

DOI: 10.19783/j.cnki.pspc.240012

# 考虑锂电池多时间尺度效应的参数辨识与SOC估计方法

邹国发, 高祥, 王春

(四川轻化工大学机械工程学院, 四川 宜宾 644000)

**摘要:** 准确的荷电状态(state of charge, SOC)估计对新能源汽车电池管理系统的安全运行具有重要意义, 而可靠的参数辨识是SOC估计的关键。考虑锂电池多时间尺度效应, 提出了自适应遗忘因子递推最小二乘法(adaptive forgetting factor recursive least squares, AFFRLS)与自适应扩展卡尔曼滤波(adaptive extended Kalman filtering, AEKF)联合的参数辨识算法。首先, 根据多时间尺度效应将锂电池双极化模型(dual-polarization model, DP)划分为快动态与慢动态。其次, 设计AFFRLS与AEKF联合的参数辨识算法, 分别辨识快、慢动态参数。最后, 结合参数辨识数据利用H无穷算法估计SOC。结果表明, 所提算法在不同工况与温度下具备良好的精度与鲁棒性。模型最大端电压均方根误差仅为3.329 mV, SOC均方根误差低于1%。

**关键词:** 新能源汽车; 锂电池; 多时间尺度; 联合参数辨识; 荷电状态

## Parameter identification and SOC estimation methods considering multi-timescale effect lithium batteries

ZOU Guofa, GAO Xiang, WANG Chun

(School of Mechanical Engineering, Sichuan University of Science and Engineering, Yibin 644000, China)

**Abstract:** Accurate state of charge (SOC) estimation is of great significance for the safe operation of battery management systems in new energy vehicles, and reliable parameter identification is the key to SOC estimation. In this paper, a joint parameter identification algorithm based on adaptive forgetting factor recursive least squares (AFFRLS) and adaptive extended Kalman filter (AEKF) is proposed considering the multi-timescale effect of a lithium battery. First, a lithium battery dual-polarization model (DP model) is classified into fast dynamic and slow dynamic based on multi-timescale effects. Secondly, the AFFRLS and AEKF based-joint parameter identification algorithm is designed to identify the parameters of fast dynamic and slow dynamic, respectively. Finally, the SOC is estimated using an H-infinity algorithm with the parameter identification data. The results show that the proposed algorithm has good accuracy and robustness in different driving cycles and at different temperatures. The maximum root-mean-square error of the terminal voltage is only 3.329 mV, and the SOC root mean square error is less than 1%.

This work is supported by the National Natural Science Foundation of China (No. 51907136).

**Key words:** new energy vehicle; lithium battery; multi-timescale; joint parameter identification; state of charge

## 0 引言

大力发展新能源汽车是我国汽车行业支撑“碳达峰、碳中和”目标的重要技术路径<sup>[1]</sup>。锂电池作为新能源汽车的主要储能元件, 其准确的SOC估计, 对电池管理系统(battery management system, BMS)

制定合理的控制策略具有重要意义<sup>[2-4]</sup>, 而精确的电池模型参数辨识是SOC估计的关键一环<sup>[5]</sup>。

建立精确的电池模型是估计锂电池SOC的前提<sup>[6]</sup>。电化学模型(electrochemical model, EM)和等效电路模型(equivalent circuit model, ECM)是目前较为常见的电池模型。EM基于电化学机理<sup>[7]</sup>, 考虑了电极多孔结构的影响。但EM由于计算量大、耦合关系复杂, 不适合计算能力有限的BMS场景。ECM以其简单的电路网络结构和明确的物理含义, 依靠电路元件来模拟电池的内部特性, 在计算的复

**基金项目:** 国家自然科学基金项目资助(51907136); 四川省自然科学基金项目资助(2024NSFSC0145); 四川轻化工大学科研创新团队计划项目资助(SUSE652A004)

杂性和准确性之间有良好的平衡。常用的等效电路模型有 Rint 模型、戴维南模型、PNGV 模型、RC 网络模型等<sup>[8-9]</sup>。其中 RC 网络模型能准确地模拟电池内部的工作特性, RC 阶数越大, 模拟效果越好, 但也增加了建模的复杂性, 降低了模型参数辨识的实时性<sup>[10]</sup>。DP 模型<sup>[11]</sup>采用两个 RC 网络分别模拟电池内部的电荷转移与电荷扩散现象, 从而能够很好地兼顾电池的动态特性与静态特性, 且此模型具备优秀的模拟效果与较适中的建模复杂性, 所以本文选择 DP 模型作为研究对象。

电池 SOC、老化和环境温度等工作环境<sup>[12-13]</sup>会改变模型参数, 这给电池模型参数辨识带来了挑战, 因此如何精确地辨识成为当前研究的热点。在线参数辨识<sup>[14]</sup>是一种有效的解决方法, 它在较短周期内利用智能算法辨识模型参数。在线参数辨识是实时更新的, 因此可在很大程度上降低工作环境的影响。电池模型参数辨识的另一个挑战是存在多时间尺度效应<sup>[15]</sup>, 电池内部存在电荷转移与扩散现象, 根据电化学理论, 电荷转移现象通常在较短的时间尺度上进行, 而电荷扩散现象的时间尺度较长<sup>[16]</sup>。由于系统刚度高、数据存储分辨率低, 同一时间尺度估计所有模型参数的最小二乘(least square, LS)算法可能出现数值问题, 容易由于交叉干扰导致识别结果不准确或不合理。因此, 为了更准确地建立锂电池模型, 有必要区分不同时间尺度的模型参数。文献[17]将电池模型划分为快动态与慢动态, 提出了一种新的解耦加权递归最小二乘参数辨识算法, 结果显示该方法在建模和辨识精度方面优于传统 LS 算法。但是该方法快、慢动态采用相同辨识算法容易造成互相干扰, 并且严重依赖于电池 SOC 与开路电压(open circuit voltage, OCV)的关系。文献[18]提出了一种将递推最小二乘与扩展卡尔曼滤波相结合的参数辨识算法, 分别用于获取快、慢动态参数。实验结果表明, 该方法有效地提高了辨识精度, 但快、慢动态之间的耦合关系并不合理。文献[16]在文献[18]的基础上进行改进, 将 OCV 视为慢动态部分的一个分量与其他电路零件一同辨识。虽然避免了 SOC-OCV 误差干扰, 但并未将辨识出的参数代入模型中进一步估计 SOC, 缺乏 SOC 验证分析。

针对以上问题, 本文从锂电池多时间尺度效应出发, 提出了基于 AFFRLS 与 AEKF 的联合参数辨识算法, 避免了同一时间尺度下最小二乘法辨识过程中的交叉干扰。首先通过实验获取锂电池在不同工况与温度下的充放电特性数据, 然后建立电池双尺度 DP 模型, 基于多时间尺度联合参数辨识算法分别求解快动态与慢动态参数, 最后将辨识参数代

入模型估计电池 SOC, 并在不同工况与温度下将结果与未考虑多时间尺度的方法进行对比分析。

## 1 电池模型及实验平台

### 1.1 双尺度 DP 模型

本文对 DP 模型不同时间尺度的模型参数进行划分, 建立了双尺度 DP 模型, 如图 1 所示。

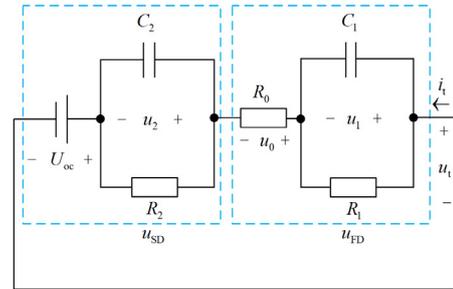


图 1 双尺度 DP 模型

Fig. 1 Dual scale DP model

图 1 中:  $U_{oc}$  表示开路电压;  $u_t$ 、 $i_t$  分别表示端电压和端电流;  $R_0$  表示欧姆内阻;  $C_1$ 、 $C_2$  分别表示电池极化电容;  $R_1$ 、 $R_2$  分别表示电池极化内阻;  $u_0$ 、 $u_1$ 、 $u_2$  分别表示  $R_0$ 、RC 网络 1 与 RC 网络 2 上的电压;  $u_{FD}$  表示快动态总电压;  $u_{SD}$  表示慢动态总电压。

该电池模型中,  $R_0$  用来模拟电池内部的电阻特性,  $R_1$ 、 $C_1$  用来模拟由于电荷转移现象而引起的电压快速改变,  $R_2$ 、 $C_2$  用来模拟由于电荷扩散现象而引起的电压缓慢改变。由于 RC 网络 1 上的时间常数  $\tau_1$  通常很小, 因此将 RC 网络 1 划分到快动态。RC 网络 2 上的时间常数  $\tau_2$  较大, 因此将 RC 网络 2 划分到慢动态。电池工作过程中  $U_{oc}$  变化相对缓和, 因此把它划分到慢动态。出于多时间尺度考虑, 本文将该 DP 模型根据其不同的动态过程分为快、慢动态两个时间尺度。

### 1.2 实验平台

为了验证本文提出的方法, 需要提前获取锂电池特性实验数据。为此, 搭建了如图 2 所示的实验测试平台, 主要包括额定容量为 25 Ah 的锂电池、用于锂电池充电或放电的电池循环仪、用于储存数据与编写程序的计算机、可模拟不同环境温度的温控室以及若干数据线。锂电池基本参数如表 1 所示。基于实验平台, 完成了容量标定实验、SOC-OCV 测试以及动态应力(dynamic stress test, DST)、城市道路循环(urban dynamometer driving schedule, UDDS)两个经典工况测试循环, 为后续研究做好准备。低

温加热技术<sup>[19]</sup>避免了电池在 0 °C 以下工作, 故所有电池特性实验都在 10 °C、25 °C、40 °C 这 3 个温度下进行。后续的参数辨识与 SOC 估计计算过程都是通过 Matlab/Simulink 平台实现的。

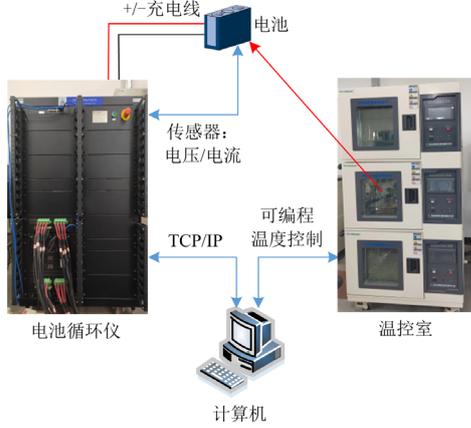


图 2 电池特性实验测试平台

Fig. 2 Experimental test platform for battery characterization

表 1 锂电池基本参数

Table 1 Basic parameters of lithium battery

种类	LiNiMnCoO2
额定容量	25 Ah
上截止电压	4.2 V
下截止电压	2.5 V

## 2 参数辨识

### 2.1 算法整体结构

基于锂电池内部的多时间尺度特性, 本文提出了考虑锂离子电池多时间尺度效应的 AFFRLS-AEKF 联合参数辨识方法。利用 AFFRLS 与 AEKF 算法分别辨识快动态与慢动态参数。

通过前面的分析, 快动态部分包括了欧姆内阻和电荷转移过程造成的影响, 即  $R_0$ 、 $R_1$ 、 $C_1$ 。带有遗忘因子的递推最小二乘算法是一种优秀的模型参数辨识和数据挖掘方法, 其通过定期的参数校正和更新可以很好地克服模型参数的不确定性, 从而精确捕捉系统状态, 并且通过对测量数据置入遗忘因子来减少老数据的权重, 为补充新数据的信息创造条件。本文在常规 FFRLS 方法的基础上, 根据不同工况的电流、电压变化和噪声特性, 利用自适应遗忘因子(adaptive forgetting factor, AFF)优化系统参数。

慢动态部分包括了开路电压与电荷扩散过程造成的影响, 即  $U_{oc}$ 、 $R_2$ 、 $C_2$ 。时间常数  $\tau_2$  较大, 故极化电压  $u_2$  变化缓慢。由于模型特性的影响, 识别慢动态参数时, 算法可能将  $u_2$  识别为开路电压的一

部分, 造成识别结果不准确。与 AFFRLS 算法相比, AEKF 算法可以根据相邻时刻状态转移变化规律来改善这种情况。因此, 本文使用 AEKF 算法识别慢动态参数。AEKF 算法结合了扩展卡尔曼滤波和自适应滤波的优点, 相比 EKF 算法能够在识别过程中对噪声的统计特性进行持续自适应估计和校正<sup>[20]</sup>, 提高系统辨识的精度与鲁棒性; 相比无迹卡尔曼滤波算法可以有效减少系统计算负担, 并且它的噪声自适应能力更加符合参数时变的系统。

参数辨识算法整体结构如图 3 所示, 由 I. 快动态参数辨识、II. 慢动态参数辨识、III. 完整参数辨识 3 部分组成。I 中, 在每个采样周期内, 将测量电流与电压输入到电池模型中, 利用 AFFRLS 算法辨识出快动态参数。慢动态参数辨识则在子算法 II 中实现, 快动态的精确识别可计算出准确的耦合因子, 然后将其作为输入信息传递到慢动态部分, 紧接着利用 AEKF 算法辨识参数, 最后将所有参数输入到电池模型中即可完成当前周期内的参数辨识。III 中, 得到完整模型参数并利用它进一步预测电池 SOC。需要强调的是, 快、慢动态参数辨识都是在完整的 DP 模型中进行的。

### 2.2 子算法结构

#### 2.2.1 快动态参数辨识算法设计

快动态部分采用 AFFRLS 算法在线辨识参数, 算法具体实现过程如下。根据图 3, 端电压  $u_1(s)$  可表示为

$$u_1(s) = i_1(s) \cdot \left( R_0 + \frac{R_1}{1 + R_1 C_1 s} \right) + u_{SD}(s) \quad (1)$$

式中,  $s$  表示复频率。

将系统传递函数  $G(s)$  定义为

$$G(s) = \frac{u_{FD}(s)}{i_1(s)} = \frac{u_1(s) - u_{SD}(s)}{i_1(s)} = R_0 + \frac{R_1}{1 + R_1 C_1 s} \quad (2)$$

采用式(3)的变换法将系统从  $s$  平面映射到  $z$  平面。

$$s = \frac{1 - z^{-1}}{T_s} \quad (3)$$

$$G(z) = \frac{u_1(z) - u_{SD}(z)}{i_1(z)} = \frac{c_2 + c_3 z^{-1}}{1 - c_1 z^{-1}} \quad (4)$$

式中:  $T_s$  为系统的采样间隔时间;  $c_1$ 、 $c_2$ 、 $c_3$  均为与模型参数相关的系数, 其表达式如式(5)所示。

$$\begin{cases} c_1 = \frac{\tau_1}{T_s + \tau_1} \\ c_2 = R_0 + \frac{T_s R_1}{T_s + \tau_1} \\ c_3 = \frac{-R_0 \tau_1}{T_s + \tau_1} \end{cases} \quad (5)$$

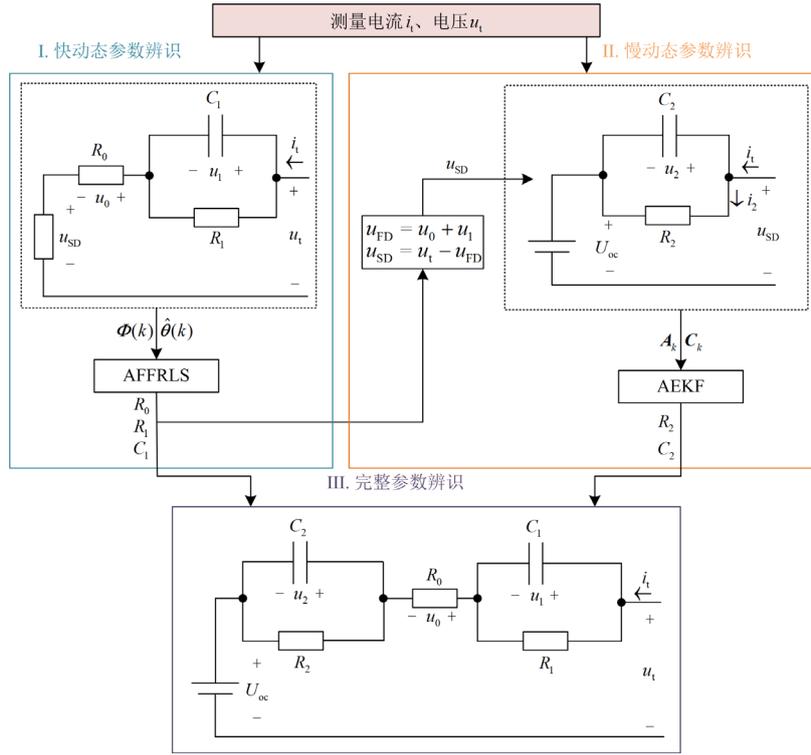


图3 参数辨识算法整体结构

Fig. 3 Overall structure of the parameter identification algorithm

式中，时间常数  $\tau_1 = R_1 C_1$ 。

将式(4)转化到离散化时域并化简可得到

$$u_1(k) = c_1 u_1(k-1) + c_2 i_1(k) + c_3 i_1(k-1) + u_{SD}(k) - c_1 u_{SD}(k-1) \quad (6)$$

式中， $k$  表示时刻。为了便于计算，引入系数  $c_4$ ，如式(7)所示。

$$c_4 = u_{SD}(k) - c_1 u_{SD}(k-1) \quad (7)$$

结合式(6)和式(7)，定义  $k$  时刻系统的数据矩阵

$\Phi(k)$  和参数矩阵  $\hat{\theta}(k)$  为

$$\begin{cases} \Phi(k) = [u_1(k-1), i_1(k), i_1(k-1), 1] \\ \hat{\theta}(k) = [c_1, c_2, c_3, c_4]^T \end{cases} \quad (8)$$

最后，整个系统的输出  $y(k)$  可表示为

$$y(k) = u_1(k) = \Phi(k) \cdot \hat{\theta}(k) \quad (9)$$

为了降低误差协方差矩阵中旧数据的占有量，增强算法跟踪、修正的能力，FFRLS 算法引入遗忘因子  $\mu$ ，其迭代过程如式(10)所示。

$$\begin{cases} \mathbf{K}_1(k) = \mathbf{P}_1(k-1) \Phi(k)^T [\Phi(k) \mathbf{P}_1(k-1) \Phi(k)^T + \mu]^{-1} \\ \hat{\theta}(k) = \hat{\theta}(k-1) + \mathbf{K}_1(k) [y(k) - \Phi(k) \hat{\theta}(k-1)] \\ \mathbf{P}_1(k) = \frac{1}{\mu} [\mathbf{I} - \mathbf{K}_1(k) \Phi(k)] \mathbf{P}_1(k-1) \end{cases} \quad (10)$$

式中： $\mathbf{K}_1(k)$  和  $\mathbf{P}_1(k)$  分别为  $k$  时刻 AFFRLS 算法的增益矩阵和状态估计值的误差协方差矩阵； $\mathbf{I}$  为单位矩阵。

需要指出的是， $0 < \mu < 1$ ， $\mu$  越大，算法的跟踪能力就越差，但算法精度更稳定。而当  $\mu$  越小，新的数据对参数的校正效果更好，算法的跟踪校正效果也更好，但是可能会造成算法的波动。所以为了获得准确且误差小的估计参数集，实时最优  $\mu$  是至关重要的。因此，本文采用可以实时迭代和校正的自适应遗忘因子。其迭代校正过程为

$$E_1(k) = u_1(k) - \Phi(k) \hat{\theta}(k-1) \quad (11)$$

$$\mu(k) = 1 - \frac{E_1^2(k)}{1 + \mathbf{K}_1(k)^T \mathbf{P}_1(k) \mathbf{K}_1(k)} \quad (12)$$

式中， $E_1(k)$  为快动态部分的电压新息。

结合式(10)一式(12)不难分析出，当系统发生快速变化时，新息  $E_1(k)$  增大而  $\mu(k)$  迅速迭代减小，使得旧的数据被快速遗忘，同时新数据权重提高以建立新的系统模型，从而达到迅速追踪系统最新状态的效果。而当新的数据被逐渐输入时，系统将趋于稳定状态，在这一过程中，系统模型会出现收敛现象。新息  $E_1(k)$  会逐渐降低从而使  $\mu(k)$  在迭代过程中慢慢提高，这使得被遗忘的历史数据减少，系统有效数据长度得以增加，参数估计的精度更稳定。

AFFRLS 算法计算出参数矩阵后, 根据式(13)可求解出模型参数。

$$\begin{cases} \tau_1 = \frac{c_1 T_s}{1 - c_1} \\ R_0 = \frac{-c_3 (T_s + \tau_1)}{\tau_1} \\ R_1 = \frac{(c_2 - R_0)(T_s + \tau_1)}{T_s} \\ C_1 = \frac{\tau_1}{R_1} \end{cases} \quad (13)$$

### 2.2.2 慢动态参数辨识算法设计

如当前时刻快动态部分被精确识别, 则可根据识别结果准确计算出慢动态电压  $u_{SD}$ 。本文将  $u_{SD}$  作为慢动态与快动态的耦合因子, 后者的高精度识别可为前者传递输入信息。具体实施过程如式(14)所示。

$$\begin{cases} u_0(k) = R_0(k) \cdot i_1(k) \\ u_1(k) = e^{\frac{-T_s}{R_1(k-1)C_1(k-1)}} \cdot u_1(k-1) + \\ \quad R_1(k-1) \cdot i_1(k-1) \cdot (1 - e^{\frac{-T_s}{R_1(k-1)C_1(k-1)}}) \\ u_{FD}(k) = u_0(k) + u_1(k) \\ u_{SD}(k) = u_1(k) - u_{FD}(k) \end{cases} \quad (14)$$

通过式(14)可看出, 如果  $R_0$ 、 $R_1$ 、 $C_1$  的精度得到保证, 那么计算出的  $u_{SD}$  自然也无限逼近其真实值, 可作为慢动态部分的输入。部分学者将 SOC-OCV 曲线引入到参数辨识, 把拟合出的 OCV 作为一个已知条件。然而, 实验误差、计算误差、工作温度等因素会影响 OCV 的准确性, 并且这种影响是不可避免的。为了最大程度地减小辨识误差, 本文将 OCV 视为模型中未知的一部分, 将其与其他慢动态电路零件一同辨识。

扩展卡尔曼滤波算法(extended Kalman filter, EKF)在电池模型参数辨识领域被研究<sup>[21]</sup>证明是有效的, 但它依赖于对过程噪声与测量噪声协方差矩阵的良好估计, 而自适应扩展卡尔曼滤波算法利用滤波器的创新序列对算法进行了进一步创新, 增强了算法的自适应性, 可在一定程度上改善 EKF 的劣势。具体设计过程如下。

由电池模型可得到  $u_2$  的表达式, 如式(15)所示。

$$u_2(k+1) = e^{\frac{-T_s}{R_2(k)C_2(k)}} \cdot u_2(k) + R_2(k) \cdot i_1(k) \cdot (1 - e^{\frac{-T_s}{R_2(k)C_2(k)}}) \quad (15)$$

将式(15)两边同时除以  $R_2$ , 可得到  $i_2$ , 如式(16)所示。

$$i_2(k+1) = e^{\frac{-T_s}{R_2(k)C_2(k)}} \cdot i_2(k) + i_1(k) \cdot (1 - e^{\frac{-T_s}{R_2(k)C_2(k)}}) \quad (16)$$

将需要辨识的参数  $i_2$ 、 $U_{oc}$ 、 $R_2$ 、 $C_2$  设置为状态变量, 测量电流  $i_1$  作为系统输入。在电池实际工作过程中, 模型参数在单位采样时间内的变化微小, 因此可以假设

$$\begin{cases} U_{oc}(k+1) = U_{oc}(k) \\ R_2(k+1) = R_2(k) \\ C_2(k+1) = C_2(k) \end{cases} \quad (17)$$

将式(16)与式(17)联立, 可得到系统的状态方程, 如式(18)所示。

$$f(\mathbf{x}_k, \mathbf{v}_k) = [i_2(k+1) \ U_{oc}(k+1) \ R_2(k+1) \ C_2(k+1)]^T = \begin{bmatrix} e^{\frac{-T_s}{R_2(k)C_2(k)}} & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} i_2(k) \\ U_{oc}(k) \\ R_2(k) \\ C_2(k) \end{bmatrix} + \begin{bmatrix} 1 - e^{\frac{-T_s}{R_2(k)C_2(k)}} \\ 0 \\ 0 \\ 0 \end{bmatrix} \cdot i_1(k) \quad (18)$$

式中:  $\mathbf{x}_k$  为系统的状态向量;  $\mathbf{v}_k$  为系统的输入。

式(18)对状态向量求偏导可得到系统的状态转移矩阵  $A_k$ , 如式(19)所示。

$$A_k = \frac{\partial f(\mathbf{x}_k, \mathbf{v}_k)}{\partial \mathbf{x}_k} \Big|_{\mathbf{x}_k = \hat{\mathbf{x}}_k^+} = \begin{bmatrix} \frac{\partial f_1}{\partial i_2(k)} & 0 & \frac{\partial f_1}{\partial R_2(k)} & \frac{\partial f_1}{\partial C_2(k)} \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (19)$$

式中,  $\hat{\mathbf{x}}_k^+$  表示系统后验估计。

$$\begin{cases} \frac{\partial f_1}{\partial i_2(k)} = e^{\frac{-T_s}{R_2(k)C_2(k)}} \\ \frac{\partial f_1}{\partial R_2(k)} = e^{\frac{-T_s}{R_2(k)C_2(k)}} \cdot \frac{T_s}{R_2(k)C_2(k)} \cdot (i_2(k) - i_1(k)) \\ \frac{\partial f_1}{\partial C_2(k)} = e^{\frac{-T_s}{R_2(k)C_2(k)}} \cdot \frac{T_s}{R_2(k)C_2(k)} \cdot (i_2(k) - i_1(k)) \end{cases} \quad (20)$$

定义  $u_{SD}$  为模型输出, 则系统的观测方程为

$$h(\mathbf{x}_k, \mathbf{v}_k) = u_{SD}(k) = U_{oc}(k) + R_2(k) \cdot i_2(k) \quad (21)$$

式(21)对状态向量求偏导即是系统观测矩阵  $C_k$ , 如式(22)所示。

$$C_k = \frac{\partial h(\mathbf{x}_k, \mathbf{v}_k)}{\partial \mathbf{x}_k} \Big|_{\mathbf{x}_k = \hat{\mathbf{x}}_k^-} = [R_2(k) \ 1 \ i_2(k) \ 0] \quad (22)$$

式中,  $\hat{\mathbf{x}}_k^-$  表示系统先验估计。

噪声信息协方差匹配算法可以使滤波算法中的噪声统计特性随着估计结果的变化而自适应更新,

增强算法的鲁棒性。AEKF 噪声信息协方差匹配算法的具体实施步骤如下所述。

由开窗估计原理得到的电压新息实时估计协方差函数, 如式(23)所示。

$$H(k) = \frac{1}{M} \sum_{i=k-M+1}^k E_2(k) E_2^T(k) \quad (23)$$

式中:  $M$  为开窗大小;  $E_2(k)$  为慢动态部分的电压新息。

测量噪声协方差矩阵更新公式为

$$N(k) = (H(k) - C_k P_2^-(k) C_k^T) \quad (24)$$

式中,  $P_2^-(k)$  表示 AEKF 算法预估的误差协方差矩阵。

系统噪声协方差矩阵更新公式为

$$Q(k) = K_2(k) H(k) K_2^T(k) \quad (25)$$

式中,  $K_2(k)$  为 AEKF 算法的增益矩阵。

状态估计误差协方差矩阵更新公式为

$$P_2^+(k) = (I - K_2(k) C_k) P_2^-(k) \quad (26)$$

### 3 验证与分析

#### 3.1 参数辨识结果分析

##### 3.1.1 参数辨识结果

参数辨识结果如图 4 所示。由图 4 可以看出, 辨识出的每个参数都在小范围内波动, 说明所提辨识算法在每个周期内辨识出的参数具有高度一致性。内阻  $R_0$ 、 $R_1$ 、 $R_2$  随着时间呈现出逐渐增大的趋势, 这与大量的研究结果相似, 即内阻随着 SOC 的降低而增加<sup>[22]</sup>。此外, 时间常数  $\tau_2$  ( $\tau_2 = R_2 C_2$ ) 大约是  $\tau_1$  ( $\tau_1 = R_1 C_1$ ) 的 21 倍<sup>[21]</sup>。

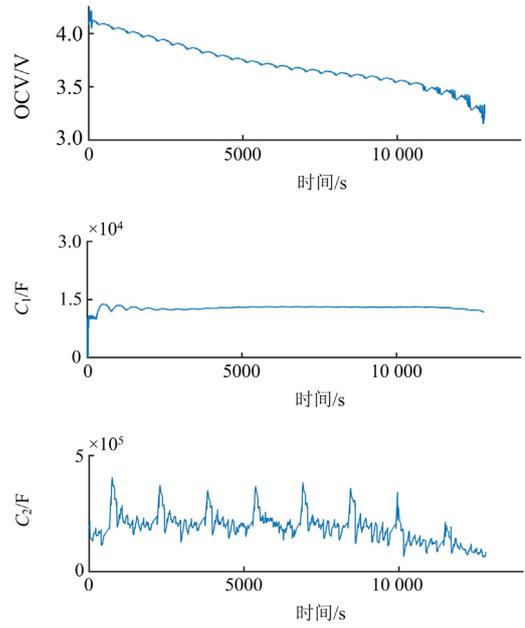
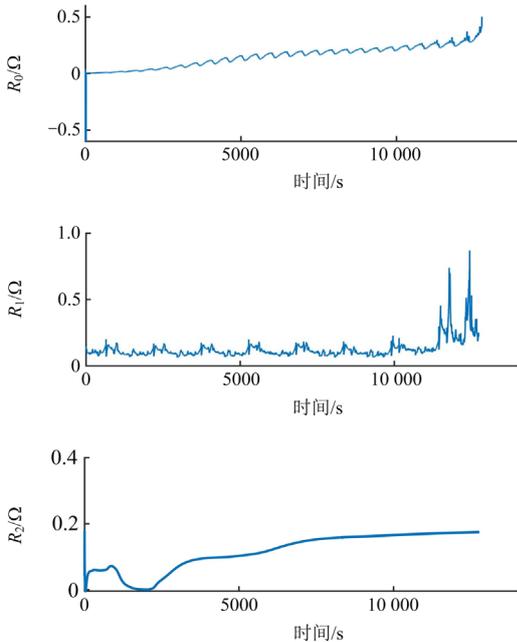


图 4 参数辨识结果

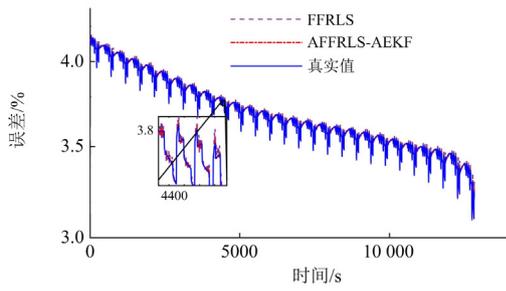
Fig. 4 Parameter identification results

##### 3.1.2 端电压验证

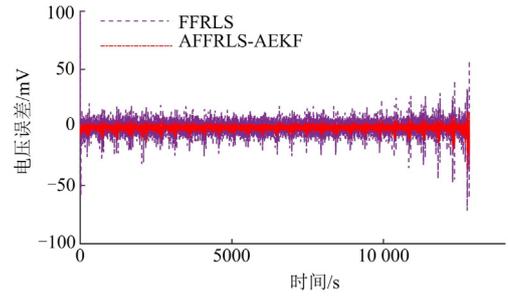
考虑到实际驾驶情况的高度复杂性, 电流、电压等数据可能在 1 s 内急剧变化, 并且变化方向是不可预知的, 较长的辨识周期将不能准确地反映慢动态部分的电流、电压变化。因此, 慢动态参数的辨识周期设置为与快动态一致, 均为 1 s。通过比较端电压估计值与实际测量值的误差, 可以分析识别模型的准确性。电动汽车行驶路况与环境温度多变, 导致锂电池的实际工作状态也随之变化, 因此在 DST 与 UDDS 工况的 10 °C、25 °C 与 40 °C 下验证分析。

本研究在验证过程中将快动态与慢动态参数辨识算法对调, 结果显示虽然两种组合算法的收敛性、计算效率相差不大, 但本文所提的 AFFRLS-AEKF 联合参数辨识算法端电压误差更小, 说明 AFFRLS 算法与 AEKF 算法分别辨识快动态与慢动态参数的组合时更具优势。

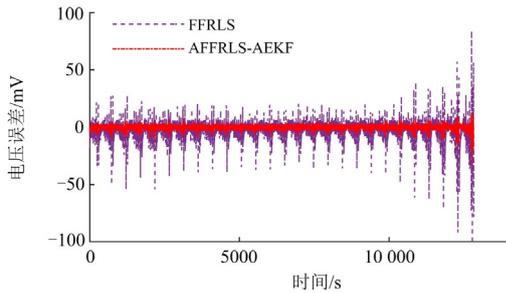
为了验证所提算法的可行性, 在 DST 工况下将 AFFRLS-AEKF 多时间尺度参数辨识算法与同一时间尺度的 FFRLS 算法进行比较, 需要说明的是此处对比的电压是 DP 模型的端电压, 结果如图 5(a)~图 5(e)所示。由图 5 可看出, 两种算法辨识过程中前期误差波动都较平稳, 随着电池电量下降, 后期误差波动都有一定程度增加。但本文所提多时间尺度参数辨识算法的端电压误差更小, 并且在低电量状态下 ( $SOC < 0.2$ ), 也能更准确地跟踪参数的实时



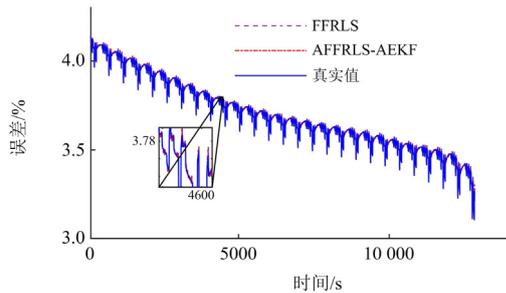
(a) 10 °C 端电压对比



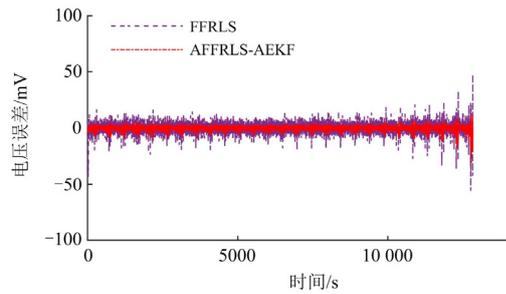
(f) 40 °C 端电压误差



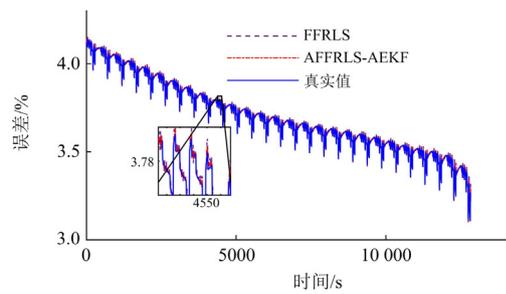
(b) 10 °C 端电压误差



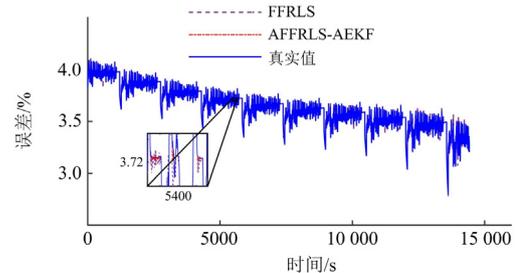
(c) 25 °C 端电压对比



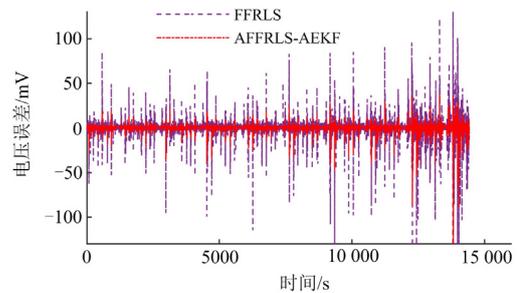
(d) 25 °C 端电压误差



(e) 40 °C 端电压对比



(a) 10 °C 端电压对比



(b) 10 °C 端电压误差

图 5 DST 端电压验证结果

Fig. 5 DST terminal voltage verification results

变化, 实现对模型的准确识别。由此可见, 从多时间尺度的角度将快、慢动态分别辨识的方法可以有效避免交叉干扰, 提高模型参数辨识的准确性。

为了验证所提算法对不同工况的适应性, 在 UDSS 工况 3 个温度下将两种算法进行对比分析, 结果如图 6(a) 一图 6(e) 所示。从图 6 可知, 在 UDSS 的 3 个温度下本文所提算法仍能始终保持更准确的辨识结果。FFRLS 由于没有考虑系统实际特性, 并且需要手动调整参数, 过大或过小都会影响算法性能, 因而在具有时变参数的系统中, 不可能准确地实现系统自适应辨识过程, 因而在 UDSS 整个辨识过程误差波动都较大。本文所提算法在系统环境多变的情况下能够根据系统特性实时优化与更新遗忘因子和协方差矩阵, 从而有效减小算法波动并且更准确地跟踪到实际端电压, 整体辨识效果更好。

端电压均方根误差 (root mean square error, RMSE) 反映了估计值与真实值之间的平均误差, 通常采用端

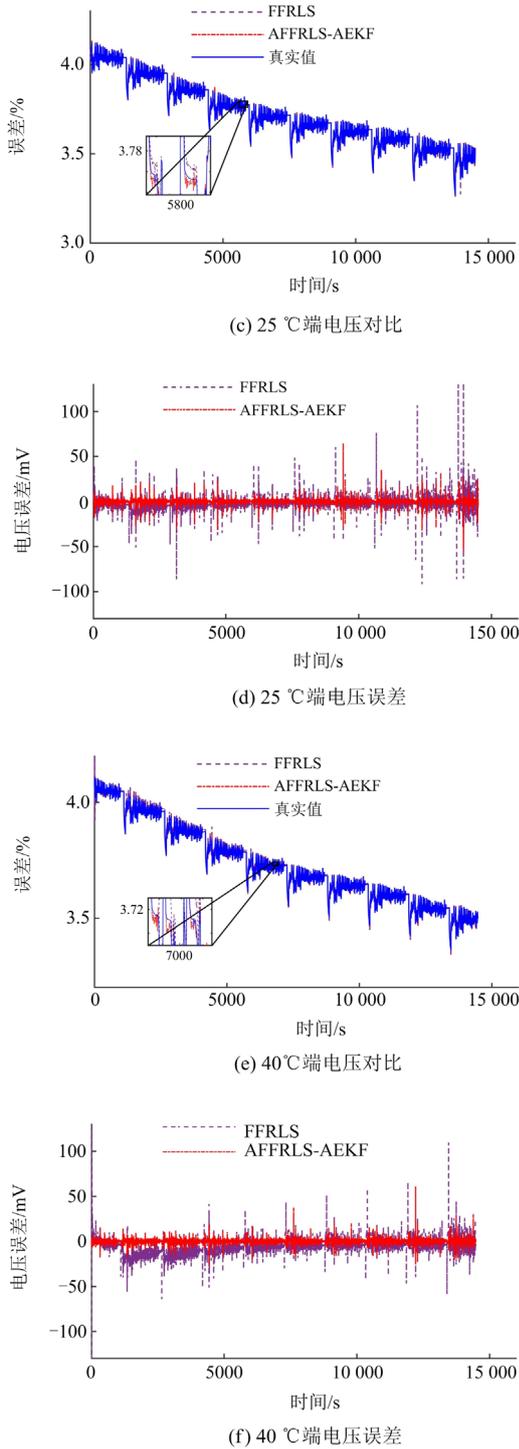


图 6 UDDS 端电压验证结果

Fig. 6 UDDS terminal voltage verification results

电压的均方根误差作为评价算法整体辨识精度的标准，其值越小说明算法越准确，均方根误差定义为

$$e_{\text{RMSE}} = \sqrt{\frac{\sum_{k=1}^n (y(k) - \hat{y}(k))^2}{n}} \quad (27)$$

式中： $y(k)$  表示实际值； $\hat{y}(k)$  表示估计值。

表 2 给出了两种算法在 3 个温度下的端电压 RMSE。以 25 °C 下的结果为例，FFRLS 算法在 DST 与 UDDS 工况下的 RMSE 分别达到了 5.470 mV 和 4.353 mV，而 AFFRLS-AEKF 算法在以上两种工况下的 RMSE 分别低至 2.882 mV 和 2.328 mV，相比 FFRLS 算法均方根误差大幅降低。由此可见，本文提出的 AFFRLS-AEKF 多时间尺度辨识算法在不同工况与温度下具有更高的辨识精度与更强的鲁棒性。

在验证过程中发现 10 °C 与 40 °C 下的 RMSE 相比 25 °C 略有增加，这是因为电池的內部化学性质不稳定。当工作温度较低时，电池内部化学反应速率下降<sup>[23]</sup>，导致电荷转移与扩散的速度也变缓慢，而当工作温度较高时，则速度变快。温度较高或较低都会增加参数识别的难度，影响辨识的准确性，导致终端电压的 RMSE 增加。可见，本文验证结果与理论分析结果一致。从表 2 数据来看，即使在 10 °C 与 40 °C 下本文所提算法也具有更好的性能，最大 RMSE 未超过 3.5 mV。

表 2 电压均方根误差分析

Table 2 Voltage root mean square error analysis

工况	算法	RMSE/mV	RMSE/mV	RMSE/mV
		(10 °C)	(25 °C)	(40 °C)
DST	FFRLS	6.932	5.470	6.109
	AFFRLS-AEKF	3.199	2.882	3.329
UDDS	FFRLS	6.975	4.353	4.802
	AFFRLS-AEKF	2.594	2.328	2.626

### 3.2 SOC 估计结果分析

为了进一步验证多时间尺度参数辨识算法的准确性，将两种算法辨识出的参数代入电池模型进一步估计 SOC。H 无穷滤波(H-infinity filter, HIF)算法遵循博弈论的思想<sup>[10]</sup>，利用与对手博弈的过程尽可能地降低状态的最大估计误差，使得整个系统相互协调达到均衡状态，能显著提高估计的稳定性与鲁棒性，最大程度地降低干扰对输出的影响。所以本节基于两种辨识参数利用 HIF 估计 SOC。

结合图 7 和表 3 可以看出，在 DST 工况 3 个温度下的前期验证中，两种算法估计出的 SOC 都接近真实值，最大误差不超过 0.45%。随着电池放电，两种算法的估计误差都有一定程度的增加，这可能是由于电量降低导致电池内部化学性质不稳定，当电量接近耗尽时，这种现象更为明显。但基于 AFFRLS-AEKF 辨识参数的误差明显更小，3 个温度下的最大误差未超过 3%，SOC 估计曲线也更加平滑和稳定。根据 3.1 节提到的原因，10 °C 与 40 °C 下的误差相比 25 °C 下的误差略有增加。从 SOC 均方根误差来

看, 本文所提算法具有更高的准确率。图 8 展示了 UDDS 工况 3 个温度下的 SOC 估计误差, 与 DST 工况下的结果类似, 前期两种算法都能准确地估计出 SOC, 并且误差随着电池电量的下降而增加。在低电量状态下, AFFRLS-AEKF-HIF 仍能保持较高的精度; 在 10 °C 与 40 °C 下相比 FFRLS-HIF 具有明显优势。

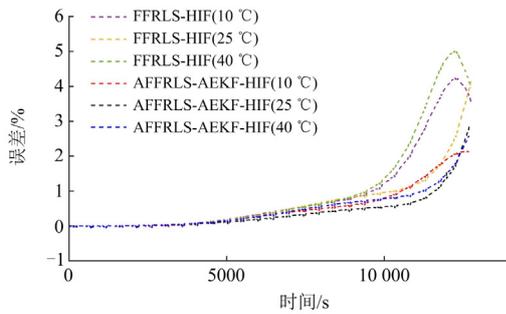


图 7 DST 工况 SOC 估计误差

Fig. 7 SOC estimation error for DST condition

表 3 SOC 均方根误差分析

Table 3 SOC root mean square error analysis

工况	算法	RMSE/%	RMSE/%	RMSE/%
		(10 °C)	(25 °C)	(40 °C)
DST	FFRLS-HIF	1.824	1.143	2.118
	AFFRLS-AEKF-HIF	0.874	0.722	0.806
UDDS	FFRLS-HIF	1.253	1.073	1.198
	AFFRLS-AEKF-HIF	0.829	0.724	0.799

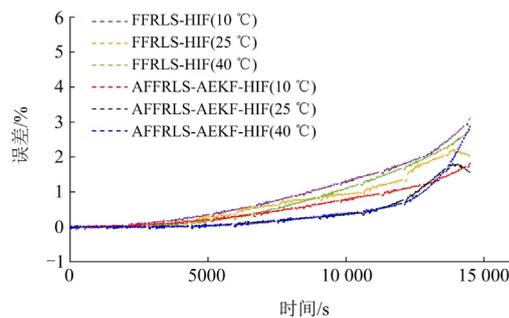


图 8 UDDS 工况 SOC 估计误差

Fig. 8 SOC estimation error for UDDS condition

综上所述, 在不同工况与温度下基于 AFFRLS-AEKF 辨识参数估计出的 SOC 远比基于 FFRLS 的准确, 也从侧面印证了本文所提多时间尺度参数辨识算法具备更高的精度与鲁棒性, 可以避免传统最小二乘法辨识过程中的交叉干扰。

## 4 结论

为了提高锂电池参数辨识与 SOC 估计的准确

性, 本文从锂电池多时间尺度效应出发, 提出了一种基于 AFFRLS 与 AEKF 的联合参数辨识算法, 并结合辨识参数进一步估计电池 SOC。得出以下结论:

1) 为了降低多时间尺度效应带来的影响, 需将电池 DP 模型划分为快动态与慢动态两部分, 采用 AFFRLS-AEKF 联合的参数辨识算法分别辨识快动态与慢动态参数可以避免传统最小二乘法辨识过程中的交叉干扰。

2) 本文提出的多时间尺度参数辨识算法在 DST 与 UDDS 工况的 10 °C、25 °C、40 °C 下始终具有较好的辨识精度与鲁棒性, 可根据系统实时特性自适应迭代更新。

3) 基于 AFFRLS-AEKF 辨识参数得到了更高精度的 SOC, 进一步印证了所提算法的有效性。

## 参考文献

- [1] 郭文佳. 碳达峰: 新能源汽车做先锋[N]. 新能源汽车报, 2021-11-01(010).
- [2] WANG Dongqing, YANG Yan, GU Tianyu. A hierarchical adaptive extended Kalman filter algorithm for lithium-ion battery state of charge estimation[J]. Journal of Energy Storage, 2023, 62: 106831.
- [3] 任碧莹, 孙佳, 孙向东, 等. 提高串联锂电池 SOC 在线估计快速性的简化二阶模型[J]. 电力系统保护与控制, 2022, 50(22): 110-118.  
REN Biying, SUN Jia, SUN Xiangdong, et al. A simplified second-order model for improving the speed of on-line state of charge estimation of series lithium-ion batteries[J]. Power System Protection and Control, 2022, 50(22): 110-118.
- [4] 寇发荣, 王甜甜, 王思俊, 等. 基于 ABC-RFEKF 算法的锂电池 SOC 估计[J]. 电力系统保护与控制, 2022, 50(4): 163-171.  
KOU Farong, WANG Tiantian, WANG Sijun, et al. Lithium battery SOC estimation based on an ABC-RFEKF algorithm[J]. Power System Protection and Control, 2022, 50(4): 163-171.
- [5] TANG Ruoli, ZHANG Shihan, ZHANG Shangyu, et al. Model parameter identification for lithium-ion batteries using adaptive multi-context cooperatively co-evolutionary parallel differential evolution algorithm[J]. Journal of Energy Storage, 2023, 58: 106432.
- [6] LUO Jiayi, PENG Jiakun, HE Hongwen. Lithium-ion battery SOC estimation study based on cubature Kalman filter[J]. Energy Procedia, 2019, 158: 3421-3426.
- [7] LI Liuying, REN Yaxin, O'REGAN K, et al. Lithium-ion battery cathode and anode potential observer based on reduced-order electrochemical single particle model[J].

- Journal of Energy Storage, 2021, 44: 103324.
- [8] 罗勇, 祁朋伟, 阚英哲, 等. 基于模拟退火算法的锂电池模型参数辨识[J]. 汽车工程, 2018, 40(12): 1418-1425.  
LUO Yong, QI Pengwei, KAN Yingzhe, et al. Parameter identification of lithium battery model based on simulated annealing algorithm[J]. Automotive Engineering, 2018, 40(12): 1418-1425.
- [9] 陆鹏, 付华, 卢万杰, 等. 基于 HCOAG 算法优化 KELM 的全钒液流电池 SOC 估计[J]. 电力系统保护与控制, 2023, 51(7): 135-145.  
LU Peng, FU Hua, LU Wanjie, et al. State of charge estimation for a vanadium redox flow battery based on a kernel extreme learning machine optimized by an improved coyote and grey wolf algorithm[J]. Power System Protection and Control, 2023, 51(7): 135-145.
- [10] 熊瑞. 动力电池管理系统核心算法[M]. 北京: 机械工业出版社, 2021.
- [11] HAO Xueyi, WANG Shunli, FAN Yongcun. An improved forgetting factor recursive least square and unscented particle filtering algorithm for accurate lithium-ion battery state of charge estimation[J]. Journal of Energy Storage, 2023, 59: 106478.
- [12] ZHANG Chen, LI Kang, DENG Jin, et al. Improved real time state-of-charge estimation of LiFePO<sub>4</sub> battery based on a novel thermoelectric model[J]. IEEE Transactions on Industrial Electronics, 2017, 64(1): 654-663.
- [13] TRAN M K, MATHEW M, JANHUNEN S, et al. A comprehensive equivalent circuit model for lithium-ion batteries, incorporating the effects of state of health, state of charge, and temperature on model parameters[J]. Journal of Energy Storage, 2021, 43: 103252.
- [14] LI Zhirun, XIONG Rui, HE Hongwen. An improved battery on-line parameter identification and state-of-charge determining method[J]. Energy Procedia, 2016, 103: 381-386.
- [15] SHI Haotian, WANG Shunli, LIANG Jianhong, et al. Multi-time scale identification of key kinetic processes for lithium-ion batteries considering variable characteristic frequency[J]. Journal of Energy Chemistry, 2023, 82: 521-536.
- [16] YANG Zhao, WANG Xuemei. An improved parameter identification method considering multi-timescale characteristics of lithium-ion batteries[J]. Journal of Energy Storage, 2023, 59: 106462.
- [17] ZHANG Cheng, ALLAFI W, DINH Q, et al. Online estimation of battery equivalent circuit model parameters and state of charge using decoupled least squares technique[J]. Energy, 2018, 142: 678-688.
- [18] DAI Haifeng, XU Tianjiao, ZHU Letao, et al. Adaptive model parameter identification for large capacity Li-ion batteries on separated time scales[J]. Applied Energy, 2016, 184: 119-131.
- [19] 陈泽宇, 熊瑞, 李世杰, 等. 电动载运工具锂离子电池低温极速加热方法研究[J]. 机械工程学报, 2021, 57(4): 113-120.  
CHEN Zeyu, XIONG Rui, LI Shijie, et al. Extremely fast heating method of the lithium-ion battery at cold climate for electric vehicle[J]. Journal of Mechanical Engineering, 2021, 57(4): 113-120.
- [20] LIU Donglei, WANG Shunli, FAN Yongcun, et al. State of energy estimation for lithium-ion batteries using adaptive fuzzy control and forgetting factor recursive least squares combined with AEKF considering[J]. Journal of Energy Storage, 2023, 70: 108040.
- [21] XIONG Rui, SUN Fengchun, CHEN Zheng, 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: 463-476.
- [22] FOTOUHI A, AUGER D J, PROPP K, et al. Accuracy versus simplicity in online battery model identification[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2016, 48(2): 195-206.
- [23] 余杰, 廖思阳, 徐箭, 等. 考虑环境温度的磷酸铁锂电池 SOC 实时修正及频率控制方法[J]. 电工技术学报, 2023, 38(17): 4564-4573.  
YU Jie, LIAO Siyang, XU Jian, et al. Real-time SOC correction and frequency control method for LFP batteries considering ambient temperature[J]. Transactions of China Electrotechnical Society, 2023, 38(17): 4564-4573.

收稿日期: 2024-01-03; 修回日期: 2024-07-01

作者简介:

邹国发(1998—), 男, 硕士研究生, 研究方向为新能源汽车复合电源系统多状态估计; E-mail: 1538933385@qq.com

高祥(1983—), 男, 通信作者, 硕士, 讲师, 研究方向为电池管理系统; E-mail: gaoxiang@suse.edu.cn

王春(1984—), 男, 博士, 副教授, 研究方向为新能源汽车多电源集成管理与优化控制, 先进储能系统人工智能管理与控制。E-mail: susewangchun@163.com

(编辑 周金梅)