

DOI: 10.13382/j.jemi.B2205711

基于改进的 AEKF 铅酸电池 SOC 在线估计*

袁正峰^{1,2} 郭兴众^{1,2} 花晓飞³(1. 安徽工程大学电气工程学院 芜湖 241000; 2. 高端装备先进感知与智能控制教育部重点实验室
芜湖 241000; 3. 奇瑞汽车股份有限公司 芜湖 241000)

摘要: 为了提高铅酸电池在随机工况下荷电状态(SOC)估计精度,减小误差变化对估计精度的影响。针对自适应扩展卡尔曼滤波中误差新息序列长度固定选取的局限性,本文提出一种改进的自适应扩展卡尔曼滤波算法估计 SOC。通过似然估计来监测协方差匹配算法中的误差新息序列分布变化时刻,根据误差新息的分布变化来自适应调整新息序列长度,进而降低估计 SOC 时的误差。首先通过带遗忘因子的递推最小二乘法(FRRLS)辨识获得等效模型参数,其模型平均误差电压为 13.63 mV,然后在随机工况实验下发现,改进后的算法在估计 SOC 时的 RMSE 和 MAE 性能上精度分别提高了 14.44% 和 17.26%,结果表明改进后的算法拥有更好的稳定性和精度。

关键词: 铅酸电池; SOC 估计; 自适应扩展卡尔曼滤波; 协方差匹配; 误差新息分布

中图分类号: TM912.1 **文献标识码:** A **国家标准学科分类代码:** 510.4

Online SOC estimation based on improved AEKF lead-acid battery

Yuan Zhengfeng^{1,2} Guo Xingzhong^{1,2} Hua Xiaofei³(1. School of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, China; 2. Key Laboratory
of Advanced Perception and Intelligent Control of High-end Equipment, Ministry of Education, Wuhu
241000, China; 3. Chery Automobile Co., Ltd., Wuhu 241000, China)

Abstract: In order to improve the state of charge (SOC) estimation accuracy of lead-acid battery under random conditions, reduce the influence of error variation on estimation accuracy. Aiming at the limitation of fixed length selection of error innovation sequence in adaptive extended Kalman filter, an improved adaptive extended Kalman filter algorithm is proposed to estimate SOC. The likelihood estimation is used to monitor the distribution change time of the error innovation sequence in the covariance matching algorithm, and the length of the innovation sequence is adaptively adjusted according to the distribution change of the error innovation, thereby reducing the error when estimating SOC. Firstly, the equivalent model parameters are identified by the recursive least squares method with forgetting factor (FRRLS), the average error voltage of the model is 13.63 mV. Then, in the random condition experiment, it is found that the improved algorithm improves the accuracy of RMSE and MAE performance by 14.44% and 17.26% respectively when estimating SOC. The results show that the improved algorithm has better stability and accuracy.

Keywords: lead-acid battery; SOC estimation; adaptive extended Kalman filter; covariance matching; error information distribution

0 引言

整车电源网络为燃油汽车的正常行驶提供必要的用电,汽车电源管理系统对此起到关键作用,对车载蓄电池

进行有效的能量管理直接影响到电池寿命、电源网络的可靠性,其中对电池的荷电状态(state of charge, SOC)计算是汽车电源管理的重要目标。

SOC 估计算法主要有安时积分法^[1]、开路电压法^[2-3]、数据驱动方法^[4-5]和卡尔曼滤波法^[6-7]。安时积分

法方法简便但是对电池 SOC 初值精度要求高,容易受环境和设备精度影响。开路电压法需要在离线情况下对充放电后的电池充分静置才能测量到较为准确的路电压,实效性差无法在汽车用电工况下使用。数据驱动方法,通过对大量电池数据进行训练来获得高精度的预测 SOC,对硬件要求较高。文献[8]采用了一种 3 层 BP 神经网络模型对铅酸蓄电池 SOC 进行估计,在一定误差下反映电池的动态行为和预测电池 SOC,但是需要对电池数据预处理计算量过大。文献[9]提出一种最小二乘支持向量机算法对电池 SOC 进行实时预测,提出用交叉验证方法来优化惩罚因子和核参数,但是该方法对于核函数的选取极为敏感,需要多次实验调试。扩展卡尔曼滤波法基于电池状态模型本身和量测信号对状态变量进行最小均方误差估计,此类算法采用递推方式,计算量适中可以很好地满足实时在线估计。文献[10]提出一种基于多新息理论的自适应扩展卡尔曼滤波的电池 SOC 估计方法,对过程噪声和观测噪声自适应调整有效提高了 SOC 估算精度。文献[11]提出一种自适应无迹卡尔曼滤波,弥补了扩展卡尔曼滤波算法中的截断误差,提高了估算精度,但是增大了计算复杂性并且噪声协方差无法同时估计。不同的工况对电池 SOC 估计误差精度会有不同的影响,文献[12]与[13]分别通过引入温度修正因子和耦合温度与循环次数因素,建立了更为精确的电池模型,在相应工况下提高了 SOC 估计精度。但是引入修正因子和对电池进行组合建模都会加大模型复杂度。

针对上述在电池 SOC 估计误差精度的特点分析中,本文以车载 12 V 蓄电池为研究对象,建立一阶等效 Thevenin 模型采用含遗忘因子的递推最小二乘法辨识模型参数,获取等效模型的参数后,在基于噪声协方差匹配算法的自适应扩展卡尔曼滤波基础上,提出一种基于误差新息序列分布变化来自适应调整过程噪声与量测噪声协方差的改进自适应扩展卡尔曼滤波算法。运用改进的算法来估计 SOC 有效的提高了估计性能,在模拟实车工况实验下验证了所提算法的实时在线估计精度和可靠性。

1 模型在线参数辨识

1.1 蓄电池模型

蓄电池等效电路模型主要有 Rint 模型、Thevenin 模型、PNGV 模型和 GNL 模型^[14]等,其中等效 Thevenin 模型精度好应用广泛,本文采用一阶 RC 等效电路模型如图 1 所示。

图 1 中 U_{oc} 表示电池开路电压, I 表示负载电流, R_0 、 R_p 、 C_p 分别表示欧姆电阻、极化电阻、极化电容, U_p 表示极化电阻和极化电容两端电压, U_b 表示等效模型输出端

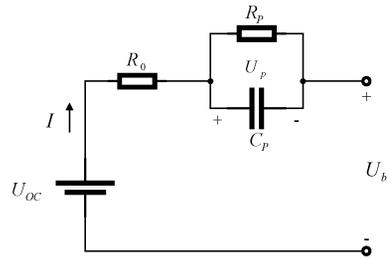


图 1 一阶 RC 等效电路模型

Fig. 1 First-order RC equivalent circuit model

电压。由基尔霍夫电路定律知:

$$U_{oc} = I \cdot R_0 + U_p + U_b \quad (1)$$

$$C_p \cdot \frac{dU_p}{dt} + \frac{U_p}{R_p} = I \quad (2)$$

$$SOC = SOC_0 + \frac{1}{C_n} \int_{t_0}^{t_1} \eta \cdot I_t dt \quad (3)$$

式中: SOC_0 是 t_0 时刻初始 SOC 值, C_n 是电池额定容量, η 为电池充放电效率, I_t 为电池工作电流放电时为负值, 充电时为正值。对上式离散化得到蓄电池的状态空间模型:

$$\begin{cases} \begin{bmatrix} U_p(k+1) \\ SOC(k+1) \end{bmatrix} = A(k) \cdot \begin{bmatrix} U_p(k) \\ SOC(k) \end{bmatrix} + B(k) \cdot I(k) \\ U_b(k) = U_{oc}(k) - I(k) \cdot R_0(k) - U_p(k) \end{cases} \quad (4)$$

$$\begin{cases} A(k) = \begin{bmatrix} \exp(-T/R_p(k)C_p(k)) & 0 \\ 0 & 1 \end{bmatrix} \\ B(k) = \begin{bmatrix} -R_p(1 - \exp(-T/R_p(k)C_p(k))) \\ T/C_n \end{bmatrix} \end{cases} \quad (5)$$

式中: $U_p(k)$ 、 $U_b(k)$ 、 $U_{oc}(k)$ 分别代表在第 k 时刻的极化电压、电池端电压、开路电压, T 为系统采样时间, 其中开路电压是关于 SOC 和温度的函数。

1.2 FFRLS 在线辨识

本文采用带遗忘因子的递推最小二乘法来获取铅酸电池等效模型参数。FFRLS 算法^[15-16]公式如下:

$$\begin{cases} K_{(k)} = P_{(k-1)} \varphi(k) (\varphi^T(k) P_{(k-1)} \varphi(k) + \lambda)^{-1} \\ \hat{\theta}(k) = \hat{\theta}(k-1) + K_{(k)} (y(k) - \varphi^T(k) \hat{\theta}(k-1)) \\ P_{(k)} = \frac{1}{\lambda} (I - K_{(k)} \varphi^T(k)) P_{(k-1)} \end{cases} \quad (6)$$

式中: $K_{(k)}$ 为第 k 时刻增益因子, $P_{(k)}$ 为第 k 时刻协方差矩阵, I 为单位矩阵。遗忘因子 λ 可以加大新数据的权重, 本文取 $\lambda = 0.999$ 。

1.3 模型实验验证

本文蓄电池实验平台由 Digatron BTS600 电池综合

参数测试仪、温变控制实验箱、上位机组成如图 2 所示,实验对象为骆驼 EFB 铅酸蓄电池相关参数性能如表 1 所示。模拟蓄电池环境舱内温度,在温变箱中设定环境温度为 50 ℃,获取电池在该温度下实际容量作为参考容量和脉冲放电工况下电池端电压响应,如图 3 所示。经测试 50 ℃ 环境下电池实际容量为 82.17 Ah,电池初始 SOC 为 0.98。



图 2 实验平台

Fig. 2 Experimental platform

表 1 电池参数

Table 1 Battery parameters

额定容量	50%DOD 循环寿命	放电截至电压	端电压
70 Ah	240 次	10.5 V	12 V

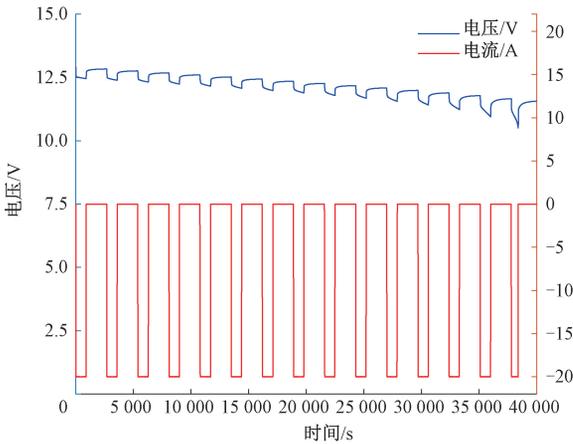


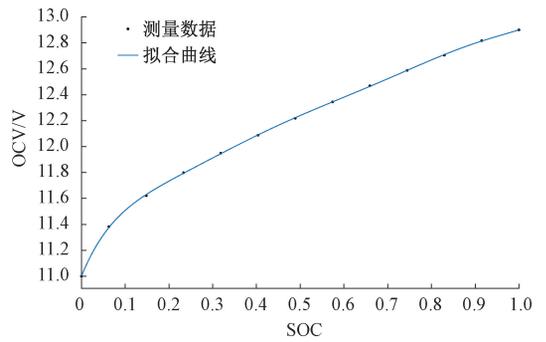
图 3 电池脉冲放电数据

Fig. 3 Battery pulse discharge data

实验共获得 13 组 SOC 和相对应的开路电压 (OCV),利用多项式拟合函数可以拟合得到 OCV-SOC 关系曲线如图 4 所示,可以得到 7 阶多项式拟合函数如式 (7) 所示。将上述脉冲放电数据导入到 MATLAB 仿真模型中,得到模型仿真电压和等效模型参数,如图 4、5 所示。

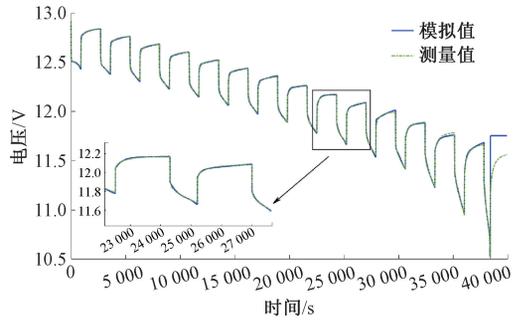
$$U_{oc} = 66.91 \times soc^7 - 266.5 \times soc^6 + 430 \times soc^5 - 361.8 \times soc^4 + 170.7 \times soc^3 - 45.59 \times soc^2 + 8.239 \times soc + 11 \quad (7)$$

从仿真端电压和辨识结果来看,FFRLS 辨识的模型参数具有良好的精度。模型仿真电压平均误差为 13.63 mV 从图 4 (b) 中看到仿真结果与实测电压变化趋



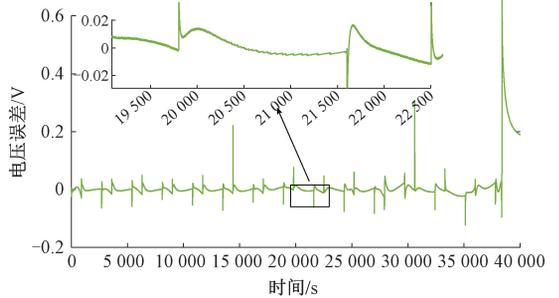
(a) 开路电压和 SOC 关系

(a) Relationship between open circuit voltage and SOC



(b) 模拟电压

(b) Simulated voltage



(c) 电压误差

(c) Voltage error

图 4 模拟电压与测量电压及其误差

Fig. 4 Analog and measured voltages and their errors

势一致,图 5 反映了辨识的模型参数变化,电池参数在前期经过波动后趋于稳定,在放电末期电池参数出现较大增幅反映了电池内部反应变化。由此分析本文建立的等效模型具有以较好的精度,为后面电池 SOC 估计提供了良好的模型。

2 自适应扩展卡尔曼滤波估计 SOC

2.1 自适应扩展卡尔曼滤波

假设离散系统状态方程与模型观测方程:

$$\begin{cases} X(k+1) = f(X(k), u(k)) + \omega(k) \\ y(k) = h(X(k), u(k)) + \nu(k) \end{cases} \quad (8)$$

式中: $X(k)$ 是状态变量; $u(k)$ 是输入信号; $\omega(k)$ 是均值为 0,协方差为 Q_k 的高斯白噪声; $y(k)$ 是观测信号;

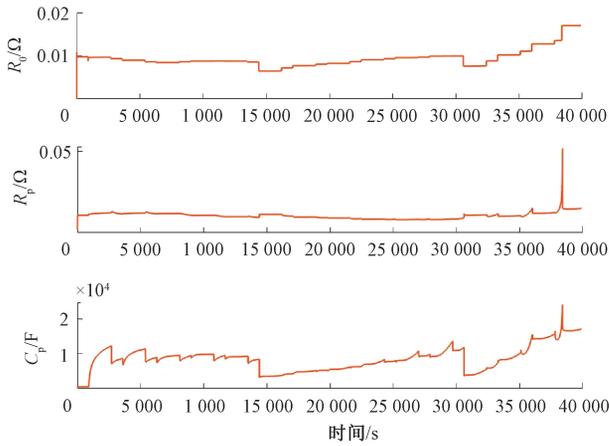


图5 辨识模型参数

Fig. 5 Identification model parameters

$\nu(k)$ 是均值为 0, 协方差为 R_k 的高斯白噪声。对式(8)采用泰勒线性化后, 结合协方差自适应匹配算法的扩展卡尔曼滤波算法^[17](AEKF)流程如下:

算法1 自适应扩展卡尔曼滤波算法

1) 滤波器初始化:

$$x_0^+ = E(x_0), P_0^+ = E[(x_0 - \hat{x}_0^+)(x_0 - \hat{x}_0^+)^T]$$

2) 时间更新:

$$P_k^- = A_{k-1} P_{k-1}^+ A_{k-1}^T + Q_{k-1}$$

$$\hat{x}_k^- = f_{k-1}(\hat{x}_{k-1}^-, u_{k-1})$$

$$A_{k-1} = \left. \frac{\partial f_{k-1}}{\partial x} \right|_{\hat{x}_{k-1}^+}$$

3) 误差新息计算:

$$e_k = y_k - h_k(\hat{x}_k^-, u_k)$$

新息协方差更新:

$$H_k = \frac{1}{M} \sum_{j=k-M+1}^k e_j e_j^T$$

4) 量测更新:

$$R_k = H_k - C_k P_k^- C_k^T$$

$$K_k = P_k^- C_k^T (C_k P_k^- C_k^T + R_k)^{-1}$$

$$\hat{x}_k^+ = \hat{x}_k^- + K_k [y_k - h_k(\hat{x}_k^-, u_k)]$$

$$P_k^+ = (I - K_k C_k) P_k^-$$

$$Q_k = K_k H_k K_k^T$$

$$C_k = \left. \frac{\partial h_k}{\partial x} \right|_{\hat{x}_k^-}$$

$k = 1, 2, 3, \dots$, 循环步骤 2)~4)

蓄电池状态方程与观测方程的参数矩阵和状态向量为:

$$x(k) = [U_p(k), SOC(k)]^T$$

$$A_k = A(k) \quad (9)$$

$$C_k = \left. \frac{\partial U_b(k)}{\partial x} \right|_{x=\hat{x}_k^-} = \left[-1 \quad \left. \frac{dU_{oc}}{dSOC} \right|_{SOC_k^-} \right]$$

$$B_k = B(k) \quad (10)$$

在算法1的自适应协方差匹配算法中, 其中 e_k 是误差新息, $\{e_{k-M+1}, e_{k-M+2}, \dots, e_k\}$ 是误差新息序列, M 称为移动窗口大小代表新息序列的长度, H_k 是误差新息序列的协方差。

2.2 改进的自适应协方差匹配算法

在2.1节的自适应协方差匹配算法中检测误差新息序列长度的移动窗口是固定的, 它只反映固定时间段内误差新息的变化。但是实际应用中误差的变化受到模型精度、蓄电池传感器误差、不同工况、环境的综合影响^[18], 误差的分布信息在不同的时间段内会呈现不同的变化, 因此十分有必要根据误差分布的变化来调整移动窗口的大小。基于此参考文献[19]和[20], 本文采用一种改进的自适应协方差匹配算法: 设立一个检测误差新息分布函数变化的长度为 $2N$ 的窗口 $\{e_{k-2N}, e_{k-2N+1}, \dots, e_{k-1}\}, e_k \sim N(0, \sigma^2)$ 。当观测噪声方差变化不明显时在检测窗口中可以认为新息序列的概率密度函数无明显变化, 此时固定窗长可以适用来估计新协方差; 当观测噪声方差变化较大时, 检测窗口中新息的概率密度函数出现不同值, 需要重新划分移动窗口长度, 因此为检测出现新息序列分布变化较大时的边界将新息序列平方化处理令 $W_k = e_k^2$ 。将序列 W_k 均分为前后长度为 N 的两个区域, 通过比较整个检测窗口和前后两个区域的新息序列平方值的方差变化来决定是否改变移动窗口长度, 具体算法如下所示:

$$\text{if}(B_x - A_x) > Th$$

$$L_k = LO$$

$$\text{else } L_k = L_{k-1} + 1$$

序列 W_k 的概率密度函数可表示为:

$$P_{(W_k)} = \prod_{j=k-2N}^{k-1} \frac{1}{\sqrt{2\pi\sigma_x^2 W_j}} e^{-\frac{W_j}{2\sigma_x^2}} \quad (12)$$

利用最大似然估计可得:

$$\ln(P_{(W_k)}) = A_x = -\frac{1}{2} \sum_{j=k-2N}^{k-1} \left[\ln(2\pi\sigma_x^2 W_j) + \frac{W_j}{\sigma_x^2} \right] \quad (13)$$

$$\text{令 } \frac{\partial A_x}{\partial \sigma_x^2} = 0, \text{ 得到 } \sigma_x^2 = \frac{1}{2N} \sum_{j=k-2N}^{k-1} W_j。$$

在检测窗口中间设立边界检测点, 此时整个窗口内 W_k 的概率密度函数是均分后前后两个区域内 W_k 概率密度函数之积:

$$P_{(W_k)} = \prod_{j=k-N}^{k-1} \frac{1}{\sqrt{2\pi\sigma_1^2 W_j}} e^{-\frac{W_j}{2\sigma_1^2}} \prod_{j=k-2N}^{k-N-1} \frac{1}{\sqrt{2\pi\sigma_2^2 W_j}} e^{-\frac{W_j}{2\sigma_2^2}} \quad (14)$$

同样利用最大似然估计可得：

$$B_x = -\frac{1}{2} \sum_{j=k-N}^{k-1} \left[\ln(2\pi\sigma_1^2 W_j) + \frac{W_j}{\sigma_1^2} \right] - \frac{1}{2} \sum_{j=k-2N}^{k-N-1} \left[\ln(2\pi\sigma_2^2 W_j) + \frac{W_j}{\sigma_2^2} \right] \quad (15)$$

$$\sigma_1^2 = \frac{1}{N} \sum_{j=k-N}^{k-1} W_j \quad \sigma_2^2 = \frac{1}{N} \sum_{j=k-2N}^{k-N-1} W_j \quad (16)$$

最后导出：

$$B_x - A_x = N \ln \frac{\sigma_x^2}{\sigma_1^2 \sigma_2^2} \quad (17)$$

其中， σ_x^2 是整个检测窗口中 W_k 序列的方差， σ_1^2 是前一个区域方差， σ_2^2 是后一个区域方差。 L_0 是每次重置移动窗口时的初值， Th 是阈值参数。这里按照文献经验设定 $Th = N$ 。当满足 $(B_x - A_x) > Th$ 条件时，说明检测窗口中噪声分布已发生明显变化，此时移动窗口是固定值来更新新息协方差；当检测到噪声无明显变化时，移动窗口将会随时间线性增加。改进后的协方差匹配算法可以自适应调整移动窗口大小，由此得到的基于改进自适应扩展卡尔曼滤波算法估计 SOC 流程如图 6 所示。

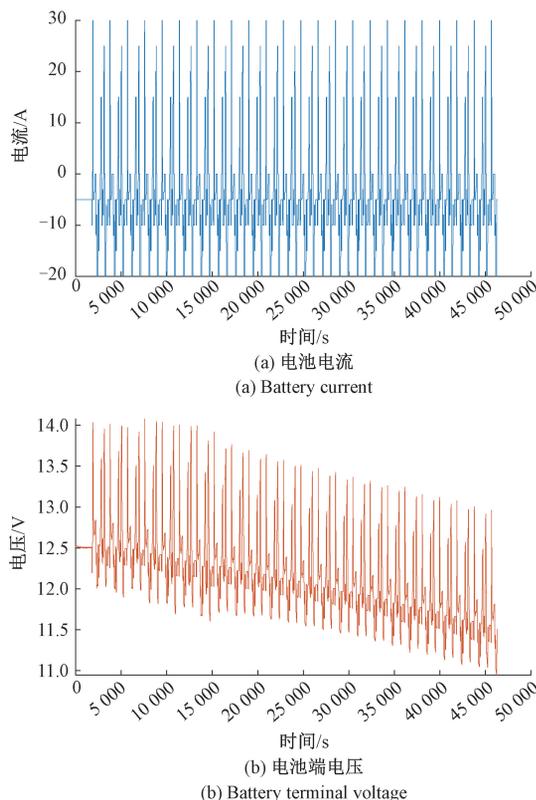


图 7 随机工况下电流、电压

Fig. 7 Current and voltage under random working conditions

表 2 SOC 估计算法初值选取

Table 2 Initial value selection of SOC estimation algorithm

参数	取值
容量	82.17 Ah
初始状态	$x_0 = [0 \ 0.98]^T$
初始状态协方差	$P_0 = [1e^{-5} \ 0; 0 \ 1e^{-1}]$
初始过程噪声协方差	$Q_0 = [1e^{-10} \ 0; 0 \ 1e^{-10}]$
初始量测噪声协方差	$R_0 = 0.02$

在 2.1 节中讲到的 AEKF 算法性能主要取决于移动窗口长度的大小，所以有必要通过多次实验找到最佳窗口长度。为了比较两种算法性能在这里定义相关指标：

$$\begin{cases} RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (SOC_{estimate} - SOC_{reference})^2} \\ MAE = \frac{1}{n} \sum_{j=1}^n |SOC_{estimate} - SOC_{reference}| \end{cases} \quad (18)$$

式中： $SOC_{estimate}$ 是估计值 $SOC_{reference}$ 是参考值，从图 8 中可以看到相关 SOC 估计性能指标随着移动窗口长度的增加在一致性的增大或减小，其中在移动窗口长度 $M = 1$ 时各指标值取得最小值，因此在后面试验中 AEKF 算法中移动窗口长度定为 1。

在本次实验中，IAEKF 算法的检测窗口长度取为 $2N = 36$ ，重置窗口长度为 1。在已知初值 $SOC = 0.98$ 情

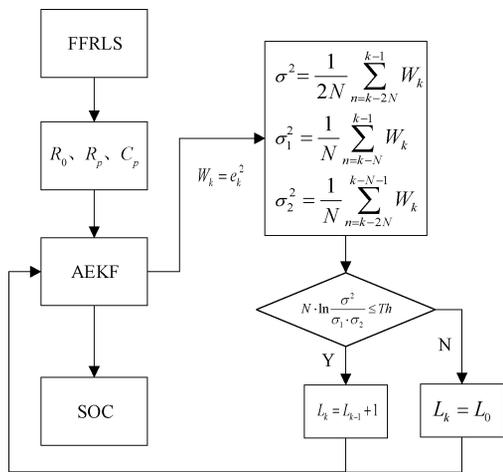


图 6 基于 IAEKF 估计 SOC 的流程

Fig. 6 Flow chart of SOC estimation based on IAEKF

3 随机工况验证与结果分析

3.1 实验验证

在实验平台上采用随机电流工况进行 SOC 估计验证，将实验中 SOC 参考值以实验电流用安时积分所得。随机电流工况如图 7 所示，SOC 估计算法初值参数如表 2 所示。

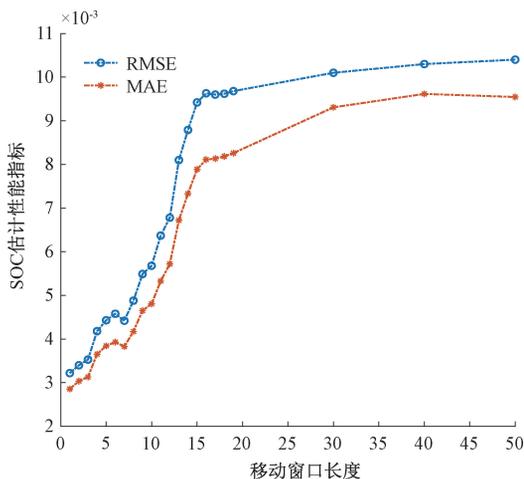


图8 不同移动窗口长度下估计性能指标

Fig. 8 Estimated performance indicators under different moving window lengths

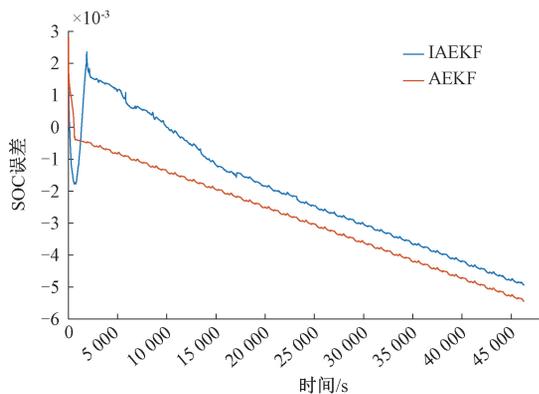


图10 SOC 估值误差曲线

Fig. 10 SOC estimation error curve

况下,两种估计算法结果如图9所示。可以看到,两种算法的估值经过短暂的超调后,快速收敛至参考值。两种算法下估值误差曲线走向一致,但是 IAEKF 算法的稳态误差比 AEKF 算法更小,从 SOC 误差曲线图 10 中看到 IAEKF 算法下的 SOC 最大绝对误差在 0.005 以内,而 AEKF 算法下的 SOC 最大绝对误差接近于 0.006。

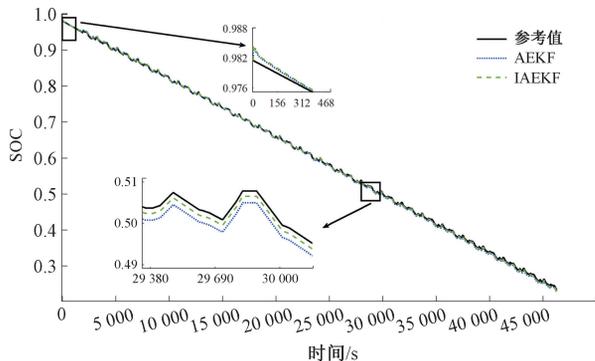


图9 两种算法下 SOC 估值对比

Fig. 9 Comparison of SOC estimation under the two algorithm

3.2 实验结果分析

表3中列举了两种算法的性能对比,可以看到 IAEKF 算法的性能比 AEKF 算法更佳,其中与 AEKF 算法相比,IAEKF 算法下的均方根误差 (RMSE) 减小了 14.44%,平均绝对误差 (MAE) 减小了 17.26%。更为重要的是,这是在 AEKF 算法选择了最佳合适移动窗口长度情况下的数据,在不同的工况中误差新息的分布不同合适的移动窗口长度也会有不同的选择,要想获得较好的性能需要前期调试窗长,IAEKF 算法可以自适应的调

整窗长优化 SOC 估计误差,由此看 IAEKF 算法的适用性更强。

表3 两种算法性能对比

Table 3 Performance comparison of the two algorithms

SOC 估计性能指标	AEKF	IAEKF
RMSE	0.003 22	0.002 755
MAE	0.002 856	0.002 363

在图 11 中可以看到误差新息的分布和移动窗口的自适应变化,由图 11 (c) 局部放大过程中可知,当误差新息变化较平稳的在 0 值附近变化时,移动窗口会依此来线性增加窗口长度进而检测更多的误差新息变化;在误差新息分布发生较大的突变时,移动窗口会重置为初始长度。正是依据这种根据误差新息分布变化来自适应调整移动窗口长度的算法,减小了估计 SOC 时的稳态误差。

4 结论

针对随机用电工况、误差变化对蓄电池 SOC 估计精度的影响,本文提出了一种改进的自适应扩展卡尔曼滤波算法,首先通过似然函数估计识别出误差新息分布变化时刻,然后选取新的误差新息序列来自适应调整协方差匹配算法中的系统噪声和测量噪声协方差,进而来提高 SOC 估计精度。首先通过 FFRLS 在线辨识了等效模型参数,模型平均误差电压为 13.63 mV 获取了较好精度的模型。在随机电流工况下发现,IAEKF 算法比 AEKF 算法在估计 SOC 时的 RMSE 和 MAE 性能上精度分别提高了 14.44% 和 17.26%。对比实验表明 IAEKF 算法在估计 SOC 时具有较好的动态响应能力和精度,在汽车电源管理策略上具有一定的实用性。

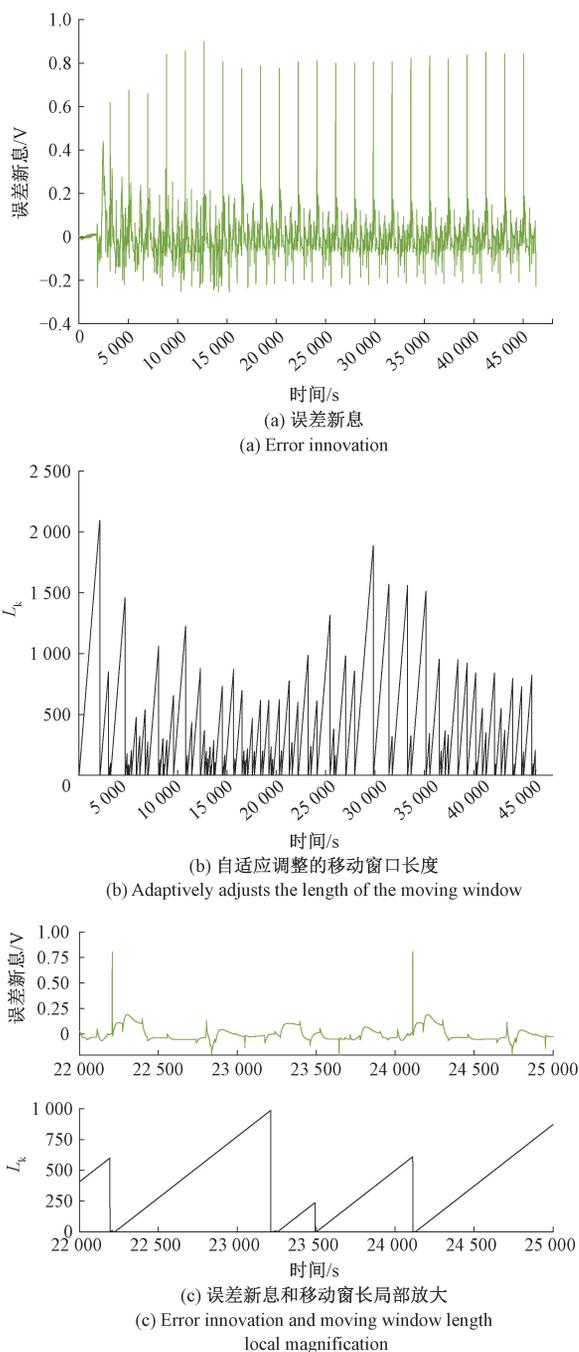


图 11 误差新息和可变窗长

Fig. 11 Error innovation distribution and variable moving window length

参考文献

[1] 罗勇, 祁朋伟, 黄欢, 等. 基于容量修正的安时积分 SOC 估算方法研究 [J]. 汽车工程, 2020, 42(5): 681-687.

LUO Y, QI P W, HUANG H, et al. Research on SOC estimation method of ampere-hour product based on capacity modification [J]. Automotive Engineering,

2020, 42(5): 681-687.

[2] YU Q, WAN C, LI J, et al. An open circuit voltage model fusion method for state of charge estimation of lithium-ion batteries [J]. Energies, 2021, 14.

[3] 何培杰, 王琪, 高田, 等. 动力电池荷电状态优化方法研究 [J]. 国外电子测量技术, 2019, 38(7): 37-42.

HE P J, WANG Q, GAO T, et al. Research on optimization method of power battery under charge state [J]. International Electronic Measurement Technology, 2019, 38(7): 37-42.

[4] ZHAI S, LI W, WANG C, et al. A novel data-driven estimation method for state-of-charge estimation of Li-ion batteries [J]. Energies, 2022, 15.

[5] LI Y, SHEN Z, RAY A, et al. Real-time estimation of lead-acid battery parameters: A dynamic data-driven approach [J]. Journal of Power Sources, 2014, 268(5): 758-764.

[6] ZANG J, WANG Q, MENG F, et al. New energy vehicle battery SOC evaluation method based on robust extended Kalman filter [J]. Journal of Physics: Conference Series, 2022, 2196(1): 012037.

[7] 王文亮, 何锋, 蒋雪生, 等. 基于双扩展卡尔曼滤波锂电池荷电状态估算研究 [J]. 电子测量技术, 2020, 43(19): 49-52.

WANG W L, HE F, JIANG X SH, et al. Study on charge state estimation of lithium battery based on double-extended Kalman filter [J]. Electronic Measurement Technology, 2020, 43(19): 49-52.

[8] 赵轩, 康留旺, 汪贵平, 等. 基于 BP 神经网络的 SOC 估计及铅酸蓄电池特性 [J]. 电源技术, 2014, 38(5): 874-877.

ZHAO X, KANG L W, WANG G P, et al. SOC estimation and lead-acid battery characteristics based on BP neural network [J]. Power Supply Technology, 2014, 38(5): 874-877.

[9] 林瑞霖, 郭辉. 最小二乘支持向量机在蓄电池剩余容量建模中的应用研究 [J]. 海军工程大学学报, 2010, 22(5): 52-55.

LIN R L, GUO H. Application of least square support vector machine in modeling battery residual capacity [J]. Journal of Naval University of Engineering, 2010, 22(5): 52-55.

[10] LI W, YANG Y, WANG D, et al. The multi-innovation extended Kalman filter algorithm for battery SOC estimation [J]. Ionics, 2020, 26: 6145-6156.

[11] 魏克新, 陈峭岩. 基于自适应无迹卡尔曼滤波算法的锂离子动力电池状态估计 [J]. 中国电机工程学报, 2014, 34(3): 445-452.

- WEI K X, CHEN Q Y. State estimation of lithiumion battery based on adaptive unscented Kalman filter algorithm [J]. Proceedings of the CSEE, 2014, 34(3): 445-452.
- [12] 陈媛,何怡刚,李忠. 电池变温度模型似然函数参数辨识及 SOC 估计[J]. 电子测量与仪器学报, 2019, 33(12):1-9.
CHEN Y, HE Y G, LI ZH. Parameter identification of likelihood function and SOC estimation of battery variable temperature model [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(12):1-9.
- [13] 刘征宇,朱诚诚,尤勇,等. 面向 SOC 估计的计及温度和循环次数的锂离子电池组合模型[J]. 仪器仪表学报, 2019, 40(11):117-127.
LIU ZH Y, ZHU CH CH, YOU Y, et al. An integrated model of lithium-ion battery for SOC estimation with temperature and cycle times [J]. Chinese Journal of Scientific Instrument, 2019, 40(11):117-127.
- [14] 程兴婷. 铅酸电池与锂离子电池的建模与参数辨识方法研究[D]. 长沙:湖南大学, 2015.
CHENG X T. Modeling and parameter identification of lead-acid battery and lithium-ion battery [D]. Changsha: Hunan University, 2015.
- [15] 汪首坤,鲁帅,陈志华,等. 基于 FFRLS-AEKF 的 6 轮足机器人电池 SOC 估计[J]. 北京理工大学学报, 2022, 42(3):271-278.
WANG SH K, LU SH, CHEN ZH H, et al. SOC estimation for six-wheeled-legged robot battery based on FFRLS-AEKF [J]. Transactions of Beijing Institute of Technology, 2022, 42(3):271-278.
- [16] 朱磊,刘子博,李路路,等. 基于 RLS-DLUKF 算法的锂电池 SOC 预测方法研究[J]. 储能科学与技术, 2021, 10(3):1137-1144.
ZHU L, LIU Z B, LI L L, et al. Research on SOC prediction method of lithium battery based on RLS-DLUKF algorithm [J]. Energy Storage Science and Technology, 2021, 10(3): 1137-1144.
- [17] XIONG R, HE H, SUN F, et al. Evaluation on state of charge estimation of batteries with adaptive extended Kalman filter by experiment approach [J]. IEEE Transactions on Vehicular Technology, 2013, 62(1): 108-117.
- [18] REN Z. Error analysis of model-based state-of-charge estimation for lithium-ion batteries at different temperatures [J]. International Journal of Electrochemical Science, 2020, 9981-10006.
- [19] SUN D, YU X, WANG C, et al. State of charge estimation for lithium-ion battery based on an intelligent adaptive extended Kalman filter with improved noise estimator [J]. Energy, 2020, 214.
- [20] EMAMI M, TABAN M R. A novel intelligent adaptive Kalman filter for estimating the submarine's velocity: With experimental evaluation [J]. Ocean Engineering, 2018, 158(15):403-411.

作者简介



袁正峰, 2020 年于湖北科技学院获得学士学位, 现为安徽工程大学硕士研究生, 主要研究方向为智能信息处理及应用。

E-mail: 574948606@qq.com

Yuan Zhengfeng received his B. Sc. degree from Hubei University of Science and Technology in 2020. Now he is a M. Sc. candidate at Anhui Polytechnic University. His main research interests include intelligent information processing and application.



郭兴众 (通信作者), 1996 年于东华大学获得硕士学位, 现为安徽工程大学教授、硕士生导师, 主要研究方向为智能控制理论和系统建模与仿真分析。

E-mail: xzguo@ahpu.edu.cn

Guo Xingzhong (Corresponding author) received his M. Sc. degree from Donghua University in 1996. Now he is a professor and master's supervisor at Anhui Polytechnic University. His main research interests include intelligent control theory and system modeling and simulation analysis.



花晓飞, 2018 年于合肥工业大学获得学士学位, 现为奇瑞汽车股份有限公司电源系统工程师, 主要研究方向为低压电源管理及控制。

E-mail: huaxiaofei@mychery.com

Hua Xiaofei received his B. Sc. degree from Hefei University of Technology in 2018. Now he is a power system engineer, Chery Automobile Co., Ltd. His main research interest includes low-voltage power management and control.