

# 采用改进最大相关熵自适应迭代容积卡尔曼滤波算法的锂离子电池荷电状态估计

巫春玲<sup>1</sup>, 赵玉冰<sup>1</sup>, 马耀<sup>1</sup>, 张湧<sup>1</sup>, 孟锦豪<sup>2</sup>

(1. 长安大学能源与电气工程学院, 710064, 西安; 2. 西安交通大学电气工程学院, 710049, 西安)

**摘要:** 针对非高斯噪声干扰下传统滤波算法在估计锂离子电池荷电状态(SOC)时存在不稳定以及精度低的问题,提出一种改进的最大相关熵自适应迭代容积卡尔曼滤波(IMCC-AICKF)算法,用于估计锂离子电池荷电状态。所提算法将加权最小二乘方法与最大相关熵准则(MCC)相结合,定义了一种新的代价权函数作为优化准则,通过优化噪声最小协方差矩阵来减小滤波误差,保证长时间滤波的收敛性和稳定性;再与自适应迭代容积卡尔曼滤波(AICKF)算法相结合,对过程噪声协方差和测量噪声协方差进行更新来提高估计的准确性和鲁棒性。基于两种电池数据,在非高斯噪声干扰下,运用所提算法对电池SOC进行估计,仿真结果表明:与容积卡尔曼滤波(CKF)算法和最大相关熵容积卡尔曼滤波(IMCC-CKF)算法相比,IMCC-AICKF算法对荷电状态估计的最大绝对误差、平均绝对误差和均方根误差都是最小的,且平均绝对误差和均方根误差均小于1%;在给定初始值错误的情况下,IMCC-AICKF算法可以准确收敛到真实值,具有较好的鲁棒性。所提算法在非高斯噪声下能实现更准确的估计,是一种估计精度高且鲁棒性好的SOC估计方法。

**关键词:** 荷电状态估计;最大相关熵准则;容积卡尔曼滤波;非高斯噪声;鲁棒性

**中图分类号:** TM912 **文献标志码:** A

**DOI:** 10.7652/xjtuxb202411005 **文章编号:** 0253-987X(2024)11-0052-13

## Estimation of Lithium-Ion Battery State of Charge Using an Innovation Maximum Correlation-Entropy Criterion Adaptive Iterative Cubature Kalman Filter Algorithm

WU Chunling<sup>1</sup>, ZHAO Yubing<sup>1</sup>, MA Yao<sup>1</sup>, ZHANG Yong<sup>1</sup>, MENG Jinhao<sup>2</sup>

(1. School of Energy and Electrical Engineering, Chang'an University, Xi'an 710064, China;

2. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** In response to the issues of instability and low accuracy in estimating the state of charge (SOC) of lithium-ion batteries under non-Gaussian noise interference traditional filtering algorithms, an innovation maximum correlation-entropy criterion adaptive iterated cubature Kalman filtering algorithm (IMCC-AICKF) is proposed for SOC estimation of lithium-ion batteries. The proposed algorithm combines the weighted least squares method with the maximum correlation-entropy criterion (MCC) to define a new cost-weight function as the optimization criterion. This approach aids in reducing filtering errors by optimizing the minimum noise covariance matrix to reduce

收稿日期: 2024-04-22。 作者简介: 巫春玲(1978—),女,副教授,硕士生导师。 基金项目: 国家重点研发计划资助项目(2021YFB2601304);陕西省重点研发计划资助项目(2022GY-193);陕西省教育厅服务地方专项科学研究计划资助项目(23JE021)。

网络出版时间: 2024-08-08

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20240806.1458.002>

filtering errors and stability of long-term filtering. Subsequently, by integrating with the adaptive iterative covariance Kalman filter (AICKF), the process noise covariances and measurement noise covariances are updated to enhance estimation accuracy and robustness. Based on two sets of battery data and under non-Gaussian noise interference, the proposed algorithm is applied to estimate the SOC of the batteries. The simulation results demonstrate that compared to cubature Kalman filtering (CKF) and innovation maximum correlation-entropy criterion cubature Kalman filtering (IMCC-CKF), the IMCC-AICKF algorithm yields the smallest maximum absolute error (MaxAE), mean absolute error (MAE), and root mean square error (RMSE) in SOC estimation, with both MAE and RMSE below 1%. Additionally, even with initial value errors, IMCC-AICKF can accurately converge to the true values, demonstrating good robustness. The proposed algorithm achieves more accurate estimation under non-Gaussian noise, providing a high-precision and robust method for SOC estimation.

**Keywords:** state of charge estimation; maximum correlation-entropy criterion; cubature Kalman filter; non-Gaussian noise; robustness

锂离子电池因其具有能量密度高、自放电率低、循环寿命长等优势,在电动汽车中被广泛运用<sup>[1-3]</sup>。电池管理系统(BMS)对保障电动汽车的安全稳定运行起着至关重要的作用,其中电池荷电状态(SOC)估计在BMS中起着不可或缺的作用。SOC的准确估计是提高电池使用的安全性、准确性和可靠性的重要保障<sup>[4]</sup>。锂离子电池作为一个复杂的非线性系统,受到许多因素的影响,这些因素的变化会导致电池特性和行为的非线性变化,使得准确估计电池的荷电状态成为一个具有挑战性的问题。

SOC估计方法大致可分为传统方法(主要包括安时积分法<sup>[5]</sup>和开路电压(OCV)法<sup>[6]</sup>)、数据驱动方法<sup>[7]</sup>和基于模型的方法<sup>[8]</sup>。安时积分法容易实现,但是随着时间的推移,SOC的估计精度很容易受到累积误差的影响<sup>[9]</sup>。电池在静态平衡状态下的稳定电压被视为开路电压。开路电压法是一种相对简单且常用的方法,但是由于电池内部复杂的扩散效应和极化机制,电池需要数小时才能达到静态平衡状态<sup>[10]</sup>。在电动汽车等对精度要求较高的应用场景中,传统的开路电压法可能无法满足高精度的能源管理需求。在实际应用中,这种方法可能会受到温度变化、充放电速率、循环寿命等因素的影响,从而导致估计结果的不确定性。由于这些常见缺陷,传统方法不适合高精度的电动汽车能源管理。

数据驱动方法,例如神经网络<sup>[11]</sup>、极限学习机<sup>[12]</sup>和支持向量机<sup>[13]</sup>等已被广泛应用于SOC估计,利用机器学习和数据分析技术来建立SOC估计模型。通过分析大量的实验数据,训练出适应各种工况的SOC估计模型。这种方法能够提高估计精

度,尤其在复杂环境下表现较好。然而,数据驱动必须使用大量数据进行模型训练并验证其准确性,数据的质量和来源对训练效果有很大影响。因此,数据驱动方法在SOC估计的实际应用中面临着诸多挑战。

相对于传统估计方法和数据驱动方法来说,基于模型的方法在电池SOC估计中具有独特的优势。基于模型的方法是通过建立等效电路模型来对SOC进行估计<sup>[14]</sup>,具有较低的计算复杂性和较高的估计精度。目前最常用的算法是卡尔曼滤波算法及其衍生算法<sup>[15-16]</sup>,这些算法在状态估计中具有显著的优势<sup>[17]</sup>。然而,这些算法在处理非线性系统时确实存在一些局限性,需要针对不同的应用场景进行选择。扩展卡尔曼滤波(EKF)<sup>[18]</sup>通过线性化非线性系统来简化计算,但可能导致高阶损失误差和估计性能下降。无迹卡尔曼滤波(UKF)<sup>[19]</sup>利用无迹变换和进行sigma点采样来处理非线性系统,但在状态维度较高时可能会导致稳定性下降。容积卡尔曼滤波(CKF)<sup>[20]</sup>算法则使用球面径向容积法则,具有更高的稳定性和适用于更高维度的非线性滤波问题的优势。为了不断优化和提高状态估计的精度,文献[21]提出迭代容积卡尔曼滤波(ICKF)算法,通过对状态更新过程进行多次迭代,来提高CKF的估计精度及稳定性。然而,这种算法可能会造成计算浪费。为了解决这个问题,文献[22]在ICKF算法的基础上提出自适应迭代容积卡尔曼滤波(AICKF)算法,对过程噪声和测量噪声进行修正,提高估计精度并减少不必要的计算。以上算法在高频噪声干扰下估计效果较好,但是无法很好地处理

非高斯分布的测量噪声,因为其基于最小均方误差(MMSE)准则导出,适应能力有限。


为了更好地解决此问题,将最大相关熵准则(MCC)与卡尔曼滤波算法相结合应用于锂离子电池的 SOC 估计,例如最大相关熵卡尔曼滤波(MCC-KF)<sup>[23]</sup>、MCC-EKF<sup>[24]</sup>、MCC-AEKF<sup>[25]</sup>、MCC-UKF<sup>[26]</sup>和 MCC-CKF<sup>[27]</sup>算法等。在 MCC 中通常使用高斯核函数。研究表明,在抑制非高斯噪声方面,基于 MCC 改进的一系列算法显著提高了 SOC 估计的精度。

为了使估计性能得到进一步提高,本文将最大相关熵和加权最小二乘(WLS)<sup>[28-30]</sup>相结合,然后结合 AICKF 算法的优势,提出一种改进的最大相关熵加权最小二乘自适应迭代容积卡尔曼滤波(IMCC-AICKF)算法。该算法通过准确估计电池的荷电状态,可以延长电池寿命、优化能量管理策略,并提升系统的性能和安全性。此外,该算法对于其他领域中非高斯噪声下的状态估计问题也具有借鉴意义。实验结果表明,所提算法可以更好地进行非高斯噪声干扰下的电池 SOC 估计且鲁棒性好。

## 1 电池建模和参数辨识

### 1.1 二阶 RC 等效电路模型

锂电池内部涉及复杂的化学反应,建立一个准确的锂电池模型需要考虑锂电池的动态特性、非线性响应以及外部环境的相互作用<sup>[31-32]</sup>。本文采用的二阶 RC 等效电路模型(ECM)如图 1 所示,具有结构简单、计算量小、精度高等优点。



$U_{OC}$ —开路电压; $U_t$ —电池端电压; $R_0$ —欧姆电阻;  
 $R_1$ 、 $C_1$ —电化学极化电阻、电容; $R_2$ 、 $C_2$ —浓差极化电阻、  
电容; $U_1$ 、 $U_2$ —电化学极化电压、浓差极化电压; $I$ —通过锂  
离子电池的电流。

图 1 二阶 RC 等效电路模型

Fig. 1 Second-order RC equivalent circuit model

通常使用  $\mathbf{x}_k = [U_{1,k} \ U_{2,k} \ \beta_{SOC,k}]^T$  表示状态向量, $\mathbf{z}_k$  表示  $k$  时刻的观测量。其中, $U_{1,k}$ 、 $U_{2,k}$  分别表示  $k$  时刻第 1、2 个 RC 网络的电压; $\beta_{SOC,k}$  表示  $k$

时刻电池的荷电状态。此时,非线性系统的状态方程和测量方程可以表示为

$$\begin{cases} \mathbf{x}_k = f(\mathbf{x}_{k-1}) + \mathbf{w}_{k-1} \\ \mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{v}_k \end{cases} \quad (1)$$

式中: $f(\cdot)$ 和 $h(\cdot)$ 分别表示系统的状态转移函数和观测函数; $\mathbf{w}_{k-1}$ 和 $\mathbf{v}_k$ 分别为过程噪声和观测噪声,两者之间不相关,都服从正态分布, $\mathbf{w}_k \sim N(0, \mathbf{Q}_k)$ , $\mathbf{v}_k \sim N(0, \mathbf{R}_k)$ , $\mathbf{Q}_k$ 为过程噪声协方差矩阵; $\mathbf{R}_k$ 为观测噪声均方差矩阵。

根据二阶 RC 等效电路模型,系统的离散状态方程和测量方程可以表示为

$$\begin{bmatrix} U_{1,k+1} \\ U_{2,k+1} \\ \beta_{SOC,k+1} \end{bmatrix} = \begin{bmatrix} e^{-\Delta t/(R_1 C_1)} & 0 & 0 \\ 0 & e^{-\Delta t/(R_2 C_2)} & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} U_{1,k} \\ U_{2,k} \\ \beta_{SOC,k} \end{bmatrix} + \begin{bmatrix} (1 - e^{-\Delta t/(R_1 C_1)})R_1 \\ (1 - e^{-\Delta t/(R_2 C_2)})R_2 \\ -\Delta t/\epsilon \end{bmatrix} I_k + \begin{bmatrix} \omega_{1,k} \\ \omega_{2,k} \\ \omega_{3,k} \end{bmatrix} \quad (2)$$

$$U_{t,k} = U_{OC,k} - U_{1,k} - U_{2,k} - I_{1,k}R_0 + v_k \quad (3)$$

式中: $I_k$ 为 $k$ 时刻的电流; $\epsilon$ 为电池的容量; $\Delta t$ 为采样时间间隔; $[\omega_{1,k} \ \omega_{2,k} \ \omega_{3,k}]^T$ 为系统的过程噪声; $v_k$ 为测量噪声。

### 1.2 开路电压与 SOC 关系

在锂离子电池中,开路电压 $U_{OC}$ 是指在没有外部负载的情况下测量得到的电池端电压。在充放电过程中,由于电池内部发生着多种复杂的化学反应,导致 OCV 随着 SOC 的变化呈现出非线性而难以预测。

本文选择了标称容量/标称电压为  $35 \text{ A} \cdot \text{h}/3.7 \text{ V}$  的  $\text{LiMn}_2\text{O}_4$  锂离子电池(命名为电池 B1)和标称容量/标称电压为  $1.5 \text{ A} \cdot \text{h}/3.6 \text{ V}$  的 ICR18650 单体电池(命名为电池 B2)作为实验对象,电池 B1 的数据由北京理工大学先进储能科学与应用课题组获得,电池 B2 数据是由蓝电 CT6001A 电池测试仪测量得到。

为了获得相对准确的荷电状态-开路电压曲线,分别对电池 B1 和电池 B2 进行完整的充放电实验。首先,将电池在  $25^\circ\text{C}$  的环境下充满电,让其静置一段时间达到相对稳定的状态,并记录此时的端电压作为  $\beta_{SOC}=100\%$  时的  $U_{OC}$  值。然后进行一段固定时间的恒流放电操作,等待足够长的时间使电池内部反应达到稳定状态,记录稳定时的电池端电压作为该时刻荷电状态对应的开路电压。重复放电操作直到电池完全放电,并记录每次放电操

作的次数,将不同荷电状态对应的开路电压记录下来,最终得到一条完整的放电过程的荷电状态-开路电压曲线。

充电过程与放电过程类似。为了准确描述开路电压和荷电状态之间的函数关系,首先将荷电状态-开路电压数据导入到 Matlab 中,然后使用 Curve Fitting 工具箱进行多项式拟合,并设置合适的多项式次数来拟合出最佳多项式曲线,以描述开路电压和荷电状态的关系,如图 2、图 3 所示。




图 2 电池 B1 的荷电状态-开路电压曲线  
Fig. 2 SOC-OCV curve of battery B1




图 3 电池 B2 的荷电状态-开路电压曲线  
Fig. 3 SOC-OCV curve of battery B2

为了更加确切地描述荷电状态-开路电压的函数关系,选取 8 次多项式对电池 B1 进行荷电状态和开路电压拟合,拟合方程如下

$$U_{OC} = 3.557 + 0.8617\beta_{SOC} + 3.65\beta_{SOC}^2 - 23.58\beta_{SOC}^3 + 50.43\beta_{SOC}^4 - 44.24\beta_{SOC}^5 + 9.22\beta_{SOC}^6 + 5.628\beta_{SOC}^7 - 1.371\beta_{SOC}^8 \quad (4)$$

由于多项式次数影响曲线的拟合效果。在完成拟合以后,使用均方根误差(RMSE, 设为  $\xi_{RMSE}$ )、决定系数(R-square, 设为  $R^2$ )、误差平方和(SSE, 设为  $\xi_{SSE}$ )来评价拟合效果的优劣。本文选取 5~8 次多

项式对电池 B2 进行拟合,分析结果见表 1。

表 1 电池 B2 荷电状态-开路电压曲线拟合误差  
Table 1 SOC-OCV curve fitting error of battery B2

| 多项式次数 | $\xi_{RMSE}$ | $R^2$    | $\xi_{SSE}$           |
|-------|--------------|----------|-----------------------|
| 5     | 0.008 64     | 0.999 38 | $2.99 \times 10^{-4}$ |
| 6     | 0.005 44     | 0.999 81 | $8.88 \times 10^{-5}$ |
| 7     | 0.006 02     | 0.999 32 | $7.26 \times 10^{-5}$ |
| 8     | 0.005 39     | 0.999 94 | $2.90 \times 10^{-5}$ |

根据表 1 可以看出,随着多项式次数的增加,当多项式次数为 8 时, $\xi_{RMSE}$  与  $\xi_{SSE}$  相对于前边其他阶次数据更接近于 0,而  $R^2$  更加接近于 1,表明在 8 阶时拟合效果较好,因此选择 8 次多项式进行拟合,则电池 B2 的荷电状态和开路电压之间的映射关系如下

$$U_{OC} = 4.206 - 18.47\beta_{SOC} + 179.3\beta_{SOC}^2 - 859.2\beta_{SOC}^3 + 2355\beta_{SOC}^4 - 3852\beta_{SOC}^5 + 3724\beta_{SOC}^6 - 1967\beta_{SOC}^7 + 437.8\beta_{SOC}^8 \quad (5)$$

1.3 参数辨识

准确的参数辨识直接影响着电池模型的精度,本节使用最小二乘拟合法进行参数辨识来得到模型未知参数  $R_0$ 、 $R_1$ 、 $C_1$ 、 $R_2$ 、 $C_2$  与  $\beta_{SOC}$  之间的关系。使用脉冲电流在不同的  $\beta_{SOC}$  下对电池进行放电,在放电过程中,由于欧姆内阻的作用导致电压急剧下降,当电流放电完成时,电压会因为电化学反应的动态平衡而逐渐回升,并趋于稳定,然后通过记录这些电压和电流,用最小二乘拟合法进行参数辨识,得到各参数与  $\beta_{SOC}$  的关系。电池 B1、B2 的辨识结果的拟合曲线如图 4、图 5 所示。




图 4 电池 B1 的模型参数和荷电状态的拟合曲线  
Fig. 4 Model parameters of the battery B1 and the fitting curve of the state of charge






图 5 电池 B2 的模型参数和荷电状态的拟合曲线

Fig. 5 Model parameters of the battery B2 and the fitting curve of the state of charge

由辨识的结果可知,不同荷电状态参数辨识的结果是不同的,最小二乘拟合法得出的各参数随着荷电状态动态变化,因此为了获得准确的模型精度,需要根据不同荷电状态选择相应的参数。

## 2 基于改进的最大相关熵自适应迭代容积卡尔曼滤波算法

### 2.1 最大相关熵准则

对于任意两个随机变量  $X$  和  $Y$ ,最大相关熵<sup>[33]</sup>可定义为

$$V_o(X, Y) = E[G_o(X - Y)] = \iint_{x, y} G_o(x - y) dF_{X, Y}(x, y) \quad (6)$$

式中:  $E[\cdot]$  为期望算子;  $F_{X, Y}(x, y)$  为联合概率密度函数;  $G_o(\cdot)$  为满足 Mercer 定理且核宽度为  $\sigma$  的核函数。由于高斯核函数对非线性模型具有无限逼近能力,因此本文采用高斯核函数,其表达式为

$$G_o(x - y) = e^{-\|x - y\|^2 / 2\sigma^2} \quad (7)$$

### 2.2 改进的最大相关熵容积卡尔曼滤波

相较于传统的最大相关熵,本文将 MCC 和 WLS 相结合,并将两者加入到 CKF 算法中形成改进的最大相关熵容积卡尔曼滤波(IMCC-CKF),使其收敛性好、精度高、稳定性好。一方面,利用 MCC 准则来处理非高斯噪声,通过引入高斯核函数来表征非高斯噪声的高阶信息;另一方面, WLS 对模型起到修正作用,将测量噪声协方差矩阵和先验误差协方差矩阵引入最大相关熵准则中修改代价函数,进一步提高了 SOC 的估计精度<sup>[33]</sup>。

IMCC-CKF 算法包括时间更新和测量更新两个步骤,具体的实现步骤<sup>[30]</sup>如下。

在算法迭代开始前需要对一系列参数进行初始化,给出初始状态值  $\mathbf{x}_0$  与误差协方差矩阵初始值  $\mathbf{P}_0$ 。

**步骤 1(时间更新)** 容积点由状态估计值  $\hat{\mathbf{x}}_{k-1}$  和误差协方差矩阵估计值  $\mathbf{P}_{k-1}$  生成

$$\begin{cases} \mathbf{S}_{k-1} = \text{chol}(\mathbf{P}_{k-1}) \\ \mathbf{x}_{k-1}^{(i)} = \mathbf{S}_{k-1} \boldsymbol{\zeta}_i + \hat{\mathbf{x}}_{k-1} \end{cases} \quad (8)$$

式中:  $\text{chol}(\cdot)$  代表 Cholesky 分解;  $\mathbf{S}_{k-1}$  为  $\mathbf{P}_{k-1}$  Cholesky 分解得到;  $\mathbf{x}_{k-1}^{(i)}$  为  $k-1$  时刻的第  $i$  个容积点,  $i=1, 2, \dots, 2n$ ;  $\boldsymbol{\zeta}_i$  表示容积点集,具体表达式如下

$$\boldsymbol{\zeta}_i = \begin{cases} \sqrt{n}[\boldsymbol{\delta}]_i, i = 1, 2, \dots, n \\ -\sqrt{n}[\boldsymbol{\delta}]_i, i = n+1, n+2, \dots, 2n \end{cases} \quad (9)$$

其中  $[\boldsymbol{\delta}]_i$  为第  $i$  个容积点,表示为  $[\boldsymbol{\delta}]_i = [\mathbf{I}_n \quad -\mathbf{I}_n]$ ,其中  $\mathbf{I}_n$  是  $n \times n$  的单位矩阵。

经非线性状态函数  $f(\cdot)$  传播的容积点  $\mathbf{x}_{k|k-1}^{*(i)}$  为

$$\mathbf{x}_{k|k-1}^{*(i)} = f(\mathbf{x}_{k-1}^{(i)}) \quad (10)$$

先验状态值  $\hat{\mathbf{x}}_{k|k-1}$  为

$$\hat{\mathbf{x}}_{k|k-1} = \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{x}_{k|k-1}^{*(i)} \quad (11)$$

先验误差协方差矩阵  $\mathbf{P}_{k|k-1}$  为

$$\mathbf{P}_{k|k-1} = \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{x}_{k|k-1}^{*(i)} \mathbf{x}_{k|k-1}^{*(i)T} - \hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{x}}_{k|k-1}^T + \mathbf{Q}_{k-1} \quad (12)$$

**步骤 2(测量更新)** 通过  $\hat{\mathbf{x}}_{k|k-1}$  和  $\mathbf{P}_{k|k-1}$  重新进行容积点采样

$$\begin{cases} \mathbf{S}_{k|k-1} = \text{chol}(\mathbf{P}_{k|k-1}) \\ \mathbf{x}_{k|k-1}^{(i)} = \mathbf{S}_{k|k-1} \boldsymbol{\zeta}_i + \hat{\mathbf{x}}_{k|k-1} \end{cases} \quad (13)$$

容积点传递值与预测测量值的表达式分别为

$$\mathbf{z}_{k|k-1}^{(i)} = h(\mathbf{x}_{k|k-1}^{(i)}) \quad (14)$$

$$\hat{\mathbf{z}}_{k|k-1} = \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{z}_{k|k-1}^{(i)} \quad (15)$$

式中:  $\mathbf{z}_{k|k-1}^{(i)}$  表示非线性测量函数  $h(\cdot)$  对容积点进行二次传播。

预测的测量误差协方差矩阵为

$$\mathbf{P}_{z, k|k-1} = \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{z}_{k|k-1}^{(i)} \mathbf{z}_{k|k-1}^{(i)T} - \hat{\mathbf{z}}_{k|k-1} \hat{\mathbf{z}}_{k|k-1}^T + \mathbf{R}_{k-1} \quad (16)$$

互协方差矩阵  $\mathbf{P}_{x, k|k-1}$  为

$$\mathbf{P}_{x, k|k-1} = \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{x}_{k|k-1}^{(i)} \mathbf{z}_{k|k-1}^{(i)T} - \hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{z}}_{k|k-1}^T \quad (17)$$

伪测量矩阵  $\mathbf{H}_k$  为

$$\mathbf{H}_k = \mathbf{P}_{x_k, k|k-1}^T \mathbf{P}_{k|k-1}^{-1} \quad (18)$$

则测量函数可以近似表示为

$$\mathbf{z}_k \approx h(\hat{\mathbf{x}}_k | k-1) + \frac{\partial h}{\partial \mathbf{x}_k} \bigg|_{\mathbf{x}_k = \hat{\mathbf{x}}_k | k-1} (\mathbf{x}_k - \hat{\mathbf{x}}_k | k-1) + \mathbf{v}_k \approx \hat{\mathbf{z}}_k | k-1 + \mathbf{H}_k (\mathbf{x}_k - \hat{\mathbf{x}}_k | k-1) + \mathbf{v}_k \quad (19)$$

将 WLS 和高斯核结合,就是在高斯核函数中加入相关权重矩阵  $\mathbf{R}_k^{-1}$  和  $\mathbf{P}_{k|k-1}$ ,即采用基于权重矩阵的高斯核函数的代价函数为

$$J_{\text{MCC}}(\mathbf{x}_k) = G_\sigma \left( \left\| \mathbf{x}_k - \hat{\mathbf{x}}_k | k-1 \right\|_{(\mathbf{P}_{k|k-1}^{-1})}^2 \right) + G_\sigma \left( \left\| \mathbf{z}_k - \hat{\mathbf{z}}_k | k-1 - \mathbf{H}_k (\mathbf{x}_k - \hat{\mathbf{x}}_k | k-1) \right\|_{\mathbf{R}_k^{-1}}^2 \right) \quad (20)$$

式中,  $\left\| \cdot \right\|_A^2 = (\cdot)^T \mathbf{A} (\cdot)$  表示向量  $\mathbf{A}$  加权平方马氏距离。重新定义具有马氏距离平方的高斯核为

$$G_\sigma \left( \left\| \cdot \right\|_A^2 \right) = e^{-\left\| \cdot \right\|_A^2 / 2\sigma^2} \quad (21)$$

通过最大化目标函数得到了  $\mathbf{x}_k$  的最优估计

$$\hat{\mathbf{x}}_k = \underset{\mathbf{x}_k}{\text{argmax}} J_{\text{MCC}}(\mathbf{x}_k) \quad (22)$$

然后解决优化问题,求解

$$\frac{\partial J_{\text{MCC}}(\mathbf{x}_k)}{\partial \mathbf{x}_k} = 2\mathbf{P}_{k|k-1}^{-1} (\mathbf{x}_k - \hat{\mathbf{x}}_k | k-1) - 2L_k \mathbf{H}_k^T \mathbf{R}_k^{-1} \cdot (\mathbf{z}_k - \hat{\mathbf{z}}_k | k-1 - \mathbf{H}_k (\mathbf{x}_k - \hat{\mathbf{x}}_k | k-1)) \quad (23)$$

$$L_k = G_\sigma \left( \left\| \mathbf{z}_k - \hat{\mathbf{z}}_k | k-1 - \mathbf{H}_k (\mathbf{x}_k - \hat{\mathbf{x}}_k | k-1) \right\|_{\mathbf{R}_k^{-1}}^2 \right) / G_\sigma \left( \left\| \mathbf{x}_k - \hat{\mathbf{x}}_k | k-1 \right\|_{(\mathbf{P}_{k|k-1}^{-1})}^2 \right) \quad (24)$$

式(23)被重新计算可以得到

$$\mathbf{x}_k = (\mathbf{P}_{k|k-1}^{-1} + L_k \mathbf{H}_k^T \mathbf{R}_k^{-1} \mathbf{H}_k)^{-1} \cdot (L_k \mathbf{H}_k^T \mathbf{R}_k^{-1} (\mathbf{z}_k - \hat{\mathbf{z}}_k | k-1 - \mathbf{H}_k \hat{\mathbf{x}}_k | k-1) + \mathbf{P}_{k|k-1}^{-1} \hat{\mathbf{x}}_k) \quad (25)$$

状态  $\mathbf{x}_k$  可以通过固定点迭代算法计算得到。由于  $\hat{\mathbf{x}}_k | k-1$  是通过动态模型获得,并且对异常值不敏感,因此,可以通过用  $\hat{\mathbf{x}}_k | k-1$  在式(25)中替换  $\mathbf{x}_k$  来执行单次迭代,并获得令人满意的近似结果。可以通过下式获得

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k | k-1 + \mathbf{K}_k (\mathbf{z}_k - \hat{\mathbf{z}}_k | k-1) \quad (26)$$

增益矩阵  $\mathbf{K}_k$  为

$$\mathbf{K}_k = (\mathbf{P}_{k|k-1}^{-1} + L_k \mathbf{H}_k^T \mathbf{R}_k^{-1} \mathbf{H}_k)^{-1} L_k \mathbf{H}_k^T \mathbf{R}_k^{-1} \quad (27)$$

$$L_k = G_\sigma \left( \left\| \mathbf{z}_k - \hat{\mathbf{z}}_k | k-1 \right\|_{\mathbf{R}_k^{-1}}^2 \right) \quad (28)$$

更新的后验误差矩阵为

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k)^T + \mathbf{K}_k \mathbf{R}_k \mathbf{K}_k^T \quad (29)$$

高斯核  $\sigma$  对任何熵滤波算法都起着重要作用。在式(28)中,  $\sigma$  越小,  $L_k$  越小,就会导致增益  $\mathbf{K}_k$  越小。在高斯噪声下,滤波性能会下降甚至发散。

由于不同噪声环境下的最优核大小不同,因此需要改进核大小的自适应方法。遵循文献[28]中提出并

在文献[34]中实现的自适应策略来选择  $\sigma$  (即在每个迭代步骤中  $\sigma = \left\| \mathbf{z}_k - \hat{\mathbf{z}}_k | k-1 - \mathbf{H}_k (\mathbf{x}_k - \hat{\mathbf{x}}_k | k-1) \right\|_{\mathbf{R}_k^{-1}}^2$ ), 在每个迭代步骤中动态调整核大小。适当的核大小对于提高鲁棒性和性能至关重要。

### 2.3 改进的最大相关熵自适应迭代容积卡尔曼滤波算法

对于电池系统而言,过程噪声和测量噪声是随着外界干扰的动态变化而变化的。使用固定的过程噪声和测量噪声的协方差矩阵会导致估计误差,并难以满足实际需求。因此在 IMCC-CKF 算法基础上,进一步采用自适应和迭代的方法提高算法的精度,WLS 的作用是通过调整加权矩阵来最小化估计的方差,二者相结合便会构造一个新的目标函数<sup>[30]</sup>。同时,AICKF 作为一种自适应滤波器,可以根据当前的测量情况实时调整滤波器增益和协方差矩阵。

根据文献[22]中的迭代方法,在本文中同样使用端电压误差的绝对值作为迭代测量更新的判断依据。具体而言,当端电压误差的绝对值超过设定的阈值  $C$ ,即  $|\mathbf{z}_k - \hat{\mathbf{z}}_k | k-1| \geq C$  时,表明当前的状态估计存在较大的偏差,需要进行迭代测量更新以提高估算精度。相反地,如果端电压误差的绝对值满足  $|\mathbf{z}_k - \hat{\mathbf{z}}_k | k-1| < C$  时,则说明当前的状态估计已经足够接近真实值,无需再进行迭代测量更新。 $C$  一般取  $0 \sim 20$  mV。通过不断迭代让估计值更加逼近真实值,提升估计值的准确性,降低计算复杂度,优化算法效率。

为了更好地适应外界的动态干扰,本文通过自适应调整过程噪声和测量噪声的协方差矩阵来进一步提高算法的准确性和稳定性,  $e_k$  表示  $k$  时刻估计状态的残差,  $e_k = \mathbf{z}_k - \hat{\mathbf{z}}_k | k-1$ ,  $\mathbf{Q}_k$  和  $\mathbf{R}_k$  的自适应更新过程<sup>[35]</sup>如下式

$$\begin{cases} \mathbf{E}_k = \frac{1}{M} \sum_{j=k-M+1}^k \mathbf{e}_j (\mathbf{e}_j)^T \\ \mathbf{Q}_k = \mathbf{K}_k \mathbf{E}_k \mathbf{K}_k^T \\ \mathbf{R}_k = \mathbf{E}_k + \frac{1}{2n} \sum_{i=1}^{2n} \mathbf{z}_k^{(i)} | k-1 \mathbf{z}_k^{(i)T} | k-1 - \hat{\mathbf{z}}_k | k-1 \hat{\mathbf{z}}_k^T | k-1 \end{cases} \quad (30)$$

式中:  $M$  表示移动估计窗口的大小;  $\mathbf{E}_k$  表示  $k$  时刻的自适应协方差矩阵。

通过将改进的最大相关熵容积卡尔曼滤波结合迭代优化和自适应调整,可以在保持算法高效性的同时提高准确性。

## 3 仿真实验与分析

实验采用两种工况数据来评估本文算法的性

能,即动态应力测试(DST)工况和新欧洲驾驶循环(NEDC)工况。图 6 为 DST 工况下电池 B1 端电压和电流,图 7 为 NEDC 工况下电池 B2 端电压和电流。




图 6 电池 B1 DST 工况下端电压和电流随时间的变化

Fig. 6 Curves of voltage and current of battery B1 over time under DST condition




图 7 电池 B2 NEDC 工况下端电压和电流随时间的变化

Fig. 7 Curves of voltage and current of battery B2 over time under NEDC condition

采用平均绝对误差(MAE, 设为  $\xi_{\text{MAE}}$ )、均方根误差和最大绝对误差(MaxAE, 设为  $\xi_{\text{MaxAE}}$ )等评价指标评价算法的性能,表达式如下式

$$\xi_{\text{MAE}} = \frac{1}{N} \sum_{k=1}^N |\beta_{\text{SOC},k} - \hat{\beta}_{\text{SOC},k}| \quad (31)$$

$$\xi_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{k=1}^N (\beta_{\text{SOC},k} - \hat{\beta}_{\text{SOC},k})^2} \quad (32)$$

$$\xi_{\text{MaxAE}} = \text{Max} |\beta_{\text{SOC},k} - \hat{\beta}_{\text{SOC},k}| \quad (33)$$

式中:  $\beta_{\text{SOC},k}$  为真实值;  $\hat{\beta}_{\text{SOC},k}$  为估计值;  $N$  为总的采样点数。

为验证本文算法的有效性,基于电池 B1 和 B2

数据,在非高斯噪声的干扰下,将本文算法与 CKF 和 IMCC-CKF 算法分别用于 SOC 的估计。

采用两种非高斯噪声干扰来验证算法的有效性。第一种非高斯噪声将均匀分布噪声和高斯噪声的混合加入到原本的高斯噪声中,将其定义为非高斯噪声 A

$$N_A = (1-a)W + aV \quad (34)$$

式中:  $a$  为权重系数,设  $a$  为 0.5;  $W$  是均匀分布噪声;  $V$  是均值为 0、方差为 0.02 的高斯噪声。

第二种非高斯噪声参照文献[25]的方法生成,将其定义为非高斯噪声 B。

### 3.1 非高斯噪声 A 干扰下的电池 SOC 估计

#### 3.1.1 电池 B1 的验证

将非高斯噪声加入到电压和电流中估计荷电状态,产生的非高斯噪声如图 8、图 9 所示。




图 8 测量电流中的非高斯噪声

Fig. 8 Non-Gaussian noise in measured current




图 9 测量电压中的非高斯噪声

Fig. 9 Non-Gaussian noise in measured voltage

在非高斯噪声环境下时,CKF、IMCC-CKF 和 IMCC-AICKF 算法的 SOC 估计对比结果如图 10 所示。




图 10 电池 B1 在非高斯噪声 A 下 3 种算法的 SOC 估计及其误差

Fig. 10 SOC estimation and error of each algorithm under non-Gaussian noise A of battery B1

从图 10 可以看出,基于 MCC 准则的 IMCC-AICKF 算法显著降低了非高斯噪声下的 SOC 估计误差,虽然在估算初期 IMCC-AICKF 算法的误差相较于另外两种算法较大,但是随着时间的推移,改进的算法逐渐收敛并且在非高斯噪声下的 SOC 估计值更接近真实值,收敛速度最快且波动最小。此外,表 2 给出了不同算法运行时间以及定量的估计误差对比。

表 2 电池 B1 在非高斯噪声 A 下 3 种算法的估计性能比较

Table 2 Comparison of estimation performance of battery B1 in non-Gaussian noise A

| 算法         | 运行时间/s  | $\xi_{MAE}$ | $\xi_{RMSE}$ | $\xi_{MaxAE}$ |
|------------|---------|-------------|--------------|---------------|
| CKF        | 1.476 2 | 0.011 7     | 0.013 1      | 0.023 7       |
| IMCC-CKF   | 1.726 8 | 0.007 0     | 0.007 9      | 0.015 4       |
| IMCC-AICKF | 2.063 7 | 0.002 9     | 0.003 6      | 0.011 4       |

从表 2 的结果可以看出,在非高斯噪声 A 的干扰下,相较于 CKF 和 IMCC-CKF 算法,IMCC-AICKF

算法计算时间有所增加,但  $\xi_{RMSE}$  显著降低。具体来说,与 CKF 相比,IMCC-AICKF 算法的 SOC 估计计算时间增加了 0.587 5 s,  $\xi_{RMSE}$  降低了 72.5%。与 IMCC-CKF 相比,计算时间增加了 0.336 9 s,  $\xi_{RMSE}$  降低了 54.4%。实验结果表明,在非高斯噪声 A 干扰下,IMCC-AICKF 算法的 SOC 估计值更接近真实值,能有效提升电池 SOC 估计的精度。

3.1.2 电池 B2 的验证

在电池 B2 的电流和电压中加入非高斯噪声 A,得到不同算法估计结果,如图 11 所示。

从图 11 可以看出,在非高斯噪声 A 下,IMCC-AICKF 算法的 SOC 估计相较于其他两种算法更接近真实值,误差最小,估计性能更优。由于最大相关熵准则能够更好地处理系统的非线性和噪声,相较于传统的均方误差方法,其利用高阶信息将高斯核应用于估计误差矩阵的每个元素,再结合 AICKF 的优势,从而提高估计的准确性和鲁棒性。定量估计误差和计算复杂度的比较见表 3。




图 11 电池 B2 在非高斯噪声 A 下不同算法的 SOC 估计及其误差

Fig. 11 SOC estimation and error of each algorithm under non-Gaussian noise A of battery B2



表 3 电池 B2 在非高斯噪声 A 下 3 种算法的估计性能比较

Table 3 Comparison of estimation performance of battery B2 in non-Gaussian noise A

| 算法         | 运行时间/s  | $\xi_{MAE}$ | $\xi_{RMSE}$ | $\xi_{MaxAE}$ |
|------------|---------|-------------|--------------|---------------|
| CKF        | 1.014 6 | 0.062 7     | 0.070 5      | 0.128 5       |
| IMCC-CKF   | 1.318 5 | 0.015 3     | 0.017 7      | 0.047 1       |
| IMCC-AICKF | 1.408 4 | 0.005 9     | 0.007 8      | 0.018 5       |

从表 3 可以看出,与 CKF 相比,IMCC-AICKF 算法的 SOC 估计计算时间增加了 0.393 8 s, $\xi_{RMSE}$  降低了 88.9%。与 IMCC-CKF 相比,IMCC-AICKF 的计算时间增加了 0.089 9 s, $\xi_{RMSE}$  降低了 55.9%。比较表 3 中的定量估计误差和计算复杂度可以得出结论,IMCC-AICKF 算法能够更准确地估计电池 B2 的 SOC,与真实值之间的误差较小。

### 3.2 非高斯噪声 B 干扰下的电池 SOC 估计

#### 3.2.1 电池 B1 的验证

电池 B1 的电流中加入非高斯噪声如图 12 所示。






图 12 电池 B1 的非高斯电流噪声

Fig. 12 The non-Gaussian current noise of battery B1  
在非高斯噪声 B 干扰下,已知 SOC 初始值为 1 的情况下,基于 3 种算法的 SOC 估计和估计误差如图 13 所示。



(a)SOC 估计



(b)SOC 估计误差

图 13 电池 B1 在非高斯噪声 B 下 3 种算法的 SOC 估计及其误差

Fig. 13 SOC estimation and error of each algorithm under non-Gaussian noise B of battery B1

从图 13(a)、13(b)可以看出,IMCC-AICKF 算法的 SOC 估计曲线与真实值的偏差较小,基本上能够紧密地跟随真实值的变化。相比之下,其他两种算法的 SOC 估计曲线存在一定的偏离和波动。这表明在非高斯噪声 B 的干扰下,基于 IMCC-AICKF 算法的 SOC 估计误差更小,精度更高,可以更准确地估计电池的 SOC。表 4 给出了定量的性能比较。

表 4 电池 B1 在非高斯噪声 B 下 3 种算法的估计性能比较

Table 4 Comparison of estimation performance of battery B1 in non-Gaussian noise B

| 算法         | 运行时间/s  | $\xi_{MAE}$ | $\xi_{RMSE}$ | $\xi_{MaxAE}$ |
|------------|---------|-------------|--------------|---------------|
| CKF        | 1.458 3 | 0.010 6     | 0.011 5      | 0.019 5       |
| IMCC-CKF   | 1.705 6 | 0.005 9     | 0.006 7      | 0.015 1       |
| IMCC-AICKF | 1.821 6 | 0.003 1     | 0.003 8      | 0.010 6       |

从表 4 可以看出,与 CKF 相比,IMCC-AICKF 算法的 SOC 估计计算时间增加了 0.363 3 s, $\xi_{RMSE}$  降低了 67.0%。与 IMCC-CKF 相比,计算时间增加了 0.116 s, $\xi_{RMSE}$  降低了 43.3%。这进一步证实了 IMCC-AICKF 算法在估计 SOC 方面具有更高的精度和更小的误差。由于 IMCC-AICKF 算法比 CKF 算法和 IMCC-CKF 算法更复杂,因此增加了计算时间,但是提高了 SOC 的估计精度。

#### 3.2.2 电池 B2 的验证

将非高斯噪声 B 添加到电池 B2 的电流中,3 种算法估计结果如图 14 所示。从图 14 可以看出,在非高斯噪声 B 的环境下,3 种算法的估计误差都有

增大的趋势,但是由于 IMCC-AICKF 算法将 IMCC 和 AICKF 算法结合使用,能够克服算法的局限性,提高了整体的 SOC 估计精度和稳定性。定量的性能比较见表 5。




图 14 电池 B2 在非高斯噪声  $B$  干扰下 3 种算法的 SOC 估计及误差

Fig. 14 SOC estimation and error of each algorithm under non-Gaussian noise  $B$  of battery B2

表 5 电池 B2 在非高斯噪声  $B$  下 3 种算法的估计性能比较

Table 5 Comparison of estimation performance of battery B2 in non-Gaussian noise  $B$

| 算法         | 运行时间/s  | $\xi_{MAE}$ | $\xi_{RMSE}$ | $\xi_{MaxAE}$ |
|------------|---------|-------------|--------------|---------------|
| CKF        | 1.233 7 | 0.007 7     | 0.009 3      | 0.019 9       |
| IMCC-CKF   | 1.348 6 | 0.006 8     | 0.007 9      | 0.017 1       |
| IMCC-AICKF | 1.600 2 | 0.002 9     | 0.003 5      | 0.008 0       |

从表 5 可以看出,与 CKF 相比,IMCC-AICKF 算法的 SOC 估计计算时间增加了 0.366 5 s, $\xi_{RMSE}$  降低了 62.4%。与 IMCC-CKF 相比,IMCC-AICKF 算

法的计算时间增加了 0.251 6 s, $\xi_{RMSE}$  降低了 55.7%。经过分析可得,IMCC-AICKF 算法的 SOC 估计相对于 CKF 和 IMCC-CKF 算法具有更低的  $\xi_{RMSE}$  值,即更高的估计精度,但是需要额外的运算时间。这表明在非高斯噪声  $B$  下,IMCC-AICKF 算法在提高 SOC 估计精度方面具有显著的优势。

由此可以得出,在两种非高斯噪声环境下,IMCC-AICKF 算法在运算时间增加不多的情况下,估计精度显著提高。

3.3 鲁棒性分析

SOC 的初始值影响 SOC 估计的精度和收敛速度。为了验证本文算法的收敛能力,在非高斯噪声  $A$  环境下,取准确的  $\beta_{SOC(0)} = 1$  与错误的  $\beta_{SOC(0)} = [0.99, 0.98, 0.97, 0.96, 0.95]$  以验证本文算法的鲁棒性。图 15、16 为电池 B1、B2 在非高斯噪声  $A$  环境下不同 SOC 初值条件下 IMCC-AICKF 算法对 SOC 的估计结果及误差曲线。






图 15 电池 B1 不同 SOC 初值下的估计及误差

Fig. 15 Estimation and error for battery B1 under different initial SOC values



(a) 不同初值下的 SOC 估计



(b) 不同初值下的 SOC 估计误差

图 16 电池 B2 不同 SOC 初值下的估计及误差

Fig. 16 Estimation and error for battery B2 under different initial SOC values

综上所述,不同程度的初始 SOC 误差会导致初始阶段的误差收敛速度和精度不同,随着 SOC 初始值减小,则需要更多的时间才可以收敛到真实值附近。而且初始误差越大,对 SOC 估计精度的影响也会越大,表明不正确的初始 SOC 会对 SOC 估计精度产生不利影响。因此,必须确保初始 SOC 的准确性以获得更准确的估计结果。

## 4 结 论

本文提出一种改进的最大相关熵自适应迭代容积卡尔曼滤波算法用于非高斯噪声干扰下电池的 SOC 估计。将加权最小二乘法与最大相关熵准则结合定义了一种新的代价权函数作为优化准则,通过优化噪声最小协方差矩阵来减小滤波误差,再与自适应迭代容积卡尔曼滤波相结合,对过程噪声协方差和测量噪声协方差进行更新来提高估计的精度和鲁棒性,实验验证了算法的有效性。

(1)与 CKF 和 IMCC-CKF 算法相比,本文所提

算法的运行时间有所增加,但增幅不大,估计精度显著提高,证明算法具有较高的估计精度。

(2)在初始荷电状态错误的情况下,本文所提算法可以收敛到实际荷电状态值,表明该算法具有较好的鲁棒性。

(3)为进一步验证本文所提算法的有效性,可以验证算法在不同温度和工作条件下抑制非高斯噪声的能力。

本文所提算法可以在非高斯噪声环境下提高电池荷电状态估计的精度且具有较好的鲁棒性,为电池管理系统的实际应用提供了有效的技术支持。

## 参考文献:

- [1] ZHENG Linfeng, ZHU Jianguo, LU D D C, et al. Incremental capacity analysis and differential voltage analysis based state of charge and capacity estimation for lithium-ion batteries [J]. *Energy*, 2018, 150: 759-769.
- [2] UL HASSAN M, SAHA S, HAQUE M E, et al. A comprehensive review of battery state of charge estimation techniques [J]. *Sustainable Energy Technologies and Assessments*, 2022, 54: 102801.
- [3] PENG Jiankun, LUO Jiayi, HE Hongwen, et al. An improved state of charge estimation method based on cubature Kalman filter for lithium-ion batteries [J]. *Applied Energy*, 2019, 253: 113520.
- [4] YANG Fan, SHI Dongliang, MAO Qian, et al. Scientific research and critical analysis of battery state-of-charge estimation [J]. *Journal of Energy Storage*, 2023, 58: 106283.
- [5] MOVASSAGH K, RAIHAN S A, BALASINGAM B. Performance analysis of coulomb counting approach for state of charge estimation [C]//2019 IEEE Electrical Power and Energy Conference (EPEC). Piscataway, NJ, USA: IEEE, 2019: 9074789.
- [6] AHMED M S, BALASINGAM B. A scaling approach for improved open circuit voltage modeling in li-ion batteries [C]//2019 IEEE Electrical Power and Energy Conference (EPEC). Piscataway, NJ, USA: IEEE, 2019: 1-6.
- [7] HOW D N T, HANNAN M A, HOSSAIN LIPU M S, et al. State of charge estimation for lithium-ion batteries using model-based and data-driven methods: a review [J]. *IEEE Access*, 2019, 7: 136116-136136.
- [8] 刘芳, 马杰, 苏卫星, 等. 基于自适应回归扩展卡尔曼滤波的电动汽车动力电池全生命周期的荷电状态估方法 [J]. *电工技术学报*, 2020, 35(4): 698-707.

- LIU Fang, MA Jie, SU Weixing, et al. State of charge estimation method of electric vehicle power battery life cycle based on auto regression extended Kalman filter [J]. Transactions of China Electrotechnical Society, 2020, 35(4): 698-707.
- [9] 付诗意, 吕桃林, 闵凡奇, 等. 电动汽车用锂离子电池 SOC 估算方法综述 [J]. 储能科学与技术, 2021, 10(3): 1127-1136.
- FU Shiyi, LÜ Taolin, MIN Fanqi, et al. Review of estimation methods on SOC of lithium-ion batteries in electric vehicles [J]. Energy Storage Science and Technology, 2021, 10(3): 1127-1136.
- [10] 颜湘武, 邓浩然, 郭琪, 等. 基于自适应无迹卡尔曼滤波的动力电池健康状态检测及梯次利用研究 [J]. 电工技术学报, 2019, 34(18): 3937-3948.
- YAN Xiangwu, DENG Haoran, GUO Qi, et al. Study on the state of health detection of power batteries based on adaptive unscented Kalman filters and the battery echelon utilization [J]. Transactions of China Electrotechnical Society, 2019, 34(18): 3937-3948.
- [11] CUI Zhenhua, WANG Licheng, LI Qiang, et al. A comprehensive review on the state of charge estimation for lithium-ion battery based on neural network [J]. International Journal of Energy Research, 2022, 46(5): 5423-5440.
- [12] 王桥, 叶敏, 魏孟, 等. 基于 ELM 和 MCSCKF 的锂离子电池 SOC 估计 [J]. 工程科学学报, 2023, 45(6): 995-1002.
- WANG Qiao, YE Min, WEI Meng, et al. ELM-and MCSCKF-based state of charge estimation for lithium-ion batteries [J]. Chinese Journal of Engineering, 2023, 45(6): 995-1002.
- [13] 李嘉波, 魏孟, 李忠玉, 等. 一种改进的支持向量机回归的电池状态估计 [J]. 储能科学与技术, 2020, 9(4): 1200-1205.
- LI Jiabo, WEI Meng, LI Zhongyu, et al. An improved battery state estimation based on support vector machine regression [J]. Energy Storage Science and Technology, 2020, 9(4): 1200-1205.
- [14] 谭必蓉, 杜建华, 叶祥虎, 等. 基于模型的锂离子电池 SOC 估计方法综述 [J]. 储能科学与技术, 2023, 12(6): 1995-2010.
- TAN Birong, DU Jianhua, YE Xianghu, et al. Overview of SOC estimation methods for lithium-ion batteries based on model [J]. Energy Storage Science and Technology, 2023, 12(6): 1995-2010.
- [15] 徐小勇. 基于退役动力电池储能的光储微网系统 [J]. 电机与控制应用, 2020, 47(2): 91-96.
- XU Xiaoyong. Photovoltaic/battery micro-grid system based on energy storage of decommissioned power battery [J]. Electric Machines & Control Application, 2020, 47(2): 91-96.
- [16] 谢长君, 费亚龙, 曾春年, 等. 基于无迹粒子滤波的车载锂离子电池状态估计 [J]. 电工技术学报, 2018, 33(17): 3958-3964.
- XIE Changjun, FEI Yalong, ZENG Chunnian, et al. State-of-charge estimation of lithium-ion battery using unscented particle filter in vehicle [J]. Transactions of China Electrotechnical Society, 2018, 33(17): 3958-3964.
- [17] 王彤, 高明阳, 黄世楼, 等. 基于自适应容积卡尔曼滤波的双馈风力发电机动态状态估计 [J]. 电网技术, 2021, 45(5): 1837-1843.
- WANG Tong, GAO Mingyang, HUANG Shilou, et al. Dynamic state estimation for doubly fed induction generator wind turbine based on adaptive cubature Kalman filter [J]. Power System Technology, 2021, 45(5): 1837-1843.
- [18] 李伟, 刘伟崑, 邓业林. 基于扩展卡尔曼滤波的锂离子电池荷电状态估计 [J]. 中国机械工程, 2020, 31(3): 321-327.
- LI Wei, LIU Weiwei, DENG Yelin. SOC estimation for lithium-ion batteries based on EKF [J]. China Mechanical Engineering, 2020, 31(3): 321-327.
- [19] GUO Xiangwei, XU Xiaozhuo, GENG Jiahao, et al. SOC estimation with an adaptive unscented Kalman filter based on model parameter optimization [J]. Applied Sciences, 2019, 9(19): 4177.
- [20] LUO Jiayi, PENG Jiankun, HE Hongwen. Lithium-ion battery SOC estimation study based on cubature Kalman filter [J]. Energy Procedia, 2019, 158: 3421-3426.
- [21] LIU Zheng, DANG Xuanju, JING Benqin, et al. A novel model-based state of charge estimation for lithium-ion battery using adaptive robust iterative cubature Kalman filter [J]. Electric Power Systems Research, 2019, 177: 105951.
- [22] 李尧太. 基于 AICKF 的锂离子动力电池全寿命周期 SOC 估算研究 [D]. 镇江: 江苏大学, 2021.
- [23] CHEN Badong, LIU Xi, ZHAO Haiquan, et al. Maximum correntropy Kalman filter [J]. Automatica, 2017, 76: 70-77.
- [24] 巫春玲, 胡雯博, 孟锦豪, 等. 基于最大相关熵扩展卡尔曼滤波算法的锂离子电池荷电状态估计 [J]. 电工技术学报, 2021, 36(24): 5165-5175.
- WU Chunling, HU Wenbo, MENG Jinhao, et al. State of charge estimation of lithium-ion batteries



- based on maximum correlation-entropy criterion extended Kalman filtering algorithm [J]. Transactions of China Electrotechnical Society, 2021, 36 (24): 5165-5175.
- [25] WU Chunling, HU Wenbo, MENG Jinhao, et al. State-of-charge estimation of lithium-ion batteries based on MCC-AEKF in non-Gaussian noise environment [J]. Energy, 2023, 274: 127316.
- [26] 赵季红, 谢志勇, 曲桦, 等. 基于最大互相关熵 UKF 的传感网目标状态和系统偏差联合估计算法 [J]. 计算机应用研究, 2019, 36(2): 570-573.  
ZHAO Jihong, XIE Zhiyong, QU Hua, et al. Augmented target state estimation algorithm with systematic errors based on maximum correntropy unscented Kalman filter in sensor networks [J]. Application Research of Computers, 2019, 36(2): 570-573.
- [27] MA Wentao, GUO Peng, WANG Xiaofei, et al. Robust state of charge estimation for Li-ion batteries based on cubature Kalman filter with generalized maximum correntropy criterion [J]. Energy, 2022, 260: 125083.
- [28] IZANLOO R, FAKOORIAN S A, YAZDI H S, et al. Kalman filtering based on the maximum correntropy criterion in the presence of non-gaussian noise [C]// 2016 50th Annual Conference on Information Science and Systems (CISS). Piscataway, NJ, USA: IEEE, 2016: 500-505.
- [29] 胡浩然, 陈树新, 吴昊, 等. 面向连续离散系统的自适应最大相关熵滤波算法 [J]. 西安交通大学学报, 2022, 56(6): 133-141.  
HU Haoran, CHEN Shuxin, WU Hao, et al. Adaptive maximum correntropy filtering algorithm for continuous-discrete systems [J]. Journal of Xi'an Jiaotong University, 2022, 56(6): 133-141.
- [30] SHAO Jianbo, CHEN Wu, ZHANG Ya, et al. Adaptive multikernel size-based maximum correntropy cubature Kalman filter for the robust state estimation [J]. IEEE Sensors Journal, 2022, 22(20): 19835-19844.
- [31] 巫春玲, 付俊成, 徐先峰, 等. 基于多新息最小二乘和多新息扩展卡尔曼滤波算法的锂电池 SOC 估计 [J]. 华南理工大学学报(自然科学版), 2024, 52(2): 74-83.  
WU Chunling, FU Juncheng, XU Xianfeng, et al. Lithium battery SOC estimation based on multi innovation least square and multi innovation extended Kalman filter algorithm [J]. Journal of South China University of Technology (Natural Science Edition), 2024, 52(2): 74-83.
- [32] 陈息坤, 孙冬, 陈小虎. 锂离子电池建模及其荷电状态鲁棒估计 [J]. 电工技术学报, 2015, 30(15): 141-147.  
CHEN Xikun, SUN Dong, CHEN Xiaohu. Modeling and state of charge robust estimation for lithium-ion batteries [J]. Transactions of China Electrotechnical Society, 2015, 30(15): 141-147.
- [33] 龙子旋, 周琪, 彭侠夫, 等. 非高斯环境下船变测量最大熵卡尔曼滤波方法 [J]. 系统工程与电子技术, 2021, 43(11): 3278-3287.  
LONG Zixuan, ZHOU Qi, PENG Xiafu, et al. Maximum correntropy Kalman filter used for hull deformation measurement in non-Gaussian environment [J]. Systems Engineering and Electronics, 2021, 43(11): 3278-3287.
- [34] KULIKOV M V. Square-root algorithms for maximum correntropy estimation of linear discrete-time systems in presence of non-Gaussian noise [J]. Systems and Control Letters, 2017, 108: 8-15.
- [35] 潘清云. 锂离子电池的健康状态估计方法研究 [D]. 西安: 长安大学, 2023.

(编辑 武红江)