

基于 AFFRLS-AEKF 的电池 SOC 估计方法

葛 科¹
GE Ke

摘 要

文章基于 AFFRLS-AEKF 方法, 针对锂离子电池的 SOC 估计问题展开研究。首先介绍了电池 SOC 估计的重要性和应用背景, 指出了当前 SOC 估计方法存在的问题和挑战。随后详细介绍了 AFFRLS-AEKF 方法的创新之处, 包括基于自适应遗忘因子的自适应遗忘因子递归最小二乘法 (AFFRLS) 和动态调节的遗忘因子, 以及提高算法敏感性与适应性的特点。在电池等效模型和电池容量分析方面, 采用二阶 Thevenin 等效电路模型和马里兰大学提供的 INR 18650-20 R 锂离子电池数据集进行研究。通过实验验证 AFFRLS 参数辨识的准确性, 并将结果应用于等效电路模型中, 进一步验证了 AFFRLS-AEKF 方法在复杂工况下的准确性和鲁棒性。最后, 通过仿真实验和对比分析, 证明了 AFFRLS-AEKF 方法相较于传统方法具有更高的精度和稳定性, 能够更准确地进行电池状态估计, 提高电池管理系统的整体性能。该研究为电池管理系统的设计和开发提供了重要的理论依据和技术支持, 展现了 AFFRLS-AEKF 方法在电池 SOC 估计领域的优越性和应用前景。

关键词

锂电池; SOC 估计方法; 最小二乘法; 自适应扩展卡尔曼滤波器; 电池管理系统

doi: 10.3969/j.issn.1672-9528.2024.12.041

0 引言

在国家相关政策下, 新能源技术及应用得到了快速发展。锂离子电池作为主要的能量存储设备, 发挥着至关重要的作用。随着电池技术的不断进步, 准确估计电池的荷电状态 (state of charge, SOC) 已成为提升电池管理系统性能的关键因素之一^[1]。SOC 的准确估计不仅影响电池的使用效率和安全性, 还直接关系到电池的续航能力和整体性能。锂离子电池因其高放电容量、高能量密度和低自放电率而被广泛应用于储能设备、电动汽车以及航空领域等领域。可见, SOC 是电池管理系统中的重要参数^[2], 同时还是故障诊断中的重要参数^[3]。

因此, 寻求一种合理的方法来准确估计 SOC 非常重要^[4]。目前, 用于估算 SOC 的主要方法有四种: 一是库仑计数法^[5-6]; 二是查找表法^[7-8]; 三是基于模型的方法^[9]; 四是数据驱动法^[10]。库仑计数法通常是通过对电流进行时间积分来估算电池的 SOC, 库仑计数法不需要复杂的模型和算法, 只需简单积分计算电池的充放电电量即可得出 SOC。因此, 该方法实现简单, 易于操作。但在实际工程应用中, 传感器精度和其他外部变量等因素会影响电流测量的精度, 进而影响 SOC 计算的精度。查找表法是测量电池 SOC 与开路电压 (OCV) 之间关系的特定过程。建立好 SOC-OCV 对应关系表后, 不需要实时监测电池充放电过程, 只需在需要时测量电池的开路电压即可获取 SOC 值。但这一过程可能耗时

较长, 尤其是在稳态期间。因此, 这种方法可能不适合在线 SOC 估算。基于模型的方法是通过建立电池工作模型, 结合电池电压、电流、温度等参数进行状态估计, 从而计算电池的 SOC。基于模型的方法不受特定电池类型的限制, 适用于各种不同类型的电池系统。缺点在于建立高精度的模型需要充分了解电池的特性和内部结构, 以及大量的实验数据作为支撑, 因此需要一定先验知识和数据支持。数据驱动法是通过分析历史数据, 利用机器学习等方法建立 SOC 估计模型, 从而预测电池的 SOC。数据驱动法不需要建立复杂的电池模型, 而是直接利用历史数据进行学习, 可以适用于各种类型的电池系统, 降低了模型建立的复杂性。但是数据驱动法对数据质量的依赖性较高, 需要大量的高质量历史数据来支撑模型建立和训练, 若数据质量不好或者缺乏代表性数据, 可能导致 SOC 估计精度下降。

针对上述方法存在的问题, 文献 [11] 提出了一种基于组内电池均匀性分析的电池组 SOC 估算方法。该方法中使用第一个过放电电池和第一个过充电电池来表示电池组的 SOC。文献 [12] 计算了电池组的平均 SOC, 并估算了 SOC 的不确定性。此方法虽然能够提高 SOC 估算的精度, 但却是以牺牲 SOC 估计速度为代价, 难以在嵌入式平台中实现。文献 [13] 使用“平均单体”等效电路模型和 SOC 差值, 通过单体与“平均单体”之间的电压差来计算电池组中每个单体的 SOC。双时间尺度卡尔曼滤波方法可以提高对电池单体 SOC 的估算精度, 有助于提高系统的稳定性和性能。但研究者仅讨论 SOC

1. 江苏海基新能源股份有限公司 江苏无锡 214400

估计方法在单工况下的效果，并未充分讨论该方法在不同类型的电池组和不同工况下的适用性。文献 [14] 提出了电池组的均值加差值模型，其中均值模型代表整个电池组，差值模型研究每个单体电池之间的不一致性。均值加差值模型可以较为方便地应用于电池 SOC 不一致性估算，具有一定的可行性和实用性。但是该方法可能更适用于特定类型的电池（如 LiFePO₄ 电池），在其他类型电池或不同工况下的适用性有待进一步验证。随着近年来人工智能的发展，神经网络和机器学习等新方法已被用于估算电池的 SOC。例如，Wang 等人 [15] 引入了一种改进的前馈长短期记忆建模方法，用于准确估算 SOC。虽然神经网络在准确估算电池 SOC 方面显示出良好的前景，但这些方法也存在一些局限性，如训练过程耗时较长，需要大量训练数据等。

通过对 SOC 估算方法的分析，可以得出结论：多电池估算方法更有可能实现准确可靠的电池组 SOC 估算，同时，需要兼顾效率与成本。

综上，现有的锂电池 SOC 估计研究中存在以下几点问题：使用算法过于复杂时，虽然 SOC 估计精度得到提高，但其计算量较大，难以在嵌入式系统中成功应用；通过平均单体与差值模型研究可以提高 SOC 估计的效率与降低计算量，但是却忽视了不同电池在不同工况下的表现会有所不同；神经网络算法估计 SOC 虽然可以对特定的电池做估计，提高准确性，但是神经网络估计 SOC 需要庞大的数据作为支撑，当数据量不够时，SOC 估计精度较低。

本文的主要贡献如下：（1）创新的模型参数辨识方法：提出了基于自适应遗忘因子的自适应遗忘因子递归最小二乘法（AFFRLS），为嵌入式系统中模型参数的实时辨识提供了一种新的解决方案，克服了现有方法的局限性；（2）动态调节的遗忘因子：通过引入自适应遗忘因子的概念，AFFRLS 算法能够根据系统参数变化的速度动态调整遗忘因子，增强了算法的灵活性和适应性。这一特性使得算法能够更好地应对实时系统中参数的快速变化；（3）提高算法的敏感性与适应性：针对传统 FFRLS 方法在参数变化面前的不足 AFFRLS 算法在提高对参数变化的敏感性方面有所突破，确保在动态环境下仍能稳定、高效地进行参数估计，为嵌入式系统的应用提供了更为可靠的技术支持。

1 电池等效模型

1.1 电池等效电路模型

电池是一个复杂的电化学系统，精确描述其内部和外部特性是提高荷电状态估计精度的关键之一。为此，研究人员提出了多种基于模型的方法，如电化学模型 [16-18]、等效电路模型 [19-21]、电化学阻抗模型 [22] 等，以解决电池荷电状态估计问题。模型越能准确地模拟电池运行中的电化学过程，其精度就越高。

其中，等效电路模型因其高精度和计算效率而被广泛采用。这种模型利用电气元件，如电阻、电压源和电容等，对电池进行建模，以模拟其外部特性，并通过电路中的变量关系来描述和分析电池的工作原理。常见的等效电路模型包括 Rint 模型、PNGV 模型和 Thevenin 模型等。其中，Rint 模型仅包含一个电阻，无法反映电池在频繁充放电情况下的极化现象 [23]。PNGV 模型虽然可以有效反映电池的瞬时状态，但其复杂的数学模型增加了计算负担，并且不利于参数辨识算法的收敛 [24]。Thevenin 模型通过引入 RC 网络来模拟电池的极化特性，能够直观地反映电池的动态响应问题 [25]。在此使用二阶 Thevenin 模型。

如图 1 所示，当电流 I 从正极流出时，电池处于放电状态，否则电池处于充电状态。 U_{oc} 为电池的开路电压（open-circuit voltage, OCV）， R_0 为电池的 Ω 电阻， R_1 、 R_2 为极化电阻， C_1 、 C_2 为极化电容。




图 1 二阶 Thevenin 等效电路模型

根据基尔霍夫原理可建立方程组，其公式为：

$$\begin{cases} U_0 = U_{oc} - IR_0 - U_1 - U_2 \\ \frac{dU_1}{dt} = \frac{I}{C_1} - \frac{U_1}{R_1 C_1} \\ \frac{dU_2}{dt} = \frac{I}{C_2} - \frac{U_2}{R_2 C_2} \end{cases} \quad (1)$$

由安时积分法可近似获得电池的 SOC，其公式为：

$$SOC(t) = SOC_0 - \frac{\eta}{Q} \int_0^t I(\tau) d\tau \cdot 100\% \quad (2)$$

式中： SOC_0 为电池初始电量， t 为充放电时间， η 为库伦效率系数， Q 为电池的可用容量。

将式（1）与式（2）联立，并进行离散化处理，可得二阶 Thevenin 等效电路模型的状态空间方程：

$$\begin{cases} \begin{bmatrix} SOC_{k+1} \\ U_{1,k+1} \\ U_{2,k+1} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{T_s}{\tau_1}} & 0 \\ 0 & 0 & e^{-\frac{T_s}{\tau_2}} \end{bmatrix} \begin{bmatrix} SOC_k \\ U_{1,k} \\ U_{2,k} \end{bmatrix} + I_k \cdot \begin{bmatrix} -\frac{T_s}{Q} \\ R_1(1 - e^{-\frac{T_s}{\tau_1}}) \\ R_2(1 - e^{-\frac{T_s}{\tau_2}}) \end{bmatrix} \\ U_{T,k} = U_{oc}(SOC_k) - I_k \cdot R_0 - U_{1,k} - U_{2,k} \end{cases} \quad (3)$$

式中： T_s 为采样时间， $\tau_1 = R_1 C_1$ ， $\tau_2 = R_2 C_2$ 。

1.2 电池容量分析

本文采用了马里兰大学提供的 INR 18650-20R 锂离子电池数据集, 该电池的额定容量为 2 Ah。为了研究不同环境温度对电池容量的影响, 本文利用在 0 °C、25 °C 和 45 °C 下的 HPPC (hybrid pulse power characterization) 放电数据, 测量并分析了 3 个温度条件下电池的可用容量。具体而言, 首先在不同温度下对电池进行放电实验, 记录放电过程中电池的性能数据。在 0 °C、25 °C 和 45 °C 的环境温度下, 通过 HPPC 放电数据获取了电池在每个温度条件下的实际可用容量。HPPC 测试包括一系列的脉冲充放电操作, 这些操作能够反映电池在不同温度和不同放电倍率下的性能, 从而准确测量电池的可用容量。将不同温度下得到的可用容量数据进行分析和处理, 进一步采用三次多项式拟合方法, 将可用容量和温度之间的关系进行建模。图 2 展示了拟合结果, 可以清晰地看出电池可用容量随温度变化的趋势。




图 2 电池可用容量和温度关系曲线

当环境温度在 298.15~318.15 K (即 25 °C ~45 °C), 锂离子电池的容量有较好的保持性。当环境温度为 298.15 K (即 25 °C) 时, 电池的可用容量为 1.97 Ah, 相对于额定容量改变 1.5%; 当环境温度为 318.15 K (即 45 °C) 时, 电池的可用容量为 1.99 Ah, 相对于额定容量改变 0.5%。

1.3 OCV-SOC 曲线

在进行参数辨识前需要得到锂离子电池的 OCV-SOC 曲线, 通过锂离子电池在 0 °C、25 °C 和 45 °C 下的脉冲充放电实验得到 OCV 和 SOC 数据, 经过 6 次多项式拟和, 得到 OCV 与 SOC 函数关系如图 3 所示。




图 3 0 °C、25 °C 和 45 °C 时 OCV-SOC 拟合曲线

2 基于 AFFRLS 的模型参数辨识

由式 (1) 进行拉式变换可得:

$$U_{oc}(s) - U_0(s) = I(s) \left(R_0 + \frac{R_1}{1 + R_1 C_1 s} + \frac{R_2}{1 + R_2 C_2 s} \right) \quad (4)$$

则等效电路模型的传递函数为:

$$\begin{aligned} G(s) &= \frac{U_{oc}(s) - U_0(s)}{I(s)} = R_0 + \frac{R_1}{1 + R_1 C_1 s} + \frac{R_2}{1 + R_2 C_2 s} \\ &= \frac{R_0 \tau_1 \tau_2 s^2 + (R_0 \tau_1 + R_0 \tau_2 + R_1 \tau_2 + R_2 \tau_1) s + R_0 + R_1 + R_2}{\tau_1 \tau_2 s^2 + (\tau_1 + \tau_2) s + 1} \\ &= \frac{R_0 s^2 + \frac{1}{\tau_1 \tau_2} (R_0 \tau_1 + R_0 \tau_2 + R_1 \tau_2 + R_2 \tau_1) s + \frac{1}{\tau_1 \tau_2} (R_0 + R_1 + R_2)}{s^2 + \frac{1}{\tau_1 \tau_2} (\tau_1 + \tau_2) s + \frac{1}{\tau_1 \tau_2}} \end{aligned} \quad (5)$$

为了保证前后系统稳定性的一致性, 采用双线性变换方法将函数从 s 域变换到 z 域。

$$s = \frac{2}{T_s} \cdot \frac{1 - z^{-1}}{1 + z^{-1}} \quad (6)$$

将式 (7) 代入式 (6), 得到 z 域的传递函数:

$$G(z^{-1}) = \frac{a_3 + a_4 z^{-1} + a_5 z^{-2}}{1 - a_1 z^{-1} - a_2 z^{-2}} \quad (7)$$

式中: $a_i (i=1, 2, 3, 4, 5)$ 为待识别参数, 模型参数与待识别参数的关系为:

$$\begin{cases} R_0 = \frac{a_3 - a_4 + a_5}{1 + a_1 - a_2} \\ \tau_1 \tau_2 = \frac{T_s^2 (1 + a_1 - a_2)}{4(1 - a_1 - a_2)} \\ \tau_1 + \tau_2 = \frac{T_s (1 + a_2)}{1 - a_1 - a_2} \\ R_0 + R_1 + R_2 = \frac{a_3 + a_4 + a_5}{1 - a_1 - a_2} \\ R_0 \tau_1 + R_0 \tau_2 + R_2 \tau_1 + R_1 \tau_2 = \frac{4(a_3 - a_5)}{T_s (1 - a_1 - a_2)} \end{cases} \quad (8)$$

将式 (7) 改写成差分方程形式:

$$U(k) = a_1 U(k-1) + a_2 U(k-2) + a_3 I(k) + a_4 I(k-1) + a_5 I(k-2) \quad (9)$$

式中: $U(k) = U_{oc}(k) - U_0(k)$, 将式 (8) 改写成矩阵形式:

$$\begin{cases} y(k) = \theta^T(k) \phi(k) \\ \theta(k) = [a_1 \ a_2 \ a_3 \ a_4 \ a_5]^T \\ \phi(k) = [U(k-1) \ U(k-2) \ I(k) \ I(k-1) \ I(k-2)]^T \end{cases} \quad (10)$$

自适应遗忘因子递归最小二乘法 (adaptive forgetting factor recursive least squares, AFFRLS) 是对遗忘因子递归最小二乘法 (forgetting factor recursive least squares, FFRLS) 进行改进的一种参数估计算法^[26]。FFRLS 是一种经典的在线参数估计算法, 通过最小化预测误差的平方和来实现系统参数的估计, 具有快速收敛和高精度的优点, 非常适合用于线

性和线性化系统的参数估计。其公式为：

$$\begin{cases} \theta(k) = \theta(k-1) + K(k)[y(k) - \phi^T(k)\theta(k-1)] \\ K(k) = \frac{P(k-1)\phi(k)}{\lambda + \phi^T(k)P(k-1)\phi(k)} \\ P(k) = \frac{1}{\lambda}[I - K(k)\phi^T(k)]P(k-1) \end{cases} \quad (11)$$

式中： $\theta(k)$ 是系统参数向量； $K(k)$ 是增益向量； $P(k)$ 是误差协方差； $\phi(k)$ 是输入向量； λ 是遗忘因子。FFRLS 算法通过更新这些参数，逐步逼近真实的系统参数。然而，FFRLS 算法使用固定的遗忘因子 λ ，这在某些情况下可能无法适应系统参数的快速变化。为了克服这一问题，AFFRLS 引入了自适应遗忘因子。自适应遗忘因子能够根据系统的变化情况动态调整，从而提高了算法对参数变化的敏感性和适应性^[27]。

在 AFFRLS 中，遗忘因子不再是一个固定值，而是根据误差的变化情况进行调整。一般来说，当系统参数变化较快时，误差会增大，此时遗忘因子会减小，以便算法能够更快地跟踪系统的变化；而当系统参数变化较慢时，误差会减小，遗忘因子则会增大，以保持估计的稳定性^[28]。这种自适应调整机制使得 AFFRLS 在处理动态系统的参数估计问题时，能够更好地适应系统的变化，提高估计的准确性和鲁棒性。具体来说，自适应遗忘因子的调整可用通过公式实现：

$$\begin{cases} \lambda(k) = \lambda_0 + (1 - \lambda_0)2^{L(k)} \\ L(k) = -r(2e^2(k)) \end{cases} \quad (12)$$

3 SOC 估计方法

扩展卡尔曼滤波器（extended kalman filter, EKF）是一种用于非线性系统状态估计的滤波算法，是经典卡尔曼滤波器的扩展版本^[29]。传统的卡尔曼滤波器适用于线性系统，通过最小化估计误差的方差来优化状态估计。然而，电池的充放电过程具有高度的非线性特性，使得标准的卡尔曼滤波器不适用。EKF 通过在当前估计点处对非线性系统模型进行线性化，从而应用卡尔曼滤波器进行状态估计。对于非线性系统，离散空间状态方程为：

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{w}_k \\ y_k = \mathbf{h}(\mathbf{x}_k, \mathbf{u}_k) + v_k \end{cases} \quad (13)$$

式中： $\mathbf{x}_k$ 表示系统在 k 时刻的状态； $\mathbf{u}_k$ 表示控制变量； y_k 表示测量值； $\mathbf{w}_k$ 和 v_k 分别表示过程噪声和测量噪声。 $\mathbf{w}_k$ 和 v_k 不相关且服从高斯分布，协方差分别为 $\mathbf{Q}_k$ 和 R_k 。

将式（3）的状态方程和观测方程线性化后为：

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

式中：状态向量 $\mathbf{x}_k = [\text{SOC}_k \ U_{1,k} \ U_{2,k}]^T$ ；输入量 $\mathbf{u}_k$ 为充放电电流 I ；输出量 y_k 为端电压 U_0 。根据等效电路模型的状态空间方程，可得到 $\mathbf{A}$ 、 $\mathbf{B}$ 、 $\mathbf{C}$ 和 $\mathbf{D}$ ，公式为：

$$\begin{cases} \mathbf{A}_k = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{T_s}{\tau_1}} & 0 \\ 0 & 0 & e^{-\frac{T_s}{\tau_2}} \end{bmatrix} \\ \mathbf{B}_k = \begin{bmatrix} -\frac{T_s}{Q} & R_1(1 - e^{-\frac{T_s}{\tau_1}}) & R_2(1 - e^{-\frac{T_s}{\tau_2}}) \end{bmatrix}^T \\ \mathbf{C}_k = \frac{\partial g}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\mathbf{x}_k} = \left[\frac{\partial U}{\partial \text{SOC}} \Big|_{\mathbf{x}=\mathbf{x}_k} \quad -1 \quad -1 \right] \\ \mathbf{D}_k = -R_0 \end{cases} \quad (15)$$

在 SOC 估计中，EKF 使用电池的动态模型和测量数据，通过迭代的预测和更新步骤来估计 SOC。具体步骤为：

（1）参数初始化：

$$\mathbf{x}_0 = E(\mathbf{x}_0) \quad (16)$$

$$\mathbf{P}_0 = E[(\mathbf{x}_0 - \hat{\mathbf{x}}_0)(\mathbf{x}_0 - \hat{\mathbf{x}}_0)^T] \quad (17)$$

（2）预测阶段：根据电池模型预测下一个时刻的状态和误差。预测方程为：

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{A}_{k-1}\hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B}_{k-1}\mathbf{u}_{k-1} \quad (18)$$

$$\mathbf{P}_{k|k-1} = \mathbf{A}_{k-1}\mathbf{P}_{k-1|k-1}\mathbf{A}_{k-1}^T + \mathbf{Q}_{k-1} \quad (19)$$

式中： $\hat{\mathbf{x}}_{k|k-1}$ 是预测的状态估计； $\mathbf{P}_{k|k-1}$ 是预测的误差协方差矩阵； $\mathbf{A}_{k-1}$ 是状态转移的雅可比矩阵； $\mathbf{Q}_{k-1}$ 是过程噪声协方差矩阵。

（3）更新阶段：利用当前的测量数据更新状态估计和误差协方差矩阵。更新方程为：

$$\mathbf{K}_k = \mathbf{P}_{k|k-1}\mathbf{C}_k^T(\mathbf{C}_k\mathbf{P}_{k|k-1}\mathbf{C}_k^T + R_k)^{-1} \quad (20)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k(y_k - \hat{y}_{k|k-1}) \quad (21)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k\mathbf{C}_k)\mathbf{P}_{k|k-1} \quad (22)$$

式中： $\mathbf{K}_k$ 是卡尔曼增益； $\mathbf{C}_k$ 是观测矩阵的雅可比矩阵； $\mathbf{R}_k$ 是测量噪声协方差矩阵。EKF 的优势在于其能够处理非线性系统，并在实践中表现出较好的估计性能。然而，EKF 的性能依赖于模型的准确性和噪声统计特性的精确性，这在实际应用中可能导致估计误差较大。

为了增强 EKF 的鲁棒性和适应性，本文引入了一种 AEKF 算法。AEKF 通过引入自适应机制，使滤波器能够根据系统状态和测量噪声的变化动态调整其参数，从而显著提高估计的精度和鲁棒性^[30]。AEKF 的核心改进在于其自适应调整机制。传统的 EKF 算法在处理非线性系统状态估计时，依赖于预设的噪声协方差矩阵。然而，实际应用中系统的动态特性和测量噪声往往是变化的，固定的噪声协方差矩阵可能无法有效应对这些变化，导致估计精度下降。为了解决这一问题，AEKF 通过实时评估预测误差和测量误差，动态调整噪声协方差矩阵，使滤波器能够更好地适应系统的实时变化。具体而言，AEKF 在每个时间步长内，通过比较预测误差和实际测量误差来评估系统当前的噪声特性。基于这些评

估结果, AEKF 算法动态调整过程噪声协方差矩阵和测量噪声协方差矩阵, 使其能够反映当前系统状态和测量条件的变化。这一自适应调整机制, 使得 AEKF 在应对系统动态和噪声特性变化方面, 表现出更高的灵活性和精确度。通过这种方法, AEKF 能够在各种复杂和动态的工况下, 保持高精度的状态估计。

AEKF 在 EKF 的基础上增加了自适应调整机制, 通过下列公式更新观测噪声与状态噪声的均值:

$$\begin{cases} d_k = \frac{1-b}{1-b^k} \\ q_k = (1-d_k)q_{k-1} + d_k(\hat{x}_{k|k} - x_{k-1|k-1}) \\ r_k = (1-d_k)r_{k-1} + d_k(y_k - (C_k\hat{x}_{k|k-1} + D_k u_k)) \end{cases} \quad (23)$$

式中: d_k 为更新数据的权重分配; b 为遗忘因子, 本文取 0.98。然后更新观测噪声与状态噪声的误差矩阵:

$$\begin{cases} e_k = y_k - \hat{y}_{k|k-1} \\ Q_k = (1-d_k)Q_{k-1} + d_k K_k e_k e_k^T K_k^T \\ R_k = (1-d_k)R_{k-1} + d_k (e_k e_k^T - C_k P_{k|k} C_k^T) \end{cases} \quad (24)$$

式中: e_k 为测量端电压与估计端电压的误差。通过这种自适应机制, AEKF 能够更准确地反映实际系统的噪声特性, 从而提高 SOC 估计的精度。

结合 AFFRLS 参数辨识和 EKF 算法, 电池的 SOC 估计算法如图 4 所示。




图 4 AFFRLS-AEKF 算法流程图

4 仿真结果及分析

本文采用了马里兰大学提供的 INR 18650-20R 锂离子电池数据集, 利用 HPPC 放电数据进行电池参数辨识。具体而言, 放电电流如图 5 所示, 每次放电电量为电池总容量的 10%, 放电电流设定为 0.5 C。在每次放电结束后, 电池静置 2 h, 以确保电池内部状态恢复平衡。为了更准确地识别该型号电池的参数, 使用了 AFFRLS 进行离线参数辨识。通过 AFFRLS 算法, 能够有效识别出二阶 Thevenin 等效电路模型中的参数, 具体包括极化电阻和极化电容等关键参数。图中展示了参数辨识的具体结果, 显示出该方法的高效性和准确性。在 AFFRLS 算法中, 遗忘因子 λ 的自适应变化是其一

大特点。遗忘因子的变化范围为 0.98 到 1 之间, 这意味着在参数辨识过程中, λ 能够根据系统参数的变化进行自适应调整, 从而提升模型对电池动态特性的捕捉能力。通过这种自适应机制, AFFRLS 算法能够更好地反映电池的真实工作状态, 提高参数辨识的精度。




图 5 HPPC 参数辨识结果

为了验证 AFFRLS 参数辨识的准确性, 将参数辨识的结果代入二阶 Thevenin 等效电路模型中进行进一步验证。具体来说, 通过比较端电压误差来评估不同参数辨识方法的性能。图 6 中展示了采用 AFFRLS 和 FFRLS 两种方法进行参数识别后, 将其结果代入等效电路模型中得到的端电压误差。对于 FFRLS 方法, 设置遗忘因子为 0.99。




图 6 估计端电压误差

结果显示, FFRLS 方法在某些情况下的端电压估计误差最大可以达到 0.2 V。这表明, 在较大误差的情况下, FFRLS 方法可能无法准确反映电池的实际工作状态, 导致模型预测的端电压与实际端电压存在显著偏差。相比之下, AFFRLS 方法的性能明显优于 FFRLS。通过改进后的 AFFRLS 方法进行参数识别, 并将其结果代入等效电路模型后, 端电压估计误差始终保持在 0.2 V 以内。这意味着 AFFRLS 方法在捕捉电池动态特性方面更为精准, 能够更好地反映电池的真实行为。通过实验验证, AFFRLS 方法在参数辨识方面表现出更高的准确性和可靠性。其在端电压估计上的小误差, 表明该方法能够为等效电路模型提供更加准确的参数支持, 从而提升电池管理系统的整体性能。

这一结果不仅验证了 AFFRLS 方法的优越性,也为进一步应用于复杂电池管理系统提供了有力的理论和实验依据。通过采用 AFFRLS 方法,可以更精确地进行电池状态估计,提高系统的稳定性和可靠性,从而延长电池的使用寿命,提升其在各种应用中的性能。

为了验证 AEKF 算法在估计 SOC 方面的准确性和鲁棒性,采用了 FUDS 和 DST 工况。具体来说,这些工况的电流如图 7 所示。在仿真过程中,设置仿真步长为 10 s,并 AFFRLS 参数辨识后的极化电阻和极化电容代入二阶 Thevenin 等效电路模型中,以确保模型能够准确反映电池的实际工作状态。随后,使用 AEKF 算法进行电池的 SOC 估计。在此次实验中,初始 SOC 设置为 1,仿真时长为 5000 s。在这一过程中,AEKF 算法表现出色,在 DST 和 FUDS 工况下的 SOC 估计误差均保持在 0.008 以内。




图 7 DST 和 FUDS 工况下 SOC 估计误差

这一结果不仅证明了 AEKF 算法在动态工况下具有较高的估计精度,同时也展示了其在不同环境下的鲁棒性。具体来说,在 FUDS 工况下,电流变化复杂且频繁,但 AEKF 算法依然能够准确追踪 SOC 的变化,保持误差在极低水平。同样,在 DST 工况下,尽管电池经历了多次高强度放电和充电过程,AEKF 算法仍然能够迅速调整并保持高精度的 SOC 估计。这表明,AEKF 算法不仅适用于稳态工况,在动态、复杂的工况下同样表现出色。通过将 AFFRLS 算法辨识出的参数引入到二阶 Thevenin 等效电路模型,并结合 AEKF 算法进行 SOC 估计,验证了该方法在复杂工况下的准确性和鲁棒性。

5 结论

本文基于二阶 Thevenin 等效电路模型,提出了一种新的估计算法——AFFRLS-AEKF 方法,以解决因充放电状态变化导致的电池参数估计不准确和噪声影响导致的电池状态估计精度较低的问题。该方法在两方面进行了改进:首先,

AFFRLS 算法相比于传统的 FFRLS 算法,能够更精确地识别出等效电路模型中的等效电阻和等效电容,使等效电路模型更贴近电池的实际工作状态。其次,AEKF 算法能够在不同环境下的电池充放电过程中修正噪声,从而进一步提高了算法的稳定性和 SOC 估计精度。在仿真实验中,AFFRLS 算法在 HPPC 放电测试中表现优异,端电压估计误差控制在 0.2V 以内。而 AEKF 算法在 DST 和 FUDS 工况下的 SOC 估计误差均低于 0.008,显著提升了稳态条件下的估计精度。综合来看,AFFRLS-AEKF 算法在与传统 EKF 算法的对比中,表现出更小的误差和更高的精度,且具有更好的稳定性。因此,AFFRLS-AEKF 方法能够更准确地进行锂离子电池的状态估计,为电池管理系统提供了更加可靠的参考。该方法不仅有效地改善了电池参数识别的准确性,还通过噪声修正提升了 SOC 估计的稳健性和精度,展现出在复杂工况下优越的性能和应用前景。这一创新性的算法为进一步优化电池管理系统的设计和开发提供了重要的理论依据和技术支持。

参考文献:

- [1] ZHANG X G, DUAN L S, GONG Q S, et al. State of charge estimation for lithium-ion battery based on adaptive extended Kalman filter with improved residual covariance matrix estimator[J]. Journal of power sources, 2024, 589(1): 233758.
- [2] SUN F C, XIONG R. A novel dual-scale cell state-of-charge estimation approach for series-connected battery pack used in electric vehicles[J]. Journal of power sources, 2015, 274(1): 582-594.
- [3] BI J, ZHANG T, YU H Y, et al. State-of-health estimation of lithium-ion battery packs in electric vehicles based on genetic resampling particle filter[J]. Applied energy, 2016, 182(11): 558-568.
- [4] QIAO X, LI G, ZHANG Y J, et al. Fault diagnosis and abnormality detection of lithium-ion battery packs based on statistical distribution[J]. Journal of power sources, 2021, 482(1): 228964.
- [5] MOHAMMADI F. Lithium-ion battery state-of-charge estimation based on an improved coulomb-counting algorithm and uncertainty evaluation[J]. Journal of energy storage, 2022, 48(4): 104061.
- [6] LIPU M S H, HUSSAIN A, AYOB A, et al. Data-driven state of charge estimation of lithium-ion batteries: Algorithms, implementation factors, limitations and future trends[J]. Journal of cleaner production, 2020, 277(12): 124110.
- [7] KHAN Z A, SHRIVASTAVA P, AMRR S M, et al. A comparative study on different online state of charge estimation algorithms for lithium-Ion batteries[EB/OL].

- (2022-06-17)[2024-12-07].<https://www.mdpi.com/2071-1050/14/12/7412>.
- [8] TIAN J P, XIONG R, SHEN W X, et al. Electrode ageing estimation and open circuit voltage reconstruction for lithium ion batteries[J]. *Energy storage materials*, 2021, 37(5): 283-295.
- [9] SHEN J W, MA W S, XIONG J, Et al. Alternative combined co-estimation of state of charge and capacity for lithium-ion batteries in wide temperature scope[J]. *Energy*, 2022, 244(4): 123236.
- [10] TIAN J P, XIONG R, CHEN C, et al. Simultaneous prediction of impedance spectra and state for lithium-ion batteries from short-term pulses[J]. *Electrochimica acta*, 2023, 449(5): 142218.
- [11] XING S, LI G, ZHANG Y J, et al. Online diagnosis of state of health for lithium-ion batteries based on short-term charging profiles[J]. *Journal of power sources*, 2020, 471(9): 228478. .
- [12] TRUCHOT C, DUBARRY M, LIAW B Y. State-of-charge estimation and uncertainty for lithium-ion battery strings[J]. *Applied energy*, 2014, 119(4): 218-227.
- [13] ZHENG Y J, OUYANG M G, LU L G, et al. Cell state-of-charge inconsistency estimation for LiFePO₄ battery pack in hybrid electric vehicles using mean-difference model[J]. *Applied energy*, 2013, 111(11): 571-580.
- [14] WANG S I, TAKYI-ANINAKWA P, JIN S, et al. An improved feedforward-long short-term memory modeling method for the whole-life-cycle state of charge prediction of lithium-ion batteries considering current-voltage-temperature variation[J]. *Energy*, 2022, 254(9): 124224..
- [15] CORNO M, BHATT N, SAVARESI S M, et al. Electrochemical model-based state of charge estimation for Li-ion cells[J]. *IEEE transactions on control systems technology*, 2014, 23(1): 117-127.
- [16] FAN G D, LI X, CANOVA M. A reduced-order electrochemical model of li-ion batteries for control and estimation applications[J]. *IEEE transactions on vehicular technology*, 2017, 67(1): 76-91.
- [17] PRADA E, DI DOMENICO D, CREFF Y, et al. Simplified electrochemical and thermal model of LiFePO₄-graphite Li-ion batteries for fast charge applications[J]. *Journal of the electrochemical society*, 2012, 159(9): A1508.
- [18] HE H W, XIONG R, FAN J X. Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach[EB/OL]. (2011-03-29)[2024-07-11]. <https://www.mdpi.com/1996-1073/4/4/582>.
- [19] XIONG R, SUN F C, CHEN Z, 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(1): 463-476.
- [20] XIONG R, SUN F C, HE H W. Data-driven state-of-charge estimator for electric vehicles battery using robust extended Kalman filter[J]. *International journal of automotive technology*, 2014, 15(2): 89-96.
- [21] LELIE M, BRAUN T, KNIPS M, et al. Battery management system hardware concepts: an overview[EB/OL].(2018-03-30)[2024-05-19].<https://www.mdpi.com/2076-3417/8/4/534>.
- [22] HE H W, ZHANG X W, XIONG R , et al. Online model-based estimation of state-of-charge and open-circuit voltage of lithium-ion batteries in electric vehicles[J].*Energy*, 2012, 39(1):310-318.
- [23] 安诺静. 基于EKF的电动汽车用锂离子电池SOC估计方法研究[D]. 西安: 长安大学, 2020.
- [24] FAN J X ,HE H ,XIONG R .Evaluation of lithium-Ion battery equivalent circuit models for state of charge estimation by an experimental approach[EB/OL].(2011-03-29)[2024-05-25]. <https://www.mdpi.com/1996-1073/4/4/582>.
- [25] 张强. 最小二乘法原理及其处理方法的探讨[J]. *计量与测试技术*, 2020,47(4):75-76.
- [26] SUN X D, JI J R, REN B Y, et al. Adaptive forgetting factor recursive least square algorithm for online identification of equivalent circuit model parameters of a lithium-ion battery[J]. *Energy storage and management for electric vehicles*, 2019, 12(12): 2242.
- [27] SONG Q, MI Y X, LAI W X. A novel variable forgetting factor recursive least square algorithm to improve the anti-interference ability of battery model parameters identification[J]. *IEEE access*, 2019, 7: 61548-61557.
- [28] PU S, ZHAO Y W. Application of unscented kalman filter in the SOC estimation of Li-ion battery for autonomous mobile robot[C]//2006 IEEE International Conference on Information Acquisition. Piscataway: IEEE, 2006: 1279-1283.
- [29] GUO Y, ZHAO Z, HUANG L. SoC estimation of lithium battery based on AEKF algorithm[J]. *Energy procedia*, 2017, 105(5): 4146-4152.

【作者简介】

葛科(1983—), 男, 湖南双峰人, 硕士, 研究方向: 动力及储能电芯研发、设计、生产等。

(收稿日期: 2024-09-10)