

DOI: 10.13718/j.cnki.xdsk.2024.12.006

汤爱华, 刘尚梅, 邹航, 等. 基于变分贝叶斯无迹卡尔曼滤波 SOC 估计 [J]. 西南大学学报(自然科学版), 2024, 46(12): 51-59.

基于变分贝叶斯无迹卡尔曼滤波 SOC 估计

汤爱华¹, 刘尚梅¹, 邹航², 陈哲明¹, 胡雯爔¹, 李粤涵¹

1. 重庆理工大学 汽车零部件先进制造技术教育部重点实验室, 重庆 400054;

2. 重庆理工大学 信息中心, 重庆 400054

摘要: 锂离子动力电池荷电状态(SOC)的精准估计事关新能源汽车的续驶里程和电池寿命, 有助于提高能源利用效率, 缓解电池过充与过放等问题。然而, 由于过程噪声和观测噪声的存在, 锂离子动力电池 SOC 的估计精度难以保证。鉴于此, 提出一种无迹卡尔曼滤波(UKF)和基于变分贝叶斯自适应时变噪声无迹卡尔曼滤波(VBAUKF)联合方法, 通过降低过程噪声和观测噪声以实现锂离子动力电池 SOC 的精确估计。在城市道路循环(UDDS)工况下进行验证, 结果表明: 锂离子动力电池 SOC 的估计误差低于 1%, 验证了所提方法的有效性。

关 键 词: 锂离子动力电池; SOC 估计; 无迹卡尔曼滤波;

变分贝叶斯

中图分类号: TK01

文献标志码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2024)12-0051-09

Variational Bayesian-Based Unscented Kalman Filter Method for SOC Estimation

TANG Aihua¹, LIU Shangmei¹, ZOU Hang²,
CHEN Zheming¹, HU Wenxi¹, LI Yuehan¹

1. Key Laboratory of Advanced Manufacturing Technology for Automobile Parts, Ministry of Education,
Chongqing University of Technology, Chongqing 400054, China;

2. Information Center of Chongqing University of Technology, Chongqing 400054, China

Abstract: Accurate state of charge (SOC) estimation of lithium-ion power battery is related to the range and battery life of new energy vehicles, which is helpful to improve the energy utilization efficiency and alleviate the problems of overcharging and overdischarging of batteries. However, due to the existence of process noise and observation noise, it is hard to guarantee the precision in SOC estimation of lithium-ion

power battery. In view of this, this paper proposed a joint method for SOC estimation of lithium-ion power battery by unscented Kalman filtering (UKF) and adaptive time-varying noise unscented Kalman filtering based on variational Bayesian (VBAUKF) to realize the accurate SOC estimation of lithium-ion power battery by reducing the process noise and observation noise. The proposed method was verified under urban dynamometer driving schedule (UDDS) working conditions, and the results showed that the SOC estimation error of lithium-ion power battery was less than 1%, confirming the effectiveness of the proposed method.

Key words: lithium-ion power battery; state of charge estimation; unscented Kalman filter; variational Bayesian

电池管理系统(Battery Management System, BMS)对于电动汽车和电池储能系统的安全性和可靠性至关重要. 电池荷电状态(State of Charge, SOC)估计是 BMS 的基础^[1-2], 为了实现锂离子动力电池 SOC 的准确估计, 国内外学者在该领域开展了大量研究工作.

当前绝大多数研究采用基于模型的方法, 常见的可分为基于电化学模型、神经网络模型和等效电路模型^[3]3 种方法. 电化学模型依托多孔电极和浓溶液理论, 运用数学方法详尽阐述电池内化学反应与电极动态, 从电化学反应机理中分析问题, 能够深入了解电池的电化学机制. 但由于其模型结构复杂, 建模时需要强大的计算能力和较多的数据^[4-5]. 神经网络模型通过收集锂离子动力电池大量历史数据, 包括电流、电压、温度等信息, 能够在不了解电池工作原理的情况下构建数据与 SOC 之间复杂的线性关系^[6-8], 最终得到电池 SOC 预测数据. 然而当训练数据减少、网络参数设置不当时, 该方法估计精度会变差, 估计结果波动会变大^[9]. 等效电路模型通过模拟电子元件的输入输出行为来捕捉锂离子动力电池的动态特性, 主要有 Rint 模型^[10]、PNGV 模型^[11] 和 Thevenin 模型^[12] 等. 等效电路模型通常结合滤波算法建立状态空间方程估计电池 SOC, 该方法具有复杂度低且精度较高等优点, 可适用于不同类型的电池, 因此一般采用等效电路模型应用于实际 SOC 的估计^[13].

电池动态参数的准确识别是保证锂离子动力电池系统安全、可靠运行的前提. 目前, 常用的参数辨识方法是离线 HPPC 法. 在建模过程中, 由于检测量伴随着不确定的噪声信号, 离线辨识不仅耗时长, 而且结果不准确. 如果采用在线方法进行参数辨识, 则可以实时补偿噪声产生的误差. 周坤等^[14]提出了一种扩展卡尔曼滤波(EKF)自适应无迹卡尔曼滤波(AUKF)联合算法在线估计电池模型参数与 SOC, 通过在不同工况下的试验数据进行验证, 该方法能够实现电池参数和 SOC 实时估计. 但 EKF 算法在线性化过程中引入了导数计算, 此计算过程中忽略了高阶项引起的截断误差, 因此降低了 SOC 估计精度. 为解决卡尔曼滤波在非线性状态转换为线性状态过程中出现的误差问题, Wang 等^[15]提出一种双无迹卡尔曼滤波(DUKF)算法, 在考虑电化学极化和浓度极化的双极化(DP)模型基础上, 在线实现参数辨识和 SOC 估计. 该算法考虑了参数的实时变化, 对运行过程中的噪声信号进行补偿, 避免了实际环境中环境因素的影响, 因此该方法的精度和效率优于 EKF 算法. 在实现上述算法时, 过程噪声协方差 P_k 和观测噪声协方差 R_k 通常已是已知且平稳的. 由于假设变量的分布为高斯分布, 当噪声协方差为具有已知统计量的高斯时, 估计过程可以很好地执行. 然而, 在非高斯分布的情况下, 过程和观测噪声序列的统计量是未知的. 为此, 研究人员开发了基于变分贝叶斯(Variational Bayesian, VB)^[16]的噪声估计算法, 该方法利用逆 Wishart 分布和 VB 方法来推断 P_k 和 R_k .

为解决过程噪声和观测噪声时变会降低滤波精度这一问题从而提高锂离子动力电池 SOC 的估计精度, 本文提出一种无迹卡尔曼滤波和基于变分贝叶斯自适应时变噪声无迹卡尔曼滤波的参数和 SOC 联合估计方法(UKF-VBAUKF), 具体方案为: ①首先建立二阶等效电路模型, 采用无迹卡尔曼滤波辨识模型参数; ②其次利用逆 Wishart 分布对 P_k 和 R_k 进行建模, 对 P_k 进行迭代更新来降低过程噪声的影响, 对 R_k 进行迭代更新降低观测噪声的影响; ③最后采用 UKF-VBAUKF 算法实现对电池状态 X_k 、 P_k 和 R_k 的联合

估计, 从而提高锂离子动力电池 SOC 的估计精度.

1 电池状态空间模型

电池模型的建立是 SOC 估计的基础, 它不仅需要反映电池的静态和动态特性, 并且要易于实现. 考虑到模型精度和复杂度成正比, 本文选用如图 1 所示的无迟滞的二阶等效电路模型. 该模型结构简单, 物理意义清晰, 足以模拟电池的静动态性能, 同时也便于电池特性分析和参数辨识^[17]. 其中 R_0 为电池的欧姆内阻; 由 R_1 、 R_2 、 C_1 、 C_2 组成的 2 个 RC 网络代表电池的极化电阻和极化电容; U_1 和 U_2 为电池的极化电压; U_t 为电池端电压; U_{oc} 为开路电压(Open Circuit Voltage, OCV); I 为电池的负载电流.

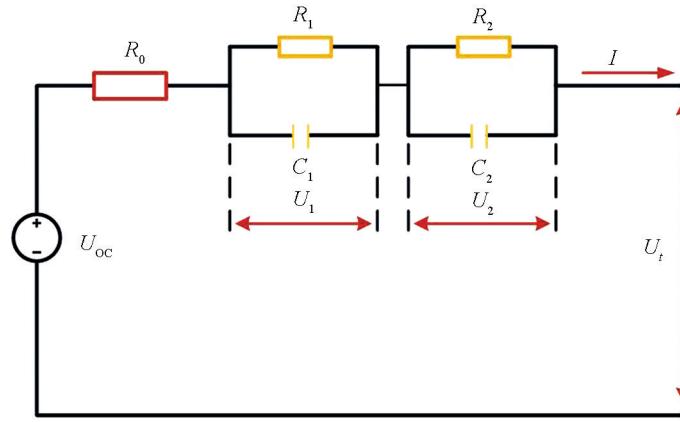


图 1 锂离子动力电池二阶等效电路模型

基于基尔霍夫电压和电流定律得到二阶等效电路模型的状态空间表达式(1) 和观测方程(2):

$$\begin{cases} U_1(t) = -\frac{U_1(t)}{R_1 C_1} + \frac{1}{C_1} I(t) \\ U_2(t) = -\frac{U_2(t)}{R_2 C_2} + \frac{1}{C_2} I(t) \\ S_{soc,k+1} = S_{soc,k} - \frac{I_k T_x}{Q_n} \end{cases} \quad (1)$$

$$U_t = U_{oc}(S_{soc}) - IR_0 - U_1 - U_2 \quad (2)$$

其中: R_1 、 R_2 、 C_1 、 C_2 分别为电池的极化电阻和极化电容; U_{oc} 为电池 OCV; U_1 、 U_2 为极化电压; T_x 为采样时间; Q_n 为电池容量; R_0 为电池欧姆内阻; I 为电池负载电流; S_{soc} 为电池的 SOC 值. 为了便于计算机处理, 需将式(1)、式(2) 进行离散化处理, 得到二阶 RC 模型的线性离散化方程如式(3) 所示:

$$\begin{cases} \begin{pmatrix} S_{soc,k+1} \\ U_{1,k+1} \\ U_{2,k+1} \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{T_s}{R_1 C_1}} & 0 \\ 0 & 0 & e^{-\frac{T_s}{R_2 C_2}} \end{pmatrix} \begin{pmatrix} S_{soc,k} \\ U_{1,k} \\ U_{2,k} \end{pmatrix} + \begin{pmatrix} -\frac{T_s}{Q_n} \\ R_1(1 - e^{-\frac{T_s}{R_1 C_1}}) \\ R_2(1 - e^{-\frac{T_s}{R_2 C_2}}) \end{pmatrix} i_k \\ U_{t,k} = (0 \quad -1 \quad -1) \begin{pmatrix} S_{soc,k} \\ U_{1,k} \\ U_{2,k} \end{pmatrix} - i_k R_0 + U_{oc,k} \end{cases} \quad (3)$$

2 电池模型参数辨识与验证

2.1 OCV-SOC 曲线

测试采用额定电压 3.6 V, 标称容量为 5 000 mAh 的 NCR26650 锂电池作为试验对象, 采用美国 Arbin

公司生产的 LBT 系列 5 V/30 A 电池充放电测试仪作为电池试验平台。OCV 测试试验具体步骤如下：采用 0.3 C 电流倍率对电池进行恒流放电，当电池端电压下降到下截止电压时，静置 1 h 使电池内部反应达到稳态，记录当前端电压值。依据容量测试试验获得电池最大可用容量，使用 0.3 C 电流倍率进行恒流恒压充电，以充入电池的容量为截止条件，每充入 10% 的最大可用容量后静置 1 h，记录当前端电压值，直至电池容量充满。静置 1 h，同样采用 0.3 C 的电流倍率对电池进行放电，每放出 10% 的最大可用容量后静置 1 h，记录当前端电压值，与每阶段的 SOC 相对应，OCV 测试结果如图 2 所示。进一步对数据进行多项式拟合，通过式(4)对 OCV 与 SOC 的数据点进行六阶拟合，得到 OCV 与 SOC 的函数对应关系，OCV-SOC 曲线如图 3 所示。

$$U_{\text{OC}}(S_{\text{soc}}) = p_1 S_{\text{soc}}^6 + p_2 S_{\text{soc}}^5 + p_3 S_{\text{soc}}^4 + p_4 S_{\text{soc}}^3 + p_5 S_{\text{soc}}^2 + p_6 S_{\text{soc}} + p_7 \quad (4)$$

式中： $p_i (i = 1, 2, \dots, 7)$ 为多项式拟合系数。

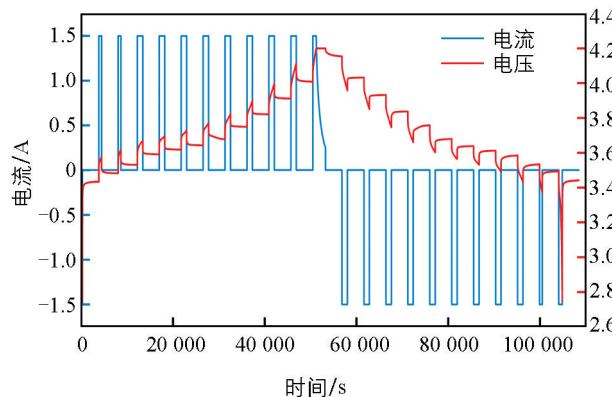


图 2 OCV 测试结果

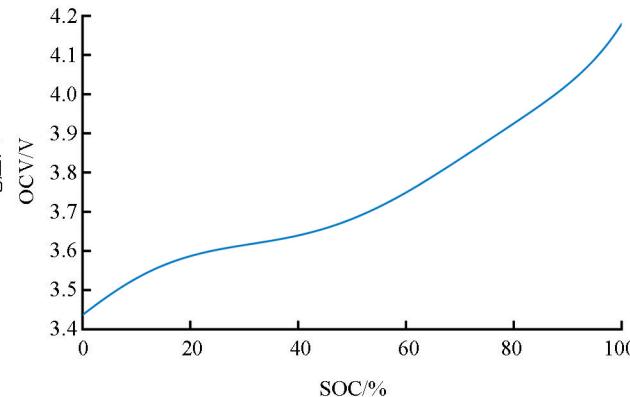


图 3 OCV-SOC 拟合曲线

2.2 基于 UKF 算法的在线参数辨识

为使所建立的模型实现电池端电压预测，需要对电池内部参数进行辨识。参数辨识方法可分为离线参数辨识和在线参数辨识，离线辨识的模型参数固定，不适用于复杂工况^[18]。电池模型中的参数 R_1 、 R_2 、 C_1 、 C_2 和 R_0 会随着电池 SOC 的变化而动态调整，所以本文采用 UKF 算法在线辨识参数，这一算法能够实时地、自适应地更新电池模型中的这些参数，以反映电池状态随时间的变化，从而确保 SOC 的估计结果更加精确。为了便于分析，使用式(5) 表示非线性离散系统：

$$\begin{cases} \boldsymbol{\theta}_{k+1} = \boldsymbol{\theta}_k + \boldsymbol{\rho}_k \\ \mathbf{x}_{k,l+1} = f(\mathbf{x}_{k,l}, \boldsymbol{\theta}_k, \mathbf{I}_{k,l}) + \boldsymbol{\omega}_{k,l} \\ \mathbf{y}_{k,l} = g(\mathbf{x}_{k,l}, \boldsymbol{\theta}_k, \mathbf{I}_{k,l}) + \boldsymbol{v}_{k,l} \end{cases} \quad (5)$$

式中： k 表示时刻； $\boldsymbol{\theta} = [R_0 \ R_1 \ C_1 \ R_2 \ C_2]^T$ ； $\boldsymbol{\omega}_k$ 、 \boldsymbol{v}_k 为系统的过程噪声和观测噪声； $\boldsymbol{\rho}_k$ 为模型参数过程噪声； \mathbf{x} 为 n 维系统状态向量； \mathbf{y} 为 m 维系统输出向量。

UKF 在线参数辨识的具体算法执行流程^[19] 如下所示：

步骤 1 初始话参数变量和协方差矩阵，确定 UKF 算法的参数。 λ 是一个调节参数，用来调节采样点到均值的距离， $\lambda = \alpha^2(M + k_i) - M$ ，其中比例因子 $\alpha = 0.01$ ，次级比例因子 $k_i = 0$ ； M 为模型阶数； β 为非负权重系数，取值 $\beta = 2$ 。

步骤 2 计算 k 时刻采样点。

$$\begin{cases} \boldsymbol{\theta}_k^0 = \boldsymbol{\theta}_k \\ \boldsymbol{\theta}_k^i = \boldsymbol{\theta}_k + \sqrt{(M + \lambda) \mathbf{P}_{\boldsymbol{\theta}_{k-1}}} \\ \boldsymbol{\theta}_k^i = \boldsymbol{\theta}_k - \sqrt{(M + \lambda) \mathbf{P}_{\boldsymbol{\theta}_{k-1}}} \end{cases} \quad (6)$$

步骤 3 计算权重。

$$\left\{ \begin{array}{l} \lambda = \alpha^2 (M + k_i) - M \\ W_m^0 = \frac{\lambda}{M + \lambda}, W_m^i = \frac{1}{2(M + \lambda)}, i = 1, 2, \dots, 2M \\ W_c^0 = \frac{\lambda}{M + \lambda} + 1 - \alpha^2 + \beta, W_c^i = \frac{1}{2(M + \lambda)}, i = 1, 2, \dots, 2M \end{array} \right. \quad (7)$$

步骤 4 计算参数预测值 $\bar{\boldsymbol{\theta}}_{k+1}$ 和系统方差预测值 \mathbf{P}_{xx} .

$$\left\{ \begin{array}{l} \bar{\boldsymbol{\theta}}_{k+1} = \sum_{i=0}^{2M} W_m^i \boldsymbol{\theta}_k^i \\ \mathbf{P}_{xx} = \sum_{i=0}^{2M} [W_c^i (\boldsymbol{\theta}_k^i - \bar{\boldsymbol{\theta}}_{k+1}) (\boldsymbol{\theta}_k^i - \bar{\boldsymbol{\theta}}_{k+1})^T] + \mathbf{Q}_k \end{array} \right. \quad (8)$$

步骤 5 更新预测参数.

$$\left\{ \begin{array}{l} \mathbf{x}_k = f(\mathbf{x}_k, \bar{\boldsymbol{\theta}}_{k+1}, \mathbf{I}_k) + \boldsymbol{\omega}_k \\ \mathbf{y}_k = g(\mathbf{x}_k, \bar{\boldsymbol{\theta}}_{k+1}, \mathbf{I}_k) + \boldsymbol{v}_k \end{array} \right. \quad (9)$$

步骤 6 更新观测值 $\hat{\mathbf{y}}_{k+1}$ 和观测方差预测值 \mathbf{P}_{yy} .

$$\left\{ \begin{array}{l} \hat{\mathbf{y}}_{k+1} = \sum_{i=0}^{2M} W_m^i \mathbf{y}_k^i \\ \mathbf{P}_{yy} = \sum_{i=0}^{2M} [W_c^i (\mathbf{y}_k^i - \hat{\mathbf{y}}_{k+1}) (\mathbf{y}_k^i - \hat{\mathbf{y}}_{k+1})^T] + \mathbf{R}_k \end{array} \right. \quad (10)$$

步骤 7 计算参数变量协方差 \mathbf{P}_{xy} 、无迹卡尔曼增益 \mathbf{K} .

$$\left\{ \begin{array}{l} \mathbf{P}_{xy} = \sum_{i=0}^{2M} W_c^i (\boldsymbol{\theta}_k^i - \bar{\boldsymbol{\theta}}_{k+1}) (\mathbf{y}_k^i - \hat{\mathbf{y}}_{k+1})^T \\ \mathbf{K} = \mathbf{P}_{xy} / \mathbf{P}_{yy} \end{array} \right. \quad (11)$$

步骤 8 观测更新.

$$\left\{ \begin{array}{l} \hat{\boldsymbol{\theta}}_{k+1} = \bar{\boldsymbol{\theta}}_{k+1} + \mathbf{K} (\mathbf{y}_{k+1} - \hat{\mathbf{y}}_{k+1}) \\ \mathbf{P}_k = \mathbf{P}_{xx} - \mathbf{K} \mathbf{P}_{xy}^T \end{array} \right. \quad (12)$$

步骤 9 系统参数更新.

$$\left\{ \begin{array}{l} \mathbf{x}_k = f(\mathbf{x}_k, \hat{\boldsymbol{\theta}}_{k+1}, \mathbf{I}_k) + \boldsymbol{\omega}_k \\ \mathbf{y}_k = g(\mathbf{x}_k, \hat{\boldsymbol{\theta}}_{k+1}, \mathbf{I}_k) + \boldsymbol{v}_k \end{array} \right. \quad (13)$$

2.3 模型参数结果验证

采用城市道路循环(Urban Dynamometer Driving Schedule, UDDS)工况作为在线参数辨识实际工况. UDDS 是一种高功率测试工况, 其特点是汽车加速和减速更为快速和激烈. 在 UDDS 工况下, 电池电压变化很大, 放电电流也相对较大. 这种工况模拟了一种对电池性能要求极高的驾驶环境, 是评估在高功率需求下电池性能的重要手段. 电池在 20 °C 时 UDDS 工况下的实测电压和实测电流如图 4 所示.

为了说明 UKF 算法在线参数辨识结果的准确性和可靠性, 图 5 显示了 UDDS 工况下端电压测量结果与估计结果的对比, 图 6 显示了 2 种辨识方法辨识出的端电压误差, 其中黑线表示遗传算法(GA)离线辨识结果, 红线表示 UKF 在线辨识结果. 由图 5 可知, 由 GA 离线辨识所得模型电压的平均绝对误差(MAE)为 0.054 7, 均方根误差(RMSE)为 0.089 3; 相比之下, 采用 UKF 在线辨识所得模型电压的 MAE 降低至 0.020 2, RMSE 降低至 0.042 1. 图 6 显示在 15 000 s 后端电压误差逐渐增大, 在最后时刻甚至超过 400 mV, 这主要是因为在低电量区间电池内部极化效应加剧的影响, 但总体误差都分布在 50 mV 以内, 这充分证明了通过 UKF 算法进行在线参数辨识所构建的电池模型, 不仅具备高度的精确性, 其误差波动范围也较小, 展现出了良好的鲁棒性.

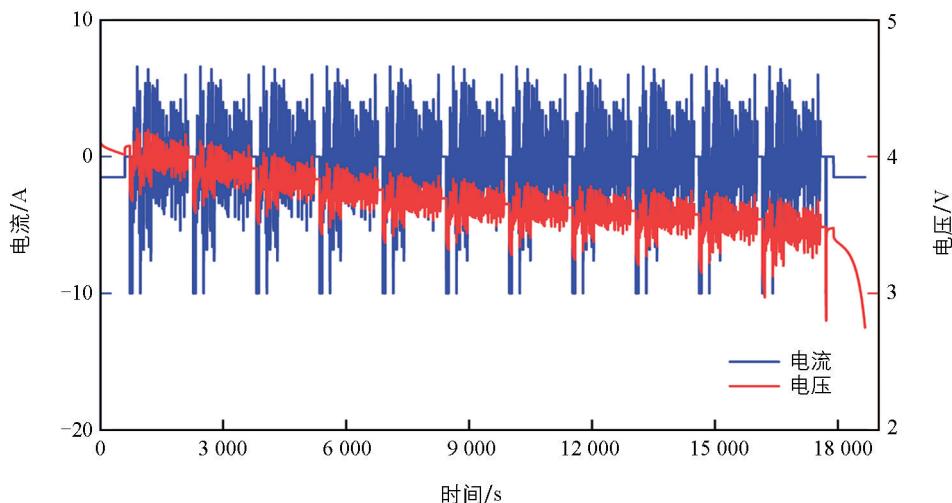


图 4 UDDS 工况电压、电流曲线

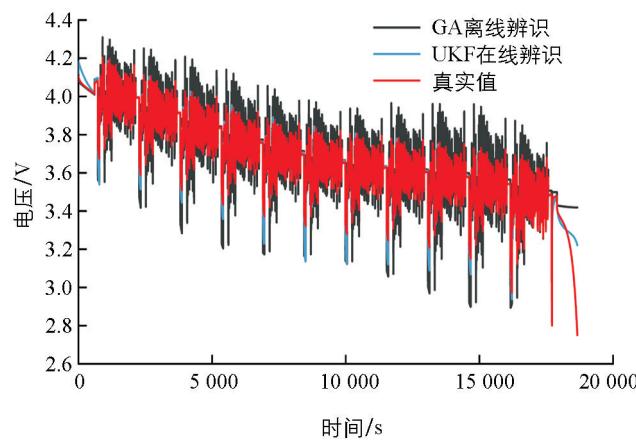


图 5 端电压真实值与估计值对比

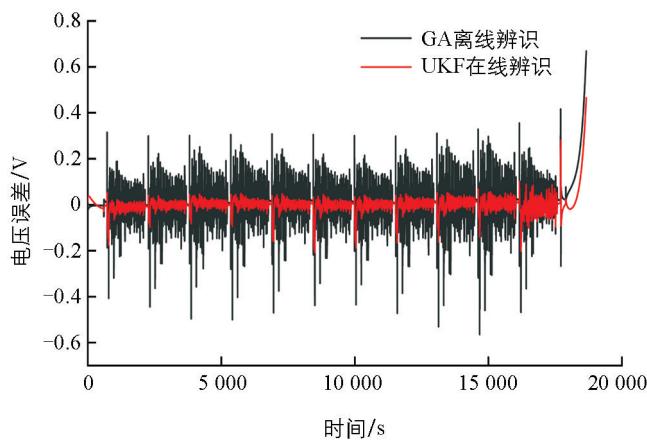


图 6 端电压误差

3 锂电池 SOC 估计

3.1 变分贝叶斯估计原理

在现有的多种估计算法中, 假设噪声协方差 P_k 和 R_k 服从高斯分布^[20]. 高斯白噪声是一种功率谱密度均匀分布的随机变量噪声. 但实际应用中的噪声不可能是理想的高斯白噪声, 噪声协方差随着时间变化而变化, 因此本文引入 VB 方法对 P_k 和 R_k 进行估计以提高卡尔曼滤波器对 X_k 的估计精度.

在将 VB 方法的思想引入到 UKF 中时, 该方法利用逆 Wishart 分布来推断和预测状态变量的观测噪声及其协方差矩阵. 具体来说, 通过 VB 方法, 可以建立一个模型, 其中观测噪声的协方差矩阵被视为一个随机变量, 并假定其先验分布遵循逆 Wishart 分布. 在 UKF 的迭代过程中, 利用 VB 方法不断更新这一先验分布, 结合观测数据来近似得到其后验分布, 从而实现对观测噪声及其协方差矩阵的动态估计和预测. 这样, UKF 在处理含有不确定性的观测噪声时, 能够更加鲁棒和精确. 基于变分贝叶斯自适应时变无迹卡尔曼滤波算法(VBAUKF)的实现过程如下所示:

步骤 1 初始化: 设状态变量 $\mathbf{X} = [S_{soc} \quad U_1 \quad U_2]^T$, 生成 $2n + 1$ 个 sigma 点, 其中 $n = 3$.

步骤 2 确定加权系数 ω_m , ω_c .

步骤 3 得到预测的 sigma 点集后, 根据上一步计算得到的相应权重, 通过加权求和的方式来估计和计算出系统状态的预测值 $\hat{\mathbf{X}}_{k+1|k}$ 和协方差矩阵 $\mathbf{P}_{k+1|k}$.

步骤 4 根据预测值再次进行 UT 变换, 得到新的 sigma 点.

步骤 5 由新的 sigma 点计算预测的观测值 $\hat{\mathbf{Z}}_{k+1|k}$. 然后计算出自协方差 $\mathbf{P}_{z_k|z_k}$ 和交叉协方差 $\mathbf{P}_{x_k|z_k}$.

UKF 中的交叉协方差和自协方差可以理解为交叉协方差和自协方差的 sigma 点逼近. 根据变分原理和贝叶斯分析, 迭代计算预测误差协方差矩阵 \mathbf{P}_k 和观测噪声协方差矩阵 \mathbf{R}_k , 迭代次数 N 根据实际情况选择. 在 UKF 算法中引入迭代的思想如下:

首先, 设置初始迭代参数:

$$\left\{ \begin{array}{l} \hat{x}_{k+1|k+1}^{(0)} = \hat{x}_{k+1|k}, \quad \hat{\mathbf{P}}_{k+1|k+1}^{(0)} = \mathbf{P}_{k+1|k} \\ \hat{t}_{k+1|k} = n + \tau + 1, \quad \hat{\mathbf{T}}_{k+1|k} = \tau \mathbf{P}_{k+1|k} \\ \hat{u}_{k+1|k} = \rho (\hat{u}_{k|k} - m - 1) + m + 1 \\ \hat{\mathbf{U}}_{k+1|k} = \rho \hat{\mathbf{U}}_{k|k} \end{array} \right. \quad (14)$$

式中: $\hat{t}_{k+1|k}$ 和 $\hat{\mathbf{T}}_{k+1|k}$ 分别为协方差矩阵 $\mathbf{P}_{k+1|k}$ 的自由度参数和逆尺度矩阵; $\hat{u}_{k+1|k}$ 和 $\hat{\mathbf{U}}_{k+1|k}$ 分别为协方差矩阵 $\mathbf{R}_{k+1|k}$ 的自由度参数和逆尺度矩阵; n 为状态向量维数; m 为观测维度; τ 为 $\mathbf{P}_{k+1|k}$ 的调节参数; $\tau > 0$, ρ 是 $\hat{\mathbf{U}}_{k+1|k}$ 的遗忘因子, $\rho \in (0, 1]$.

然后, 开始迭代, $j = 1, 2, \dots, N$.

计算预测误差协方差:

$$\left\{ \begin{array}{l} \mathbf{A}_{k+1}^{(j)} = \mathbf{P}_{k+1|k+1}^{(j)} + (x_{k+1|k+1}^{(j)} - \hat{x}_{k+1|k}) (x_{k+1|k+1}^{(j)} - \hat{x}_{k+1|k})^T \\ \hat{t}_{k+1}^{(j+1)} = \hat{t}_{k+1|k} + 1, \quad \hat{\mathbf{T}}_{k+1}^{(j+1)} = \mathbf{A}_{k+1}^{(j)} + \hat{\mathbf{T}}_{k+1|k} \\ \hat{\mathbf{P}}_{k+1|k}^{(j+1)} = \{(\hat{t}_{k+1}^{(j+1)} - n - 1) (\hat{\mathbf{T}}_{k+1}^{(j+1)})^{-1} \}^{-1} \end{array} \right. \quad (15)$$

计算观测噪声协方差:

$$\left\{ \begin{array}{l} \mathbf{B}_{k+1}^{(j)} = (z_{k+1} - \hat{z}_{k+1|k}) (z_{k+1} - \hat{z}_{k+1|k})^T + \mathbf{P}_{z_k|z_k} \\ \hat{u}_{k+1}^{(j+1)} = \hat{u}_{k+1|k} + 1, \quad \hat{\mathbf{U}}_{k+1}^{(j+1)} = \mathbf{B}_{k+1}^{(j)} + \hat{\mathbf{U}}_{k+1|k} \\ \hat{\mathbf{R}}_{k+1}^{(j+1)} = \{ (\hat{u}_{k+1}^{(j+1)} - m - 1) (\hat{\mathbf{U}}_{k+1}^{(j+1)})^{-1} \}^{-1} \end{array} \right. \quad (16)$$

计算无迹卡尔曼增益:

$$\mathbf{K}_{k+1}^{(j+1)} = \mathbf{P}_{x_k|z_k} (\tilde{\mathbf{P}}_{z_k|z_k} + \hat{\mathbf{R}}_{k+1}^{(j+1)})^{-1} \quad (17)$$

计算预测误差协方差:

$$\mathbf{P}_{k+1|k+1}^{(j+1)} = \hat{\mathbf{P}}_{k+1|k}^{(j+1)} - \mathbf{K}_{k+1}^{(j+1)} (\tilde{\mathbf{P}}_{z_k|z_k} + \hat{\mathbf{R}}_{k+1}^{(j+1)}) (\mathbf{K}_{k+1}^{(j+1)})^T \quad (18)$$

循环之后, 输出参数为:

$$\left\{ \begin{array}{l} \hat{x}_{k+1|k+1} = \hat{x}_{k+1|k+1}^{(N)} \\ \mathbf{P}_{k+1|k+1} = \mathbf{P}_{k+1|k+1}^{(N)}, \quad \mathbf{R}_{k+1} = \hat{\mathbf{R}}_{k+1}^{(N)} \\ \hat{t}_{k+1|k+1} = \hat{t}_{k+1}^{(N)}, \quad \hat{\mathbf{T}}_{k+1|k+1} = \hat{\mathbf{T}}_{k+1}^{(N)} \\ \hat{u}_{k+1|k+1} = \hat{u}_{k+1}^{(N)}, \quad \hat{\mathbf{U}}_{k+1|k+1} = \hat{\mathbf{U}}_{k+1}^{(N)} \end{array} \right. \quad (19)$$

在每一次的采样周期结束后, 所得到的预测状态值、预测误差协方差矩阵将作为下一次采样时执行时间更新(预测)和测量更新步骤的初始输入数据, 从而实现滤波器对噪声的不断更新.

3.2 结果分析

为了验证所提出的 UKF-VBAUKF 联合估计算法精度, 对 UDDS 工况下参数辨识所得模型进行 SOC 估计, SOC 的估计结果如图 7 所示, 2 种联合估计算法对应的 SOC 估计误差则通过图 8 进行了详细比较和呈现.

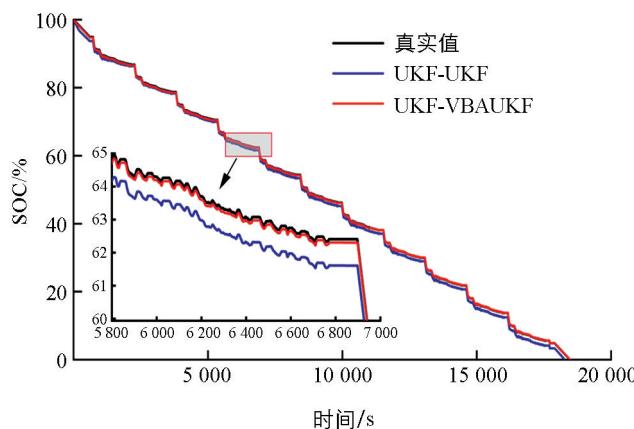


图 7 UDDS 工况下的 SOC 估计

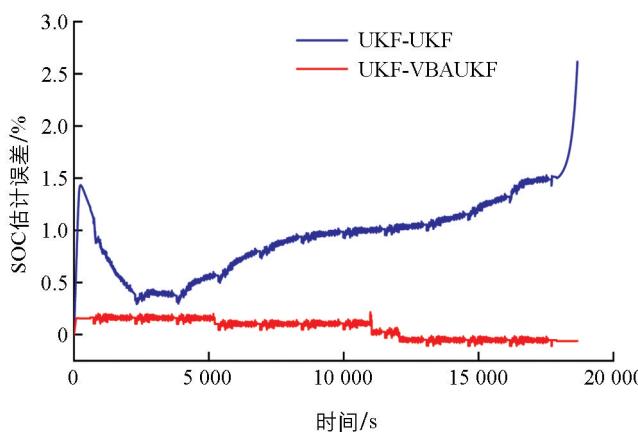


图 8 SOC 估计误差

从图 7 和图 8 可以看出,相较于其他方法,本文提出的 UKF-VBAUKF 算法 SOC 估计结果最为接近真实值,且在整个放电过程中均能保持稳定的估计性能。进一步分析表 1 中列出的 SOC 误差数据,可以看出 UKF-VBAUKF 算法在平均绝对误差(MAE)和均方根误差(RMSE)方面的优异表现,其中 MAE 低至 0.001 0, RMSE 低至 0.001 1。这一结果表明,本文提出的 UKF-VBAUKF 算法有效解决了 SOC 估计过程中因噪声时变性带来的挑战,使得 SOC 的估计误差更加平稳,显著提升了估计结果的鲁棒性和准确性。

表 1 2 种算法 SOC 误差分析

算法	平均绝对误差(MAE)	均方根误差(RMSE)
UKF-UKF	0.009 5	0.010 2
UKF-VBAUKF	0.001 0	0.001 1

4 结论

本文首先建立了二阶 RC 等效电路模型,采用 UKF 算法在线辨识模型参数,并且在 UDDS 工况下与离线辨识的端电压误差结果进行比较,验证了 UKF 在线辨识的模型精度。然后引入变分贝叶斯滤波对协方差 P_k 和 R_k 进行建模并迭代预测,采用 UKF-VBAUKF 联合估计算法估计锂离子动力电池 SOC,将 SOC 的 MAE 降低至 0.001 0, RMSE 降低至 0.001 1, 解决了复杂工况下锂离子动力电池 SOC 估计过程中受噪声协方差时变影响的问题。最后在 UDDS 工况下与其他 SOC 估计算法进行对比分析,验证了本文所提算法的精确性和鲁棒性。

参考文献:

- [1] CHEN C, XIONG R, YANG R X, et al. A Novel Data-Driven Method for Mining Battery Open-Circuit Voltage Characterization [J]. Green Energy and Intelligent Transportation, 2022, 1(1): 100001.
- [2] LI H, BIN KALEEM M, LIU Z J, et al. IoB: Internet-of-Batteries for Electric Vehicles-Architectures, Opportunities, and Challenges [J]. Green Energy and Intelligent Transportation, 2023, 2(6): 100128.
- [3] HOU J Y, XU J, LIN C P, et al. State of Charge Estimation for Lithium-Ion Batteries Based on Battery Model and Data-Driven Fusion Method [J]. Energy, 2024, 290: 130056.
- [4] FANG D Y, WU W T, LI J F, et al. Performance Simulation Method and State of Health Estimation for Lithium-Ion Batteries Based on Aging-Effect Coupling Model [J]. Green Energy and Intelligent Transportation, 2023, 2(3): 100082.
- [5] 张兴红,徐翊,巩泽浩.融合电化学阻抗与容量增量曲线特征的锂电池健康状态算法研究 [J].重庆理工大学学报(自然科学),2023,37(10): 265-272.
- [6] WANG J, ZHOU J H, ZHAO W Z. Deep Reinforcement Learning Based Energy Management Strategy for Fuel Cell/

- Battery/Supercapacitor Powered Electric Vehicle [J]. Green Energy and Intelligent Transportation, 2022, 1(2): 100028.
- [7] CHAI X Q, LI S H, LIANG F W. A Novel Battery SOC Estimation Method Based on Random Search Optimized LSTM Neural Network [J]. Energy, 2024, 306: 132583.
- [8] ZHOU Z Y, LIU Y G, YOU M X, et al. Two-Stage Aging Trajectory Prediction of LFP Lithium-Ion Battery Based on Transfer Learning with the Cycle Life Prediction [J]. Green Energy and Intelligent Transportation, 2022, 1(1): 100008.
- [9] FU B Z, WANG W, LI Y H, et al. An Improved Neural Network Model for Battery Smarter State-of-Charge Estimation of Energy-Transportation System [J]. Green Energy and Intelligent Transportation, 2023, 2(2): 100067.
- [10] 高铭琨, 徐海亮, 吴明铂. 基于等效电路模型的动力电池 SOC 估计方法综述 [J]. 电气工程学报, 2021, 16(1): 90-102.
- [11] 陈正, 王志得, 牟文彪, 等. 基于 PNGV 模型与自适应卡尔曼滤波的铅炭电池荷电状态评估 [J]. 储能科学与技术, 2023, 12(3): 941-950.
- [12] SHEN D X, YANG D Z, LYU C, et al. Detection and Quantitative Diagnosis of Micro-Short-Circuit Faults in Lithium-Ion Battery Packs Considering Cell Inconsistency [J]. Green Energy and Intelligent Transportation, 2023, 2(5): 100109.
- [13] HE J T, MENG S J, YAN F J. A Comparative Study of SOC Estimation Based on Equivalent Circuit Models [J]. Frontiers in Energy Research, 2022, 10: 914291.
- [14] 周坤, 张春阳, 何佳琦. 不同温度下的锂电池 SOC 联合估算 [J]. 重庆理工大学学报(自然科学), 2023, 37(7): 336-342.
- [15] WANG Q Q, KANG J Q, TAN Z X, et al. An Online Method to Simultaneously Identify the Parameters and Estimate States for Lithium Ion Batteries [J]. Electrochimica Acta, 2018, 289: 376-388.
- [16] HUANG Y L, ZHANG Y G, WU Z M, et al. A Novel Adaptive Kalman Filter with Inaccurate Process and Measurement Noise Covariance Matrices [J]. IEEE Transactions on Automatic Control, 2018, 63(2): 594-601.
- [17] QIN S, QIN D C, WU H X, et al. State of Charge Estimation of Lithium-Ion Power Battery Based on Online Parameter Identification Method and BP Neural Network [J]. International Journal of Electrochemical Science, 2022, 17(1): 220138.
- [18] 卢云帆, 邢丽坤, 张梦龙, 等. 基于 UKF-AUKF 锂电池在线参数辨识和 SOC 联合估计 [J]. 电源技术, 2022, 46(10): 1151-1155.
- [19] DUAN W X, SONG C X, CHEN Y, et al. Online Parameter Identification and State of Charge Estimation of Battery Based on Multitimescale Adaptive Double Kalman Filter Algorithm [J]. Mathematical Problems in Engineering, 2020, 2020: 9502605.
- [20] YUN Z H, QIN W H, SHI W P. State of Charge Estimation of Lithium-Ion Battery under Time-Varying Noise Based on Variational Bayesian Estimation Methods [J]. Journal of Energy Storage, 2022, 52: 104916.

责任编辑 柳剑
崔玉洁