

DOI: 10.13382/j.jemi.B2508288

基于云端数据的 AEKF-LSTM 融合算法预测电池 SOC^{*}

吴文进¹ 吴晶¹ 詹文法¹ 查申龙¹ 苏建徽^{2,3}

(1. 安庆师范大学电子工程与智能制造学院 安庆 246133; 2. 合肥工业大学电气与自动化工程学院 合肥 230009;
3. 合肥综合性国家科学中心能源研究院(安徽省能源实验室) 合肥 230071)

摘要:针对目前电池荷电状态(stage of charge, SOC)估计算法存在稳定性差、误差大等缺点,提出一种基于实车云端放电数据的自适应扩展卡尔曼滤波(adaptive extended Kalman filter, AEKF)与长短时记忆(long short term memory, LSTM)融合的算法,预测小动力电动车的电池 SOC。首先采用自适应遗忘因子最小二乘法(adaptive forgetting factor recursive least squares, AFFRLS)辨识电池的二阶 RC 等效电路模型参数。其次,将云端实时采集到的放电数据作为研究目标,通过 AEKF-LSTM 融合算法对小动力电动车的电池 SOC 进行预测实验,实验过程中 AEKF-LSTM 融合算法将当前时刻的端电压、电流、温度以及上一时刻电池的 SOC 作为输入,以更新的 SOC 作为输出训练估计模型。最后,将 AEKF-LSTM 融合算法和单一 AEKF 算法预测电池 SOC 的结果与实际 SOC 值进行比较,实验结果表明,AEKF-LSTM 融合算法的均方根误差(root mean square error, RMSE)为 0.005 8 V, 平均绝对误差(mean absolute error, MAE)为 0.004 1 V, 比 AEKF 算法的 RMSE 减小 0.008 7 V, MAE 减小 0.116 4 V, 且 AEKF-LSTM 融合算法的 RMSE 和 MAE 均在 0.6% 以内,证明了该融合算法有较高的估计精度和较强的鲁棒性。

关键词: 荷电状态 SOC; AEKF 算法; LSTM 神经网络; 小动力电动车; 云端数据

中图分类号: TN919.5 **文献标识码:** A **国家标准学科分类代码:** 470.40

AEKF-LSTM fusion algorithm based on cloud data predicts battery SOC^{*}

Wu Wenjin¹ Wu Jing¹ Zhan Wenfa¹ Zha Shenlong¹ Su Jianhui^{2,3}

(1. School of Electronic Engineering and Intelligent Manufacturing, Anqing Normal University, Anqing 246133, China;
2. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;
3. Institute of Energy of Hefei Comprehensive National Science Center (Anhui Energy Laboratory), Hefei 230071, China)

Abstract: Owing to the shortcomings of current state of charge (SOC) estimation algorithms, such as poor stability and large error, a new algorithm based on the integration of adaptive extended Kalman filter (AEKF) and short term memory (LSTM) based on real vehicle cloud discharge data was proposed to predict SOC of small-power electric vehicles. Adaptive forgetting factor least square method (AFFRLS) was used to identify the second order RC equivalent circuit model parameters of the battery. Secondly, the real-time discharge data collected by the cloud is taken as the research target, and the AEKF-LSTM fusion algorithm is used to predict the battery SOC of small-power electric vehicles. The AEKF-LSTM fusion algorithm takes the terminal voltage, current, temperature at the current moment and the SOC of the battery at the previous moment as inputs, and uses the updated SOC as the output to train the estimation model. Finally, compare the battery SOC prediction results of the AEKF-LSTM fusion algorithm and the single AEKF algorithm with the actual SOC values. The experimental results show that the root mean square error (RMSE) of the AEKF-LSTM fusion algorithm is 0.005 8 V, and the mean absolute error (MAE) is 0.004 1 V. Compared with the AEKF algorithm, its RMSE is reduced by 0.008 7 V and its MAE is reduced by 0.116 4 V, and both RMSE and MAE of AEKF-LSTM fusion algorithm are less than 0.6%. It is proved that the fusion algorithm has high estimation accuracy and strong robustness.

Keywords: state of charge (SOC); AEKF algorithm; LSTM neural network; lower power electric vehicle; cloud data

收稿日期: 2025-04-07 Received Date: 2025-04-07

* 基金项目: 国家自然科学基金重大研究计划项目(92573109)、国家自然科学基金面上项目(62474002)、国家自然科学基金青年基金(62205005)、安徽高校协同创新项目(GXXT-2021-025)资助

0 引言

当前,电商、外卖等行业地迅速发展,增加了对商品派送服务的需求。大部分的派送员以小动力电动车作为配送工具。小动力电动车以电池产生的电力作为动力驱动来源,不仅减少了污染物的排放,为居民创造了静谧的居住环境,低廉的电力价格还大大减少了配送成本。这些优点意味着可以将更多的资源投入新能源产业的发展,推动电池续航技术的更新与升级。

锂离子电池^[1-3]具有无记忆效应及输出功率高等优点被应用于电动车等交通领域。电池的荷电状态(stage of charge, SOC)估计^[4-6]精度与电池的使用寿命紧密关系,牵制着新能源交通产业的发展,因此,电池 SOC 估计是当前新能源产业的研究热点。在小动力电动车后台运行管理系统中,不同温度条件以及不同驾驶习惯下的电池运行数据需要被上传至后台,用来分析各客户端电池的运行状态,后台云端数据的特点主要为数据规模大,实时性强,分析的复杂程度更高,合适的云端数据算法可以实现高精度的 SOC 预测。

对电池 SOC 进行精确估计之前要先建立合适的电池模型,常采用等效电路、神经网络等模型。常用的电池 SOC 估计主要有以下方法。文献[7]采用了安时积分法,该方法简便,但若测量仪器不够精密,电流测量不准确,多次积分后误差会累积,最终导致误差越来越大。文献[8]采用开路电压法,该方法只能在非工作状态下进行预测,并且所需的静置时间长,不适用于动态预测。文献[9]提出一种基于反向传播(back propagation, BP)神经网络方法估计电池 SOC,该模型存在精度与稳定性较差等问题。扩展卡尔曼滤波(extended Kalman filter, EKF)^[10-11]算法能够抑制噪声对预测结果的干扰,但需要大量的矩阵运算,多次运算易产生误差累积。结合现有方法的优点,减小估计结果受噪声与计算复杂的影响,本文提出一种基于自适应扩展卡尔曼滤波(adaptive extended Kalman filter, AEKF)^[12-14]与长短时记忆(long short term memory, LSTM)算法融合的电池 SOC 估计方法。AEKF 算法是由 EKF 算法改进而来,可以减少噪声对电池 SOC 估计造成的误差。LSTM 算法具有非线性建模能力,可以处理、归类数据,将修正后的系数即时输出,状态变量也能随之更新。AEKF-LSTM 融合算法基于云端放电数据,将当前时刻的端电压、电流、温度以及上一时刻电池的 SOC 作为输入,以更新的 SOC 作为输出训练估计模型。该方法可以规避当前算法模型估计电池 SOC 误差较大的问题及滤波失真等困扰。本文采用小动力电动车运行数据来源于智行新能科技(安徽)有限公司客户端运行时的实际工况电压电流数据,具有不规则、抖动

大、干扰多等复杂多样的工况特征。

1 建立电池模型

本文电池建模采用 RC 等效电路模型^[15-17],该模型可以精确模拟锂离子电池的动态特性。随着阶数的增加,等效电路模型的计算变得复杂。因此选用效果最佳的二阶 RC 等效电路模型,具有结构简单、参数辨识简单的优点。

本文建立二阶 RC 等效电路模型如图 1 所示。其中, U_{oc} 表示电池的开路电压, U_t 为端电压, R_0 为内阻, R_1 、 R_2 为两个极化内阻, C_1 、 C_2 为极化电容,支路的电压分别为 U_1 、 U_2 。

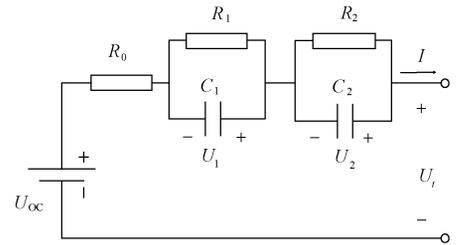


图 1 等效电路

Fig. 1 Equivalent circuit diagram

依据基尔霍夫电压定律,可以建立如下方程:

$$\dot{U}_1 = I/C_1 - U_1/(R_1 C_1), \dot{U}_2 = I/C_2 - U_2/(R_2 C_2) \quad (1)$$

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

式中: \dot{U}_1 表示电压 U_1 随时间的变化率; I 表示电流; \dot{U}_2 表示电压 U_2 随时间的变化率。

若用 τ_1 、 τ_2 表示时间常数,则 $\tau_1 = R_1 C_1$ 、 $\tau_2 = R_2 C_2$,采样时间用 Δt 表示,结合式(1)和(2)得到:

$$\begin{cases} U_1(k) = U_1(k-1) - \Delta t U_1(k-1)/\tau_1 + R_1 I(k-1)/\tau_1 \\ U_2(k) = U_2(k-1) - \Delta t U_2(k-1)/\tau_2 + R_2 I(k-1)/\tau_2 \end{cases} \quad (3)$$

$$U_t(k) = U_{oc}(k) - U_1(k) - U_2(k) - I(k)R_0(k) \quad (4)$$

式中: $U_1(k)$ 表示下一时刻的电压 U_1 ; $U_1(k-1)$ 表示初始时刻的电压 U_1 ; $I(k-1)$ 表示初始时刻的电流 I ; $U_2(k)$ 表示下一时刻的电压 U_2 ; $U_2(k-1)$ 表示初始时刻的电压 U_2 ; $U_t(k)$ 表示下一时刻的端电压 U_t ; $U_{oc}(k)$ 表示下一时刻的开路电压 U_{oc} ; $I(k)$ 表示下一时刻的电流 I ; $R_0(k)$ 表示下一时刻的内阻 R_0 。

根据 SOC 定义得到:

$$SOC(k) = SOC(k-1) - I(k)\Delta t/C_n \quad (5)$$

式中: $SOC(k)$ 表示更新的 SOC 状态; $SOC(k-1)$ 表示初始 SOC 状态; $I(k)$ 表示初始时刻的电流 I ; C_n 表示额

定容量。

结合式(3)~(5)得到状态方程,如下:

$$\mathbf{x}_k = \mathbf{A}_{k-1}\mathbf{x}_k + \mathbf{B}_{k-1}\mathbf{u}_{k-1} + \mathbf{w}_k, \quad (6)$$

$$\mathbf{y}_k = \mathbf{C}_k\mathbf{x}_k + \mathbf{D}_k\mathbf{u}_k + \mathbf{v}_k$$

式中: \mathbf{x}_k 为离散时间 k 的系统状态向量; \mathbf{A}_k 、 \mathbf{C}_k 表示状态方程的系数矩阵; \mathbf{u}_k 为离散时间 k 的测量系统输入; \mathbf{w}_k 为过程噪声; \mathbf{y}_k 为系统输出; \mathbf{B}_k 、 \mathbf{D}_k 为关于 \mathbf{u}_k 的雅可比矩阵; \mathbf{v}_k 为测量噪声。

其中, \mathbf{x}_k 、 \mathbf{A}_{k-1} 、 \mathbf{B}_{k-1} 、 \mathbf{C}_k 、 \mathbf{D}_k 表达式如下:

$$\begin{cases} \mathbf{x}_k = [\text{SOC}(k) \quad U_1(k) \quad U_2(k)]^T \\ \mathbf{A}_{k-1} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\Delta t/\tau_1} & 0 \\ 0 & 0 & e^{-\Delta t/\tau_2} \end{bmatrix} \\ \mathbf{B}_{k-1} = [-\Delta t/C_n \quad R_1(1 - e^{-\Delta t/\tau_1}) \quad R_2(1 - e^{-\Delta t/\tau_2})]^T \\ \mathbf{C}_k = [U_{oc}[\text{SOC}(k)]/\text{SOC}(k) - 1 - 1]^T \\ \mathbf{D}_k = [-R_0(k)] \end{cases} \quad (7)$$

2 参数辨识

本文选取小动力电动车电池实际运行的云端数据进行测试实验。首先获取电池的 OCV-SOC 曲线,电池的开路电压与 SOC 的拟合曲线是参数辨识^[18-20]的前提。主要实验流程如下:1) 电池充满电后静置一段时间;2) 以 1 C 的电流对电池脉冲放电 10 s,之后静置 40 s;3) 以 1 C 的电流对电池放电 10% 的 SOC,静置 1 h。重复步骤 2)~3) 直到 SOC 降为 0%。这里的 C 代表充放电倍率,通过测试实验得到 0%~100% SOC 对应开路电压值^[21]。通过 Curve Fitting Tool 将实验获取的电压和 SOC 的数据进行拟合,结果如图 2 所示,得到电压与 SOC 的 9 阶多项式函数,如式(8)所示。

$$\text{OCV} = 565.9 \times \text{SOC}^9 - 2488 \times \text{SOC}^8 + 4468 \times \text{SOC}^7 - 4187 \times \text{SOC}^6 + 2155 \times \text{SOC}^5 - 577.9 \times \text{SOC}^4 + 64.58 \times \text{SOC}^3 - 0.8059 \times \text{SOC}^2 + 0.803 \times \text{SOC} + 3.339 \quad (8)$$

之后对参数进行辨识,本文采用自适应递推最小二乘算法(adaptive forgetting factor recursive least squares, AFFRLS)^[22]对电池的参数进行辨识。遗忘因子的计算公式如下

$$\begin{cases} \lambda(k) = \lambda_{\max} - (\lambda_{\max} - \lambda_{\min}) \cdot \arctan(\mu(k)) \cdot 2/\pi \\ \mu(k) = \text{round}(|e(k)/e_0|^n) \end{cases} \quad (9)$$

式中: $\lambda(k)$ 表示遗忘因子; λ_{\max} 表示遗忘因子可取的最大值; λ_{\min} 表示遗忘因子可取的最小值; $\arctan(\cdot)$ 表示三角函数; $e(k)$ 表示误差; e_0 表示基准误差; n 取值为 2 或 4。

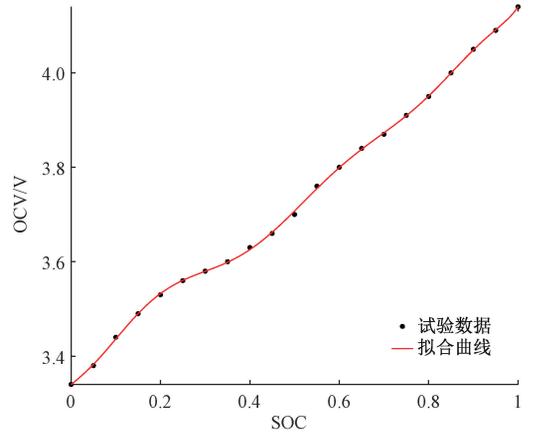


图2 OCV-SOC 拟合图

Fig. 2 OCV-SOC fitting chart

遗忘因子表示新旧数据在运算过程中所占的比例,取值范围在 0~1,遗忘因子越大,表示对旧数据的遗忘程度越大,保留的数据与算法的相关性越强。遗忘因子随着采集到的电池数据的增加进行自适应地调节,通过减少旧数据在协方差矩阵中所占比例,提高辨识结果的准确度。

3 算法介绍

3.1 AEKF 算法

AEKF 算法^[23]是由 EKF 算法改进而来,本文通过 AEKF 算法来估计锂电池的 SOC,以电流、电压、温度为输入变量,以估计 SOC、估计电压 V_t 、电压误差为输出变量。首先通过上述参数辨识方法得到的结果代入矩阵 \mathbf{A}_k 和雅可比矩阵 \mathbf{B}_k 。再通过 EKF 预测校正算法,首先预测未来状态和误差协方差,之后校正卡尔曼增益、用测量值更新估计值和误差协方差,最后修正误差。基本思路是通过噪声方差矩阵进行动态调整的方法减小估计算法产生的误差,当残差协方差的估计值和理论值的更新到相等时即可。

1) 输入: \mathbf{u}_k 、 $\hat{\mathbf{x}}_{0|k}$ 、 $\hat{\mathbf{P}}_{0|k}$ 。

2) 对矩阵进行初始化:

$$\begin{cases} \hat{\mathbf{x}}_{0|k} = \mathbf{E}(\mathbf{x}_{0|k}) \\ \hat{\mathbf{P}}_{0|k} = \mathbf{E}[(\mathbf{x}_{0|k} - \hat{\mathbf{x}}_{0|k})(\mathbf{x}_{0|k} - \hat{\mathbf{x}}_{0|k})^T] \end{cases} \quad (10)$$

3) 对未来状态进行估计:

$$\hat{\mathbf{x}}_{k+1|k} = \mathbf{A}\hat{\mathbf{x}}_{k|k} + \mathbf{B}\mathbf{u}_k \quad (11)$$

4) 对误差协方差进行估计:

$$\hat{\mathbf{P}}_{k+1|k} = \mathbf{A}\hat{\mathbf{P}}_{k|k}\mathbf{A}^T + \mathbf{Q}_k \quad (12)$$

5) 计算卡尔曼增益:

$$\mathbf{K}_{k+1} = \mathbf{P}_{k+1|k} \mathbf{C}^T (\mathbf{C} \mathbf{P}_{k+1|k} \mathbf{C}^T + \mathbf{R}_{k+1})^{-1} \quad (13)$$

6) 更新估计值:

$$\hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k+1|k} + \mathbf{K}_{k+1} (\mathbf{z}_{k+1} - \mathbf{C} \hat{\mathbf{x}}_{k+1|k}) \quad (14)$$

7) 更新误差协方差:

$$\hat{\mathbf{P}}_{k+1|k+1} = (\mathbf{I} - \mathbf{K}_{k+1} \mathbf{C}) \mathbf{P}_{k+1|k} \quad (15)$$

8) 自适应律协方差匹配:

$$\mathbf{Q}_k = \mathbf{K}_k \cdot \text{error}_k \cdot \mathbf{K}_k^T \quad (16)$$

9) 输出: $\hat{\mathbf{x}}_{k+1|k+1}$ 、 $\hat{\mathbf{P}}_{k+1|k+1}$ 。

AEKF 算法的具体流程如图 3 所示,初始化参数后,通过 AFFRLS 算法对参数进行辨识,将辨识结果代入式

(10)~(16) 得到 $\hat{\mathbf{x}}_k$, 最后得到 SOC 最新估计值。

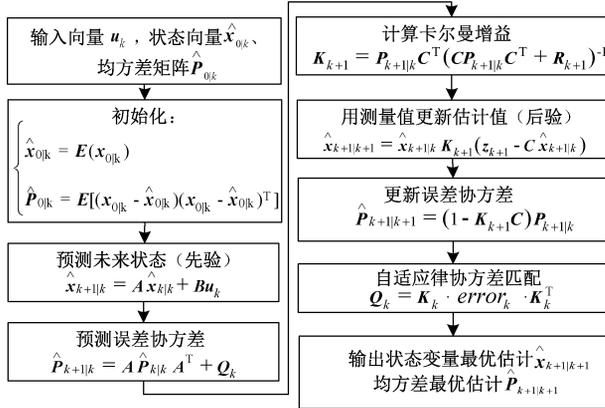


图 3 AEKF 算法流程

Fig. 3 AEKF algorithm flow chart

3.2 LSTM 网络

LSTM 神经网络^[24-25]能够处理序列数据,通过增加门控机制解决梯度消失的问题,可以简化神经网络结构,提高对参数的运算效率。主要由 C_t 、 f_t 、 i_t 和 o_t 构成。 C_t 表示记忆单元,作用是维持梯度恒定,避免了长序列训练产生的问题,简化了网络结构; f_t 表示遗忘门,作用是决定遗忘多少上一时刻的记忆; i_t 表示输入门,作用是对当前时刻的记忆单元状态进行更新; o_t 表示输出门,作用是对隐藏状态信息的输出量进行控制。LSTM 算法的过程如下:

- 1) 前向计算 f_t 、 i_t 、 o_t 、 C_t 、 h_t ;
- 2) 反向计算神经元的误差项;
- 3) 计算每个权重的梯度;
- 4) 更新权重。

本文以 LSTM 网络作为数据驱动模型,LSTM 结构如图 4 所示。其中,输入层的数据为 \mathbf{K}_k ,即 k 时刻的卡尔曼增益矩阵; e_{k+1} ,即每次估计得到的误差。隐藏层的数据包括充放电容量、充放电电压等。输出层为 AEKF 算法估计 SOC 与真实 SOC 之间的差值。

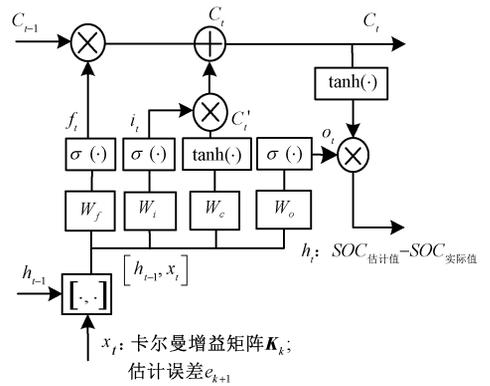


图 4 LSTM 的结构

Fig. 4 Structure diagram of LSTM

其计算公式如下所示:

$$\begin{cases} f_t = \sigma(w_f[h_{t-1}, x_t] + b_f), i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \\ o_t = \sigma(w_o[h_{t-1}, x_t] + b_o), \tilde{C}_t = \tanh(w_c[h_{t-1}, x_t] + b_f) \\ C_t = f_t C_{t-1} + i_t \tilde{C}_t, h_t = o_t \tanh(C_t) \end{cases} \quad (17)$$

式中: $\sigma(\cdot)$ 是非线性的 sigmoid 激活函数,表达式为 $\sigma(x) = 1/(1 + e^{-x})$; w 表示权重矩阵; h_{t-1} 表示上一个隐藏状态; x_t 表示输入; b 表示偏置向量; $\tanh(\cdot)$ 是双曲正切函数,表达式为 $\tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x})$ 。

LSTM 神经网络在估计电池 SOC 之前,首先对误差和迭代次数进行初始化,之后设置迭代次数,将数据返回后正则化。通过遗忘门获取输入层及隐藏层的数据,输出值在 0~1 的范围内。输出的 f_t 值越接近 0,代表需要保留的数据越少,需要遗忘的数据越多。输出的 f_t 值越接近 1,则代表需要保留的数据越多,数据相关性越强。输入门读取通过 x_{t-1} 和 h_{t-1} 获得的 i_t 和 h_t ; 输出门根据 x_{t-1} 和 h_{t-1} 得到的 o_t 决定输出所需 SOC 的误差补偿数值。

3.3 AEKF-LSTM 融合算法估计电池 SOC

小动力电动车电池在运行过程会受环境温度等因素的影响,电池参数会产生变化,随着时间的推移,造成 SOC 估计误差变大。以单一的 LSTM 神经网络进行电池 SOC 估计时,算法缺少上一样本的采样信息,会出现运算复杂的困扰,权重与偏置矩阵也会影响运算速度。

本文提出一种基于云端数据的 AEKF-LSTM 融合算法来预测小动力电动车电池 SOC,解决单一算法带来的上述问题,融合算法的框架如图 5 所示。通过 AEKF 模型得到电池 SOC 的上一样本数据,通过上一时刻的端电压与上一时刻的电流计算出电池 SOC。LSTM 神经网络再将该 SOC 值作为输入,得到估计的电池 SOC。该融合算法的模型有 4 个输入,分别为当前时刻的电流 $I(k)$ 、端电压 $U_t(k)$ 、温度 $T(k)$ 及上一时刻的电池 SOC ($k -$

1), 解决了单一算法受噪声及计算复杂的问题, 提高了算法对小动力电动车电池 SOC 预测的精度^[26-28]。

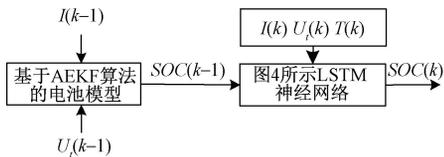


图 5 AEKF-LSTM 融合算法框架

Fig. 5 AEKF-LSTM fusion algorithm framework

首先, 通过云端采集电压、电流等数据, 由于电池参数辨识会受到电压以及变化的 SOC 的影响, 因此采用 AFFRLS 算法辨识电池各参数。在整个 SOC 的估计过程中, 每循环一次的辨识结果都进一步修正 AEKF 算法模型的参数。本文采用 AFFRLS 算法辨识模型参数, 结合 AEKF 算法与 LSTM 神经网络实时估计电池 SOC 并计算 SOC 误差, 该模型有效提高电池 SOC 估计结果的精度。AEKF-LSTM 融合算法的电池 SOC 预测流程如图 6 所示。

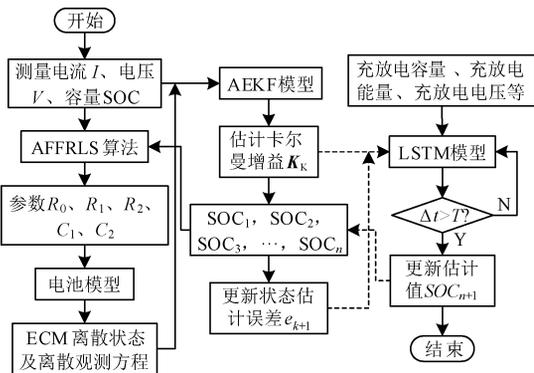


图 6 融合算法的 SOC 估计方法流程

Fig. 6 The SOC estimation method flow of fusion algorithm

校正间隔周期数为 T 。与 AEKF 算法结合对电池 SOC 进行实时预测, 利用 LSTM 神经网络估计 SOC 误差。该方法有效地提高模型预测 SOC 的精度。辨识获取的电池参数代入离散方程。至此, 参数初始化结束。在前 n 个周期中, 根据离散方程预测电池 SOC, 之后再次代入 AFFRLS 算法中修正辨识参数和估计电池 SOC。

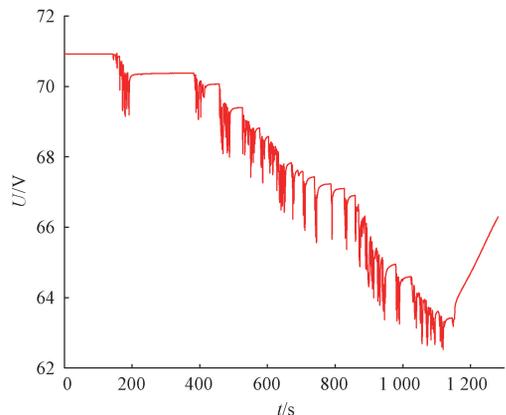
采用 LSTM 模型估计电池 SOC, 每 T 次循环, 观测器会对 AEKF 模型参数再次修正, 并输入 LSTM 模型, 更新的神经网络输出值为 AEKF 模型估计的 SOC 补偿值, 有效地提高了电池的 SOC 估计精度。

4 实验测试部分

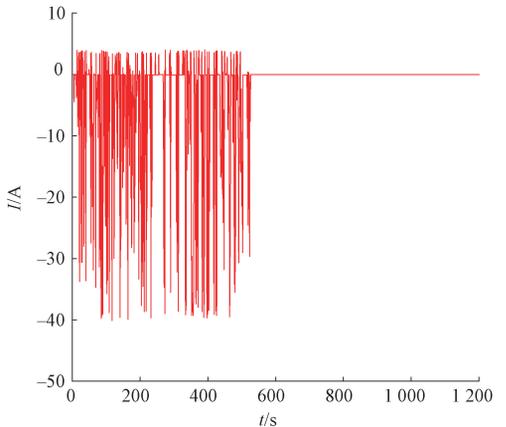
4.1 实验验证

考虑到小动力电动车在实际行驶的过程中, 电池数

据会在外界因素的干扰下出现波动等情况。因此, 本文为了验证所提算法的实际运用意义, 通过云端采集实时运行的电池数据对电池 SOC 进行预测实验。采集到的部分电压和电流曲线如图 7 所示。



(a) 电压曲线
(a) Voltage diagram



(b) 电流曲线
(b) Current diagram

图 7 电压电流测量曲线

Fig. 7 Voltage and current measurement curve

由于小动力电动车在使用过程中放电程度任意, 停留与行驶时间任意, 所以从图 7 可以看出电池实际运行的数据存在波动幅度大、不规则等特点。将上述电压、电流数据代入 MATLAB 软件编写的算法程序中并运行, 得到 AEKF 算法与 AEKF-LSTM 融合算法仿真实验估计的电池 SOC。为了直观的表达模型的估计精度, 选择均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE) 来判断融合算法的性能, 其计算公式分别为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n [x(k) - \hat{x}(k)]^2} \quad (18)$$

$$MAE = \frac{1}{n} \sum_{k=1}^n |x(k) - \hat{x}(k)| \quad (19)$$

式中: n 为选取的样本数; $x(k)$ 为观测值; $\hat{x}(k)$ 为估

计值。

4.2 结果分析

AEKF-LSTM 融合算法以 AEKF 算法输出结果作为输入,LSTM 算法增强估计结果稳定性并修正误差。另外,将 AEKF-LSTM 融合算法的估计结果与单一 AEKF 算法的估计结果以及真实 SOC 值进行对比。仿真对比实验结果及误差对比结果分别如图 8 和 9 所示。两种算法的 RMSE 和 MAE 误差计算结果如表 1 所示。

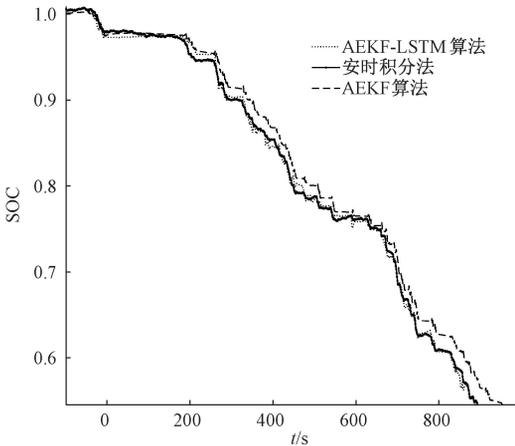


图 8 3 种算法估计结果

Fig. 8 Estimation results of three algorithms

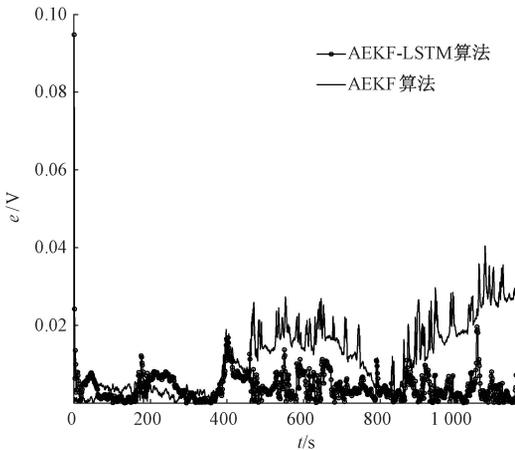


图 9 两种算法 SOC 误差对比

Fig. 9 SOC error comparison diagram of two algorithms

表 1 SOC 估计误差结果

Table 1 The results of SOC estimation errors

算法	RMSE/V	MAE/V
AEKF	0.014 5	0.120 5
AEKF-LSTM	0.005 8	0.004 1

从图 8 可以看出,AEKF-LSTM 融合算法的估计效果明显更好,较 AEKF 算法的估计曲线更加接近真实值的

曲线。从图 9 可以看出 AEKF 算法误差曲线在 400 s 之后波动幅度较大,AEKF-LSTM 融合算法的误差整体波动幅度较为平缓,在开始的短时间内出现大幅度波动现象,之后又快速收敛,变得平缓,该现象证明了融合算法在多种因素作用下的实际数据具有真实性。融合算法收敛后,电池 SOC 估计误差在 2% 以内,证明了该算法对电池 SOC 的估计精度较高。因此,通过仿真实验验证了 AEKF-LSTM 融合算法的估计效果具有精准的估计效果以及较好的鲁棒性。

根据表 1 可知,AEKF-LSTM 融合算法的 RMSE 和 MAE 均在 0.6% 以内,同时 RMSE 比 AEKF 算法减少了 0.008 7 V,MAE 比 AEKF 算法减少了 0.116 4 V,该实验数据充分证明了所提 AEKF-LSTM 融合算法具有更高的电池 SOC 估计精度。

5 结论

本文提出一种基于云端数据的 AEKF-LSTM 融合算法估计小动力电动车电池的 SOC。采用小动力电动车的运行数据,其特点是在较短时间内累计大量的充放电循环数据,其充放电数据可以体现复杂多样的工况特征。为保障动力电池的安全运行以及车辆的正常使用,云端需要实时接收电池数据。采用 AEKF 算法获取电压、电流以及 SOC 间的非线性关系得到输出 SOC,以该输出 SOC 作为 LSTM 网络的输入。基于云端的小动力电动车电池数据建立仿真实验,验证本文所提融合算法的估计精度更高。实验结果表明,AEKF-LSTM 融合算法的 RMSE 为 0.005 8 V,MAE 为 0.004 1 V,都在 0.6% 以内。比 AEKF 算法的 RMSE 减少了 0.008 7 V,MAE 减少了 0.116 4 V,证明本文所提融合算法估计 SOC 的精度更为准确,具有较强的鲁棒性,还验证了该融合算法可用于实车采集到的波动幅度大、无规律性电池数据的 SOC 预测。

目前,电商行业的快速发展加剧了派送服务对电池充换电的使用需求,促进了充电柜技术产业的更新与升级。因此,本文所提融合算法具有较广泛的现实意义,同时对锂电池的寿命预测及电池健康管理具有参考价值。

参考文献

- [1] 彭自然,杨肖阳,肖伸平. 基于 EKF-HInformer 模型估计汽车动力电池的 SOC&SOH[J]. 电子测量与仪器学报, 2025,39 (3):21-33.
PENG Z R, YANG X Y, XIAO SH P. Estimation of SOC&SOH of automotive power batteries based on EKF-HInformer model [J]. Journal of Electronic Measurement and Instrumentation, 2025,39 (3):21-33.
- [2] 吴文进,吴晶,郭海婷,等. 基于变论域模糊 PID 算

- 法的锂电池组级联式均衡控制[J]. 电子测量与仪器学报, 2024, 38(8): 137-144.
- WU W J, WU J, GUO H T, et al. Cascade equalization control of lithium battery pack based on variable discourse domain fuzzy PID algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (8) : 137-144.
- [3] 缪书文. 基于数据驱动方法的锂离子电池健康管理研究[D]. 成都: 西南交通大学, 2022.
- MIU SH W. Research on health management of lithium-ion battery based on data-driven method [D]. Chengdu: Southwest Jiaotong University, 2022.
- [4] YUN J, CHOI Y, LEE J, et al. State-of-charge estimation method for lithium-Ion batteries using extended Kalman filter with adaptive battery parameters[J]. IEEE Access, 2023, 11: 90901-90915.
- [5] 寇发荣, 王甜甜, 王思俊, 等. 基于 ABC-RFEKF 算法的锂电池 SOC 估计[J]. 电力系统保护与控制, 2022, 50(4): 163-171.
- KOU F R, WANG T T, WANG S J, et al. SOC estimation of lithium battery based on ABC-RFEKF algorithm [J]. Power System Protection and Control, 2022, 50(4): 163-171.
- [6] 高峰, 贾建芳, 元淑芳, 等. 基于 GRU-UKF 的锂离子电池 SOC 估计方法研究[J]. 电子测量与仪器学报, 2022, 36(11): 160-169.
- GAO F, JIA J F, YUAN SH F, et al. Lithium ion battery SOC estimation based on GRU helped - UKF method research [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (11) : 160-169.
- [7] 郭兆东. 储能锂电池状态估计及主动均衡策略研究[D]. 北京: 北方工业大学, 2024.
- GUO ZH D. Research on state estimation and active balancing strategy of energy storage Lithium battery [D]. Beijing: North China University of Technology, 2024.
- [8] SUNDARESAN S, SUNIL S, BALASINGAM B, et al. Joint estimation of open circuit voltage and equivalent circuit model parameters using state-space model optimization [C]. IEEE Transportation Electrification Conference & Expo, 2023: 1-6.
- [9] BAO C, CHEN J Q, XIONG H, et al. Research on classification and prediction of general traffic accidents on national and provincial highways based on BP neural networks [J]. International Conference on Neural Networks, Information and Communication Engineering, 2024, 4: 781-784.
- [10] LUO L Z, CHEN G. Research on SOC estimation of lithium battery for electric vehicle based on EKF algorithm [C]. International Conference on Power System Technology, 2021: 820-823.
- [11] TIAN F, GUO X Z, FU W B. Target tracking algorithm based on adaptive strong tracking extended Kalman filter [J]. Electronics, 2024, 13(3): 652.
- [12] XIA Y H, YE Z H, HUANG L M, et al. Research on a high-precision state-of-charge estimation method based on forgetting factor recursive least squares and adaptive extended Kalman filter applied to LiFePO4 battery [J]. Electronics, 2023, 12(17): 3670.
- [13] 袁正峰, 郭兴众, 花晓飞. 基于改进的 AEKF 铅酸电池 SOC 在线估计[J]. 电子测量与仪器学报, 2023, 37(2): 228-235.
- YUAN ZH F, GUO X ZH, HUA X F. SOC online estimation based on improved AEKF lead-acid battery [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2): 228-235.
- [14] 刘征宇, 杨俊斌, 张庆, 等. 基于 QPSO-BP 神经网络的锂电池 SOC 预测[J]. 电子测量与仪器学报, 2013, 27(3): 224-228.
- LIU ZH Y, YANG J B, ZHANG Q, et al. SOC prediction of Lithium battery based on QPSO-BP neural network [J]. Chinese Journal of Electronic Measurement and Instrumentation, 2013, 27(3): 224-228.
- [15] SHI H, NI Y L, WEI Z B, et al. Water fault diagnosis for PEMFC based on an improved equivalent circuit model[C]. 2024 IEEE 25th China Conference on System Simulation Technology and its Application (CCSSTA), 2024: 543-547.
- [16] ZHANG Q Y, ZHANG S J, YIN H D. Equivalent circuit model and parameter identification of lithium-sulfur battery[C]. 2023 International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE), 2023: 1-8.
- [17] NIE Y H, WANG Y, SI Y T. Research on modeling and SoC estimation of second-order RC equivalent model of Li-ion battery based on extended Kalman filter[C]. 2022 IEEE 5th International Conference on Information Systems and Computer Aided Education (ICISCAE), 2022: 514-517.
- [18] WU Y H, CHEN H S, CAO L Q, et al. Research on online identification of lithium-ion battery equivalent circuit model parameters[C]. 9th International Forum on Electrical Engineering and Automation, 2022: 130-136.
- [19] HU T Z, LIU J X, J. CAO J W, et al. On-line parameter identification of permanent magnet synchronous motor based on extended Kalman filter[C]. 2022 25th International Conference on Electrical Machines and

- Systems (ICEMS), 2022; 1-6.
- [20] ZHANG C, BU B, CUI S M. On-line estimation method of junction temperature based on SiC module aging parameter identification [C]. 2022 IEEE International Power and Renewable Energy Conference (IPRECON), 2022; 1-6.
- [21] WANG Z, FAN X M, HE Q, et al. SOC evaluation of lithium batteries based on VKF, ampere-hour integration and unsteady open circuit voltage fusion method [C]. International Symposium on Computational Intelligence and Design, 2022, 15; 228-231.
- [22] MOUNCEF E, MOSTAFA B, NAOUFL E. Online parameter estimation of an electric vehicle lithium-ion battery using AFFRLS [C]. 2020 IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS), 2020; 1-6.
- [23] TAO Y, CHANG H, HU J H, et al. FFRLS-AEKF based SOC estimation approach for Li-ion battery applied in electric boat system [C]. China Automation Congress, 2023; 6820-6825.
- [24] CHAKRABORTY S, BANIK J, ADDHYA S, et al. Study of dependency on number of LSTM units for character based text generation models [C]. International Conference on Computer Science, Engineering and Applications, 2020; 1-5.
- [25] ZHOU Y H, DONG M M, WU J. Hyperparameter optimization for SOC estimation by LSTM with internal resistance [C]. International Conference on Computer Network, Electronic and Automation, 2021; 263-267.
- [26] 吴文进, 郭海婷, 苏建徽, 等. 基于自适应模糊 PID 算法的锂电池组双层均衡控制 [J]. 电力系统保护与控制, 2024, 52(2): 111-117.
- WU W J, GUO H T, SU J H, et al. Dual layer equalization control of lithium battery pack based on adaptive fuzzy PID algorithm [J]. Power System Protection and Control, 2024, 52(2): 111-117.

- [27] 骆凡, 黄海宏, 王海欣. 基于电化学阻抗谱的退役动力电池荷电状态和健康状态快速预测 [J]. 仪器仪表学报, 2021, 42(9): 172-180.
- LUO F, HUANG H H, WANG H X. Rapid prediction of state of charge and state of health for retired power batteries based on electrochemical impedance spectroscopy [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 172-180.
- [28] WIJESINGHE S. Time series forecasting: Analysis of LSTM neural networks to predict exchange rates of currencies [J]. Instrumentation, 2020, 7(4): 25-39.

作者简介



吴文进, 2001 年于郑州轻工业大学获得学士学位, 2006 年于合肥工业大学获得硕士学位, 2018 年于合肥工业大学获得博士学位, 现为安庆师范大学教授, 主要研究方向为电力电子系统及其控制、电能储存与节电技术。

E-mail: wuwenjinaq@163.com

Wu Wenjin received his B. Sc. degree from the Zhengzhou University of Light Industry, Zhengzhou, China, in 2001, M. Sc. degree and Ph. D. degree both from the Hefei University of Technology in 2006 and 2018, respectively. He is now a professor at Anqing Normal University. His main research interests include renewable energy generation technology, new energy vehicle power battery, and power electronics.



吴晶 (通信作者), 2023 年于安庆师范大学获得学士学位, 现为安庆师范大学硕士研究生, 主要研究方向为储能电池建模和储能系统控制。

E-mail: wujing012@126.com

Wu Jing (Corresponding author) received her B. Sc. degree from the Anqing Normal University in 2023. Now she is a M. Sc. candidate in Anqing Normal University. Her main research interests include energy storage battery modeling and energy storage system control.