使用等工作时, 表现为一个高度非线性时变系统。采用离线参数辨识时, 所辨识参数难以跟随系统时序变化, 造成电池的等效模型参数与实际参数不匹配, 导致辨识精度偏低。因此, 需要引入在线参数辨识方法, 通过采集电池运行中可测数据, 根据电路模型动态解析各参数之间的数学关系, 最后利用算法对系统的各参数进行实时在线辨识。

利用实时采集的参数更新等效模型, 可以减小模型参数随时间变化造成的估计误差。在线辨识的参数可以准确反映当前时刻戴维南等效模型各个参数的值, 在一定程度上减小模型估计误差, 以提高 SOC 估计精度。这里采用 FFRLS 对戴维南等效电路模型进行在线参数辨识, 以应对电池长期运行过程中能量、寿命衰减的问题。

由式(2)和式(3)可得戴维南模型各个参数之间的关系, 通过拉氏变换得到的储能电池戴维南模型在频域下的传递函数为

$$G(s) = \frac{U_{oc}(s) - U_1(s)}{I(s)} = R_0 + \frac{R_1}{sR_1 C_1 + 1} \quad (4)$$

式中: s 为复变量; U_{oc} 为电池的开路电压; U_1 为电池在负载下的端电压; I 为电池的电流。

为保证该系统离散化前后一致, 采用双线性变换对式(4)进行离散化, 将式(5)代入式(4)中可得离散后的传递函数式(6)。

$$s = \frac{2(1 - z^{-1})}{T(1 + z^{-1})} \quad (5)$$

$$G(z^{-1}) = \frac{U_{oc}(z^{-1}) - U_1(z^{-1})}{I(z^{-1})} = \frac{c_2 + c_3 z^{-1}}{1 + c_1 z^{-1}} \quad (6)$$

其中:

$$c_1 = \frac{T - 2R_1 C_1}{T + 2R_1 C_1} \quad (7)$$

$$c_2 = \frac{R_0 T + R_1 T + 2R_0 R_1 C_1}{T + 2R_1 C_1} \quad (8)$$

$$c_3 = \frac{R_0 T + R_1 T - 2R_0 R_1 C_1}{T + 2R_1 C_1} \quad (9)$$

式中: z 为 Z 变换的复变量; T 为采样周期, 用于将连续系统离散化的时间间隔。

将式(6)转换到时域中的传递函数为

$$(U_{oc,k} - U_{1,k}) = -c_1(U_{oc,k-1} - U_{1,k-1}) + c_2 I_k + c_3 I_{k-1} \quad (10)$$

式中: $U_{oc,k}$ 为 k 时刻电池的开路电压; $U_{1,k}$ 为 k 时刻电池的端电压; I_k 为 k 时刻电池的负载电流。

令:

$$\begin{cases} y_k = U_{oc,k} - U_{1,k} \\ \theta_k = [c_1 \quad c_2 \quad c_3] \\ \phi_k = [-y_{k-1} \quad I_k \quad I_{k-1}]^T \end{cases} \quad (11)$$

则式(10)可以表示为




$$y_k = \theta_k \phi_k \quad (12)$$

由 FFRLS 算法可以求得参数 c_1 、 c_2 与 c_3 , 通过这些参数的求解, 即可进一步辨识出欧姆内阻 R_0 、电池极化内阻 R_1 和电池极化电容 C_1 。

$$\begin{cases} R_0 = \frac{c_2 - c_3}{1 - c_1} \\ R_1 = \frac{c_2 + c_3}{1 + c_1} - R_0 \\ C_1 = \frac{T(1 - c_1) / 2(1 + c_1)}{R_1} \end{cases} \quad (13)$$

对储能系统单体电池进行间隔恒流放电实验, 利用 FFRLS(遗忘因子为 0.95) 辨识戴维南模型的欧姆内阻、极化内阻与极化电容, 辨识结果如图 5、图 6 和图 7 所示。

由图 5—图 7 可知: 在储能电池放电初期, 由于所设置的启动初值的影响, 电池 R_0 和 C_1 值偏小; 当储能电池继续放电, 系统根据所测得的误差对协方差矩阵进行及时调整, 使辨识值更新到当前时刻实际参数较为接近的位置。

图 5 电池内阻 R_0 辨识值图 6 电池极化内阻 R_1 辨识值图 7 电池极化电容 C_1 辨识值

为了验证所辨识模型参数的准确性,将上述参数辨识所得到的参数值代入所建立的戴维南模型中,利用所代入参数得到的电压值与实际放电电压值进行比较。辨识模型输出电压与实际电压如图 8 所示,辨识模型电压误差如图 9 所示。

由图 8 和图 9 可知,辨识模型的电压与实际电压曲线较为贴合,误差较小,均控制在 0.1 V 以内。实验结果可以证明,利用 FFRLS 在线辨识的参数具有较高的辨识精度,能够满足实验要求,模型可以对实际放电行为进行准确仿真。




图 8 辨识模型电压与实际电压曲线




图 9 辨识模型电压误差曲线

2 基于 FFRLS-UKF 算法的储能电池 SOC 估计

2.1 UKF 算法

基于等效电路模型的储能锂离子电池 SOC 估计主要利用在线参数辨识所得到的模型参数,采用 UKF 算法对电池 SOC 进行估计。UKF 算法基于卡尔曼滤波算法,并采用无迹变换(unscented transform, UT)处理,可以很好地描述储能锂离子电池非线性特性,进而得到高精度的 SOC 估计。

戴维南等效电路模型的线性系统方程为

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k + \mathbf{B}\mathbf{u}_k + \mathbf{w}_k \\ \mathbf{y}_k = \mathbf{C}\mathbf{x}_k + \mathbf{D}\mathbf{u}_k + v_k \end{cases} \quad (14)$$

式中: \mathbf{x}_k 为系统状态向量,描述系统在 k 时刻的状态; \mathbf{u}_k 为 k 时刻输入变量向量,表示外部对系统的控制或影响; \mathbf{w}_k 为过程噪声,描述模型的不确定性; \mathbf{y}_k 为 k 时刻系统输出向量,表示系统的测量输出; v_k 为 k 时刻测量噪声,描述测量过程中的不确定性; \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 、 \mathbf{D} 为系统矩阵,定义了系统的状态转移和输出特性。

选取 SOC 与 U_1 为系统状态变量,电流 I 为输

入变量, 电池端电压 U 为输出变量。由所建立的仿真电路戴维南模型, 得到如下系统离散状态方程。

$$\begin{bmatrix} S_{\text{Ock}+1} \\ U_{1,k+1} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & \exp - \frac{T}{R_1 C_1} \end{bmatrix} \begin{bmatrix} S_{\text{Ock}+1} \\ U_{1,k} \end{bmatrix} + \begin{bmatrix} \frac{T}{Q_0} \\ R_0 \left(1 - \exp - \frac{T}{R_1 C_1} \right) \end{bmatrix} I_k + \begin{bmatrix} w_{1k} \\ w_{2k} \end{bmatrix} \quad (15)$$

$$U_k = F(S_{\text{Ock}}) - U_{1,k} - I_k R_{0,k} + v_k \quad (16)$$

式中: S_{Ock} 为 k 时刻的荷电状态; $U_{1,k}$ 为 k 时刻极化电容两端的电压; $R_{0,k}$ 为 k 时刻的欧姆内阻; w_{1k} 和 w_{2k} 均为过程噪声, 描述模型的不确定性; Q_0 为电池的额定容量; $F(S_{\text{Ock}})$ 为状态空间方程的函数, 描述系统在 k 时刻的状态与输入之间的关系。

状态空间模型的系数矩阵可表示为:

$$\mathbf{A} = \begin{bmatrix} 1 & 0 \\ 0 & \exp - \frac{T}{R_1 C_1} \end{bmatrix} \quad (17)$$

$$\mathbf{B} = \begin{bmatrix} \frac{T}{Q_0} \\ R_0 \left(1 - \exp - \frac{T}{R_1 C_1} \right) \end{bmatrix} \quad (18)$$

$$\mathbf{C} = \begin{bmatrix} \frac{\partial F(S_{\text{Ock}})}{\partial S_{\text{Ock}}} & -1 \end{bmatrix}, \quad \mathbf{D} = R_{0,k} \quad (19)$$

sigma 点是一组有代表性的采样点, 用于捕捉系统状态的均值和方差特征。UKF 主要通过 UT 变换保证 sigma 点与状态变量特征, 并对电池非线性系统进行处理。UKF 由状态变量均值和方差得到 sigma 点集, 将点集按状态空间模型进行传递运算得到新的点集, 通过加权运算得到状态变量的最优估计, 然后重复前面的运算过程进行迭代, 有效捕捉电池非线性动态特性, 从而对电池的 SOC 进行精确估计和校正。主要计算过程如下:

1) 参数值初始化, 初始变量为 S_{Oco} 和 U_1

$$\begin{cases} \mathbf{x}_0 = \begin{bmatrix} S_{\text{Oco}} \\ U_1 \end{bmatrix} \\ \hat{\mathbf{x}}_0 = E(\mathbf{x}_0) \\ \mathbf{P}_0 = D(\mathbf{x}_0) \end{cases} \quad (20)$$

式中: \mathbf{x}_0 为系统的初始状态向量, 包括系统在 $k=0$

时刻的所有状态变量, 例如初始荷电状态 S_{Oco} 和极化电压 U_1 ; $\hat{\mathbf{x}}_0$ 为初始状态的估计值, 表示对系统初始状态的期望; $E(\mathbf{x}_0)$ 为状态向量 \mathbf{x}_0 的数学期望, 用于量化初始状态的中心趋势; $D(\mathbf{x}_0)$ 为状态向量 \mathbf{x}_0 的方差, 描述初始状态的不确定性; \mathbf{P}_0 为初始状态协方差矩阵, 用于量化对初始状态估计的置信度及其关联性。

2) 状态变量估计

$$\begin{cases} \bar{x}_i(k+1) = f[x_i(k)], i = 1, 2, \dots, 2n \\ \bar{x}(k+1) = \sum_{i=0}^{2n} \omega_{m,i} f[x_i(k)] \end{cases} \quad (21)$$

式中: $x_i(k)$ 为系统在 k 时刻的第 i 个状态变量; $\bar{x}(k+1)$ 为 $k+1$ 时刻的状态均值估计; $f(\cdot)$ 为状态转移函数, 描述系统从 k 时刻到 $k+1$ 时刻的动态演化过程; $\omega_{m,i}$ 为与第 i 个 sigma 点对应的权重, 用于对状态估计的均值进行加权; n 为系统状态变量的总数。

3) 测量值预测

$$\begin{cases} \bar{y}_i(k+1) = h[x_i(k)] \\ \bar{y}(k+1) = \sum_{i=0}^{2n} \omega_{m,i} h[x_i(k)] \end{cases} \quad (22)$$

式中: $\bar{y}_i(k+1)$ 为 $k+1$ 时刻由第 i 个 sigma 点计算得到的测量值; $h(\cdot)$ 为测量函数, 用于描述系统状态如何映射为测量输出; $\bar{y}(k+1)$ 为 $k+1$ 时刻的测量均值估计, 通过对所有 sigma 点的测量结果进行加权求和得到。

4) 误差协方差更新及计算卡尔曼增益

$$\begin{cases} \mathbf{P}_y(k+1) = \sum_0^{2n} \omega_{c,i} [\bar{y}_i(k+1) - \bar{y}(k+1)] \cdot \\ \quad [\bar{y}_i(k+1) - \bar{y}(k+1)]^T + \mathbf{R}(k) \\ \mathbf{P}_{xy}(k+1) = \sum_0^{2n} \omega_{c,i} [\bar{x}_i(k+1) - \bar{x}(k+1)] \cdot \\ \quad [\bar{x}_i(k+1) - \bar{x}(k+1)]^T \end{cases} \quad (23)$$

$$\mathbf{K}(k+1) = \mathbf{P}_{xy}(k+1) [\mathbf{P}_y(k+1)]^{-1} \quad (24)$$

式中: $\mathbf{P}_y(k+1)$ 为 $k+1$ 时刻测量值的预测误差协方差矩阵; $\mathbf{R}(k)$ 为 $k+1$ 时刻测量噪声协方差矩阵; $\mathbf{P}_{xy}(k+1)$ 为 $k+1$ 时刻状态与测量值之间的协方差矩阵; $\mathbf{K}(k+1)$ 为 $k+1$ 时刻卡尔曼增益矩阵; $\omega_{c,i}$ 为第 i 个 sigma 点的加权系数, 用于计算预测和更新阶段的协方差。

5) 状态变量更新和协方差更新

$$\begin{cases} \hat{x}(k+1) = \bar{x}(k+1) + K(k+1)[y(k+1) - \bar{y}(k+1)] \\ P(k+1) = \bar{P}(k+1) - K(k+1)P_y(k+1) \cdot K^T(k+1) \end{cases} \quad (25)$$

式中: $P(k+1)$ 为更新后的状态误差协方差矩阵,用于量化更新后的状态估计的不确定性; $\bar{P}(k+1)$ 为预测的状态误差协方差矩阵,描述了在 $k+1$ 时刻预测阶段的状态估计不确定性。

2.2 FFRLS-UKF 估计储能电池 SOC

如图 10 所示,基于 FFRLS-UKF 等效电路模型对 SOC 进行估计,首先,需要通过 Simulink 软件搭建戴维南电路模型,并利用实测电池 OCV-SOC 曲线以及 FFRLS 在线辨识算法对电路参数进行辨识;然后,需要构造储能电池状态空间方程,采用先进的 UKF 算法对 SOC 进行估计。该方法可以应对电池放电数据变化幅度较大、变化趋势周期性不强、非线性程度较高、SOC 估计难度较大等问题。




图 10 等效电路模型方法原理

SOC 估计流程如图 11 所示:首先,将电池端的初始电流 I_0 和初始荷电状态 S_{oc0} 输入到电池仿真模型端;然后,电池仿真模型通过参数辨识后输出端电压 U_0 ,并与电池端实际端电压 U 进行比较,得到端电压偏差 ΔU ;最后,采用所提出的 SOC 估计方法进行计算,利用所输出的估计差值 ΔS_{oc} 对每个采样时刻的 SOC 估计值进行修正,并将校正后的 SOC 输入电池仿真模型用作计算下一时刻的端电压。

3 实验验证与分析

3.1 准确性验证

不同的电池管理系统由于各自算法设计、硬件电路、电流采样芯片选择的不同,其电池 SOC 估算的精度也各不相同。下面以集装箱式储能电站广泛使用的电流积分法作为对比方法,选用的实验对象为 18 650 储能电池,在经过 FFRLS 参数辨识之后的

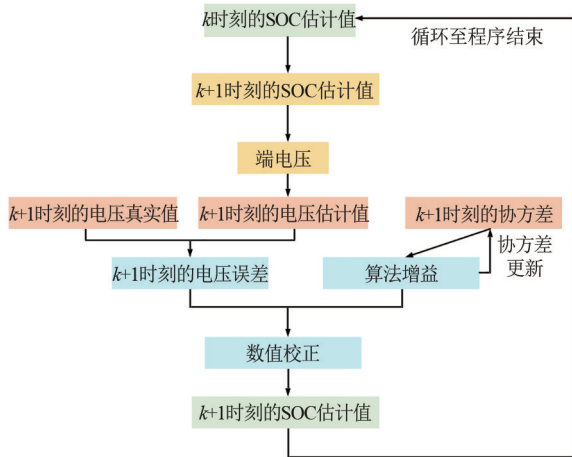


图 11 算法估计流程

戴维南模型基础上,采用如图 12 所示的电池充放电曲线,对比安培小时积分(AH)、EKF、UKF 算法对储能电池的 SOC 估计。设置总采样次数 N 为 13 000,初始 SOC 值为 1.0,SOC 估计过程中的噪声方差为 1×10^{-9} ,过程噪声方差为 1×10^{-7} ,观测噪声方差为 0.01,上述 3 种方法估计的 SOC 曲线如图 13 所示。




图 12 实验电压与电流曲线




图 13 各算法 SOC 估计曲线

从图 13 可以看出,在 SOC 初始值为 1.0 的条件下,所采用的 FFRLS-UKF 方法与其他算法相比,在整个放电过程中曲线更加贴近于真实的 SOC 曲线。图 14 所示为各算法 SOC 估计值与电池放电过程中实际 SOC 的绝对误差。由图可知,在相同的工作条件下,所提算法误差在整个放电周期内均低于其他算法。

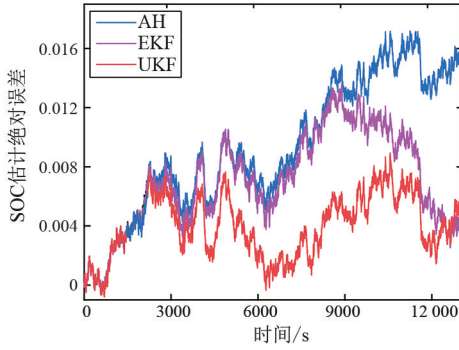


图 14 各算法 SOC 估计绝对误差

表 1 为不同算法所估计 SOC 的评价指标,可以看出,所提方法在放电周期内 ME 相对于 EKF 和 AH 算法均有较大提升,表明其预测值与真实值之间的平均差异较小。所提方法的 MSE 和准确率也均优于其他方法,说明所提方法可以在电池放电条件下进行准确的在线 SOC 估计。

表 1 各算法 SOC 估计评价指标

算法	ME/%	MSE/%	准确率/%
AH	0.933 7	0.108 2	97.93
EKF	0.705 1	0.060 2	98.61
UKF	0.399 7	0.020 1	99.20

3.2 鲁棒性验证

为了探究所提算法的鲁棒性,通过设置不同的储能电池 SOC 初始值,观察不同算法表现。分别设置初始 SOC 为 1.00、0.75 和 0.50,得到所提算法模型在未知初始 SOC 情况下的 SOC 估计图和绝对误差。由于安培小时积分法过度依赖 SOC 初始值,在未知 SOC 初始值时不能预估电池的变化,所以不纳入本次对比实验。初始 SOC 为 1.00、0.75 和 0.50 电池放电时,各算法的 SOC 估计曲线分别如图 13、图 15 和图 17 所示,SOC 估计的绝对误差分别如图 14、图 16 和图 18 所示。




图 15 初始 SOC 为 0.75 时各算法估计曲线

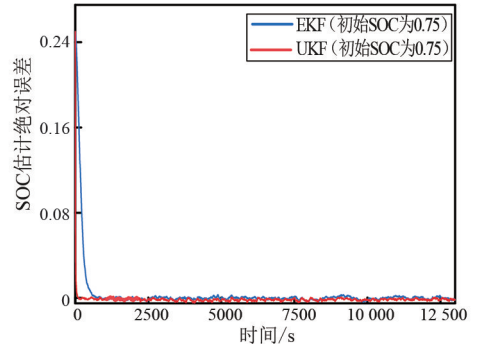


图 16 初始 SOC 为 0.75 各算法 SOC 估计绝对误差

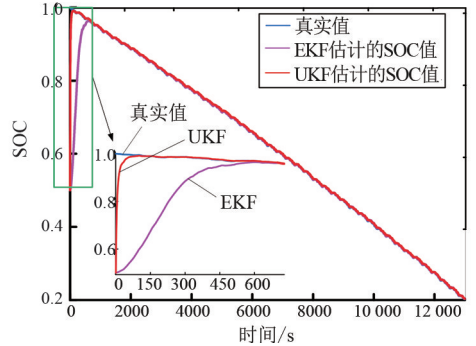


图 17 初始 SOC 为 0.50 时各算法估计曲线




图 18 初始 SOC 为 0.50 各算法 SOC 估计绝对误差

由图可知,在给定不同初始 SOC 下,所提 FFRLS-UKF 算法在短暂调整后较好地跟踪实际 SOC 值,而 EKF 算法估计偏差较大,调整时间较长。当给定 SOC 初始值为 0.50 的情况下,所提算法在第 133 步时可以调整收敛到实际 SOC 曲线附近,而 EKF 需要 722 步才能收敛到曲线。当给定 SOC 初始值为 0.75 时,所提算法在 104 步即可收敛到真实值曲线,对比模型,EKF 则需要 690 步才收敛到真实值。

综上所述,初始 SOC 直接影响模型收敛速度以及估计精度,所提算法在不同 SOC 初始值下,都能快速收敛到真实值且曲线较 EKF 更加贴合真实曲线。这是因为所提算法可以根据测量端电压与估计端电压之间的误差及时对卡尔曼增益进行调整。较大的端电压估计误差可以产生更大的卡尔曼增益矩阵对 SOC 估计值进行校正。故即使实际的电池初

始 SOC 与模型存在误差,所提算法也能在较短时间内获得准确的 SOC 估计结果。

4 结 论

针对集装箱式储能系统电池实时 SOC 估计方法存在的问题,上面提出了一种基于 FFRLS-UKF 的等效电路模型方法。首先,选取戴维南模型作为仿真模型,采用 FFRLS 对模型参数进行辨识并验证了辨识模型的准确性。然后,在此基础上,采用 UKF 算法对电池放电时 SOC 进行实时估计。通过与 EKF 算法、安培小时积分法的实验验证对比,结果表明,所提算法在不同环境下均具有更高的精度和更强的鲁棒性及适用性,能更广泛地对不同复杂现场环境的储能系统进行 SOC 估计。

参考文献

- [1] WANG Z, XIAO Y L, WAN Y, et al. Research on energy management strategy of photovoltaic-battery energy storage system [J]. *International Journal of Low-Carbon Technologies*, 2022, 17:488-493.
- [2] 徐谦,孙轶恺,刘亮东,等. 储能电站功能及典型应用场景分析[J]. *浙江电力*, 2019, 38(5):3-10.
- [3] 袁小明,程时杰,文劲宇. 储能技术在解决大规模风电并网问题中的应用前景分析[J]. *电力系统自动化*, 2013, 37(1):14-18.
- [4] 梅简,张杰,刘双宇,等. 电池储能技术发展现状[J]. *浙江电力*, 2020, 39(3):75-81.
- [5] MENG J H, STROE D-I, RICCO M, et al. A novel multiple correction approach for fast open circuit voltage prediction of lithium-ion battery [J]. *IEEE Transactions on Energy Conversion*, 2019, 34(2):1115-1123.
- [6] ZHAO C Y, ANDERSEN P B, TRAEHOLT C, et al. Grid-connected battery energy storage system: A review on application and integration [J]. *Renewable and Sustainable Energy Reviews*, 2023, 182:113400.
- [7] DING S Y, DONG C Y, ZHAO T Y, et al. A meta-learning based multimodal neural network for multistep ahead battery thermal runaway forecasting [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(7):4503-4511.
- [8] HASSAN M U I, SAHA S, HAQUE Md E, et al. A comprehensive review of battery state of charge estimation techniques [J]. *Sustainable Energy Technologies and Assessments*, 2022, 54:102801.
- [9] BIAN C, HE H L, YANG S K. Stacked bidirectional long short-term memory networks for state-of-charge estimation of lithium-ion batteries [J]. *Energy*, 2020, 191:116538.
- [10] MENG J H, RICCO M, LUO G Z, et al. An overview and comparison of online implementable SOC estimation methods for lithium-ion battery [J]. *IEEE Transactions on Industry Applications*, 2018, 54(2):1583-1591.
- [11] ANTÓN J C A, NIETO P J G, VIEJO C B, et al. Support vector machines used to estimate the battery state of charge [J]. *IEEE Transactions on Power Electronics*, 2013, 28(12):5919-5926.
- [12] HU X S, SUN F C, ZOU Y. Comparison between two model-based algorithms for Li-ion battery SoC estimation in electric vehicles [J]. *Simulation Modelling Practice and Theory*, 2013, 34:1-11.
- [13] XU H, HU X F, ZHANG Q. An EKF algorithm for lithium-ion battery SOC estimation based on an equivalent circuit model [C] // 2022 IEEE International Conference on Power Systems and Electrical Technology, October 13-15, 2022, Aalborg, Denmark. *IEEE*, 2022:17-22.
- [14] LEE S J, KIM J H, LEE J M, et al. The state and parameter estimation of an Li-ion battery using a new OCV-SOC concept [C] // 2007 IEEE Power Electronics Specialists Conference, June 17-21, 2007, Orlando, FL, USA. *IEEE*, 2007:2799-2803.
- [15] CHARKHGARD M, FARROKHI M. State-of-charge estimation for lithium-ion batteries using neural networks and EKF [J]. *IEEE Transactions on Industrial Electronics*, 2010, 57(12):4178-4187.
- [16] HUANG Z J, FANG Y S, XU J J. SOC estimation of li-ion battery based on improved EKF algorithm [J]. *International Journal of Automotive Technology* 2021, 22:335-340.
- [17] ZHOU J Z, ZHANG X W. Power battery SOC estimation with combination method based on UKF and open circuit voltage [J]. *International Journal of Electric and Hybrid Vehicles*, 2014, 6(3):215-226.
- [18] LI Q, MIAO S G, LIU S Z, et al. A joint state estimation framework for lithium-ion batteries based on hybrid method [J]. *Journal of Physics: Conference Series*, 2022, 2276:012023.
- [19] LIAN G Q, YE M, WANG Q, et al. A BP neural network-Ant lion optimizer and UKF method for SOC estimation of lithium-ion batteries [J]. *Journal of Physics: Conference Series*, 2022, 2369:012072.
- [20] WU Z Q, WANG G Y, XIE Z K, et al. Lithium battery