

考虑温度变化的新能源汽车动力电池荷电状态估计

孙君光^{1,2}, 杜睿³, 陈立新^{1,2}, 李慧^{1,2}, 王斌³, 赵雪茹^{1,2}, 董秀辉³

(1. 工业产品环境适应性全国重点实验室, 510663, 广州; 2. 中国电器科学研究院股份有限公司, 510663, 广州; 3. 西安交通大学机械工程学院, 710049, 西安)

摘要: 针对温度变化应用场景下新能源汽车动力电池荷电状态(SOC)估计不精确问题,提出了一种基于神经网络和无迹卡尔曼滤波修正的电池SOC估计方法。首先,考虑温度变化影响建立动态参数的Thevenin等效电路模型。分析温度变化条件下的电池开路电压变化特性,确定电池SOC与开路电压之间的对应关系。同时,分析温度变化条件下的电池容量变化特性,采用神经网络训练电池容量随温度变化的神经网络温度因子。进一步,通过带遗忘因子的递推最小二乘法辨识模型动态参数。在此基础上,利用神经网络温度因子和无迹卡尔曼滤波实时修正以实现温度变化条件下的精确SOC估计。实验结果表明:相比于传统的电池SOC估计方法,考虑温度变化的电池SOC估计方法可以显著提高SOC估计精度,在-15℃低温环境下,所提方法使SOC估计精度提高了2.77%。

关键词: 新能源汽车;动力电池;荷电状态估计;神经网络;无迹卡尔曼滤波

中图分类号: TM912 **文献标志码:** A

DOI: 10.7652/xjtuxb202411004 **文章编号:** 0253-987X(2024)11-0039-13

State of Charge Estimation for Power Batteries in New Energy Vehicles Considering Temperature Fluctuations

SUN Junguang^{1,2}, DU Rui³, CHEN Lixin^{1,2}, LI Hui^{1,2}, WANG Bin³,
ZHAO Xueru^{1,2}, DONG Xiuhui³

(1. State Key Laboratory of Environmental Adaptability for Industrial Products, Guangzhou 510663, China;

2. China National Electric Apparatus Research Institute Co., Ltd., Guangzhou 510663, China;

3. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the issue of inaccurate state of charge (SOC) estimation for power batteries in new energy vehicles in scenarios involving temperature variations, a modified battery SOC estimation method based on neural network and unscented Kalman filter (UKF) is proposed. Initially, a Thevenin equivalent circuit model with dynamic parameters is established, taking into account the effects of temperature fluctuations. The characteristics of changes in battery open-circuit voltage (OCV) under varying temperature conditions are examined to establish the relationship between battery SOC and OCV. Additionally, the alterations in battery capacity

收稿日期: 2024-07-01。 作者简介: 孙君光(1976—),男,教授级高级工程师;王斌(通信作者),男,副研究员,硕士生导师。 基金项目: 陕西省重点研发计划资助项目(2023-YBGY-376);工业产品环境适应性全国重点实验室开放基金资助项目(2024EASKJ-006)。

网络出版时间: 2024-08-07

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20240806.1459.004>

under temperature variations are analyzed. A neural network is employed to train the neural network temperature factor for battery capacity reduction corresponding to temperature changes. Furthermore, the dynamic model parameters are identified using the recursive least squares algorithm with a forgetting factor. Subsequently, the neural network temperature factor and the UKF are utilized for real-time adjustments to ensure precise SOC estimation under changing temperature conditions. The results demonstrate that the battery SOC estimation method considering temperature variations significantly enhances SOC estimation accuracy compared to traditional methods. In a low-temperature environment of -15°C , the proposed method enhances SOC estimation accuracy by 2.77%.

Keywords: new energy vehicles; power batteries; state of charge estimation; neural network; unscented Kalman filter.

随着我国新能源汽车产业的蓬勃发展,混合动力汽车、纯电动汽车和氢燃料电池汽车等相继出现和逐步市场化推广^[1-2]。新能源汽车对打破国外能源垄断和实现高端汽车技术弯道超车具有重要的意义,也是实现我国汽车节能环保的重要一环。当前,锂电池由于高比能量、长使用寿命和零排放无污染等优点,被广泛用作新能源汽车的动力电池^[3-5]。为提高动力电池使用效率和安全性,新能源汽车需要配置一个电池管理系统(BMS)实时监测动力电池的各种状态,以实现能量管理和安全预警^[6]。动力电池荷电状态(SOC)是电池内部特性的综合表征,是评估电池实时状态的重要因素^[7]。精确的电池 SOC 估计是 BMS 实现能量管理和优化控制的前提^[7-8]。

SOC 估计方法主要包含开路电压法、安时积分法、神经网络法以及等效电路模型法等^[9-20]。开路电压法需要长时间的电池静置测量,无法适用于新能源汽车实时 SOC 估计应用场景^[8-9]。安时积分法估计 SOC 的精度与 SOC 初始值标定精度密切相关,在不考虑外界温度等因素影响和电池容量变化条件下,开环计算方法容易产生较大偏差和累积误差,导致 SOC 估计精度偏低^[5,19]。神经网络法需要大量数据对电压与电流关系进行拟合,具有较高的信息计算成本^[10-13]。等效电路模型法利用等效电压源、等效电阻与电容等元件来模拟和预测动力电池的电压-电流响应,可以实现精确的 SOC 在线估计。现阶段,等效电路模型法已被广泛用于在线 SOC 估计^[14-20]。

动力电池系统是一个非线性时变系统,其输出性能同时受外部温度因素和内部自身参数变化的影响^[21-23]。并且,外部温度变化又会导致动力电池内部电阻和电容等参数变化。因此,常温下动力电池的 SOC 估计方法对于低温或者温度变化环境,估计

结果必然会产生较大误差^[21]。新能源汽车在我国北方地区行驶时,由于一天中昼夜温差极大,动力电池的输出性能和自身参数都会发生大幅度波动^[24]。这对动力电池 SOC 估计和新能源汽车稳定运行产生了巨大的挑战。

针对温度变化应用场景,一些研究人员已经对变温环境电池 SOC 估计展开研究^[24-30]。Feng 等建立混合电化学-热-神经网络模型,结合粒子群算法预测不同恒定温度影响下的电池电压,在城市道路循环(UDDS)工况下实现了 1% 的 SOC 估计精度^[27]。然而,该方法依赖大量数据对于粒子群模型进行训练。Zhang 等在离线状态探究了锂电池内部参数受温度变化的影响,利用扩展卡尔曼滤波和学习机完成 SOC 估计,在千岛湖地区变温环境下的 SOC 估计误差小于 1.67%^[30]。上述方法考虑不同温度下的电池内部电阻、电容等内部参数变化,对温度和电池内部参数进行拟合,但是却没有研究不同温度条件下电池开路电压与 SOC 之间关系、容量衰减对电池 SOC 估计的影响, SOC 估计精度可进一步提升。

针对上述问题,本文提出了一种基于神经网络和无迹卡尔曼滤波修正的 SOC 估计方法。首先,针对温度变化环境,建立动态参数的动力电池 Thevenin 等效电路模型,分析动力电池开路电压的温度变化特性,研究温度变化环境下电池 SOC 与开路电压之间的对应关系。然后,研究电池容量的温度变化特性,引入温度因子,并采用误差反向传播(BP)神经网络训练温度变化条件下容量衰减的神经网络温度因子。进一步,联合带遗忘因子的递推最小二乘法(FRRLS)和无迹卡尔曼滤波(UKF)法实时辨识模型参数和修正 SOC。在不同温度的循环 UDDS 工况下,验证了本文所提方法的准确性和

可靠性。

1 动力电池模型和温度变化特性

1.1 动力电池模型

新能源汽车通常采用按时积分法估计动力电池 SOC,但估计精度受初始误差和潜在累积误差的影响。为了解决这个问题,基于等效电路模型的自适应 SOC 估计方法被广泛研究。等效电路模型包括内阻模型、Thevenin 等效电路模型和多阶 RC 等效电路模型等。内阻模型过于简单,不能反映电池的极化效应和内阻特性,而多阶 RC 等效电路模型参数过多,辨识过程复杂。Thevenin 等效电路模型能够反映电池的极化效应和内阻特性,且参数在线辨识相对简单,因此本文将基于 Thevenin 等效电路模型研究新能源汽车动力电池 SOC 估计方法。在温度变化环境下,动力电池内部参数会发生变化,相应的电池 SOC 也将发生变化。考虑温度变化影响,设计动态参数的 Thevenin 等效电路模型如图 1 所示。图 1 中, U_{oc} 为动力电池开路电压; R_o 为欧姆内阻; I 为电池电流; R_p 为极化内阻; C_p 为极化电容; U_p 为阻容回路两端电压; U_t 为动力电池端电压; R_o 主要表征动力电池正负电极、电解液、隔膜以及其余封装零件中固有的电阻,极化内阻 R_p 和极化电容 C_p 则用于表征动力电池在充放电过程中电化学反应时的活化极化和浓差极化效应。




图 1 动态参数的 Thevenin 等效电路模型

Fig. 1 Thevenin equivalent circuit model with dynamic parameters

根据基尔霍夫电压定律,动力电池的开路电压和电流为

$$\begin{cases} U_{oc} = R_o I + U_p + U_t \\ I = \frac{U_p}{R_p} + C_p \dot{U}_p \end{cases} \quad (1)$$

1.2 开路电压温度变化特性

电池 SOC 可表示为剩余电量占额定电量的比例,额定容量的单位一般为 $\text{mA} \cdot \text{h}$ 。采用电荷数作为评价标准,电池 SOC 可以表示为

$$\beta_{\text{soc}}(T, t) = \frac{Q_r(T, t)}{Q_r} \quad (2)$$

式中: $\beta_{\text{soc}}(T, t)$ 表示动力电池在 T 温度下 t 时刻的 SOC; $Q_r(T, t)$ 表示在 T 温度下 t 时刻储能介质中实际的电荷数; Q_r 表示额定容量在 $30\text{ }^\circ\text{C}$ 对应的电荷数。

动力电池的开路电压是指电池处于无电流的开路状态时正负电极间的电位差。常用的新能源汽车动力电池为锂电池,开路电压与 SOC 之间有着密切的关系,为了研究后续锂电池在温度变化条件下的荷电状态估计方法,需首先探究不同温度对锂电池开路电压的影响。本研究实验对象为新能源汽车的专用低温锂电池,具体参数如表 1 所示。

表 1 低温锂电池参数

Table 1 Specifications of low temperature lithium battery

电池参数	数值
额定容量/(mA · h)	2 376
标称电压/V	3.7
最大电压/V	4.2
截止电压/V	2.5

采用间隔静置法来获取恒温状态下锂电池的开路电压,环境温度为恒定 $30\text{ }^\circ\text{C}$ 时,锂电池开路电压测试结果如图 2 所示。当锂电池结束放电后,端电压开始缓慢回升,并在静置后期,端电压几乎保持不变。这表明放电过程中产生的电池极化效应在静置中基本消失,此时端电压可以代表电池的开路电压。




图 2 开路电压测试结果

Fig. 2 Tested result of open-circuit voltage

在不同温度下分别对动力电池进行开路电压测试,结果如图 3 所示。不同温度条件下,电池的开路电压均与电池 SOC 呈强相关性。并且当电池处于相同 SOC 状态时,不同温度条件下电池开路电压十分接近,最大误差处不超过 0.012 V ,因此最大偏差低于 0.3% 。这说明在温度变化环境下,开路电压与电池 SOC 的对应关系几乎不变。




图 3 不同温度下的开路电压

Fig. 3 Open-circuit voltage under various temperatures

将不同温度下电池 SOC 对应的开路电压取平均值,如表 2 所示。在相同的电池 SOC 下,将电池平均开路电压与不同温度下标定的电池开路电压进行比较,最大的误差为不超过标定电压的 0.2%。因此使用平均开路电压可以有效表征锂电池在温度变化环境下的开路电压-SOC 特性。

表 2 电池 SOC 和平均开路电压对应关系

Table 2 Relationship between battery SOC and average open-circuit voltage

β_{soc}	1	0.9	0.8	0.7	0.6	0.5
U_{oc}/V	4.18	4.068	3.967	3.886	3.804	3.695
β_{soc}	0.4	0.3	0.2	0.1	0	
U_{oc}/V	3.624	3.575	3.519	3.417	3.330	

为实现后续动力电池的状态估计,利用下式对表 2 中数据点进行拟合,结果如图 4 所示。

$$U_{oc} = b_0\beta_{soc}^9 + b_1\beta_{soc}^8 + b_2\beta_{soc}^7 + b_3\beta_{soc}^6 + b_4\beta_{soc}^5 + b_5\beta_{soc}^4 + b_6\beta_{soc}^3 + b_7\beta_{soc}^2 + b_8\beta_{soc} + b_9 \quad (3)$$

式中: b_i 为拟合系数, $i = 0, 1, \dots, 9$ 。




图 4 平均开路电压与电池 SOC 的对应关系

Fig. 4 Relationship between average open-circuit voltage with battery SOC

1.3 电池容量温度变化特性

电池容量是 SOC 估计的重要因素,但锂电池容

量并非恒定不变。电池容量与正负极材料的活性配比密切相关,且正负极材料的活性受温度影响显著^[23]。为了探究温度与动力电池有效容量变化之间的关系,本文在不同温度下对锂电池进行测试,先恒流恒压充电至最大电压,充分静置后再进行 1C 标准倍率放电,不同温度的有效容量如表 3 所示,对应的电池容量测试结果如图 5 所示。

表 3 不同温度电池容量测试结果

Table 3 Battery capacity test results at different temperatures

温度/℃	电池容量/(mA·h)	容量衰减率/%
40	2 370.2	0.25
30	2 376.1	0
20	2 276.6	4.15
15	2 233.3	6.01
10	2 193.7	7.68
5	2 154.9	9.31
0	2 114.6	11.01
-5	2 080.2	12.45
-10	1 969.1	17.13
-15	1 908.3	19.69




图 5 不同温度容量测试中电池 SOC 与时间对应关系

Fig. 5 The relationship between SOC and time in various temperature capacity tests

随着温度降低,动力电池的容量出现了明显衰减,这将使得电池更快放电至截止电压。当温度降低时,例如温度降低为-5℃时,传统的 SOC 估计方法在动力电池 SOC 低于 12% 时就不能继续放电。为了降低温度变化特别是低温条件对动力电池 SOC 估计偏差的影响,需增加温度因子修正电池 SOC。温度因子用 δ 表示,表达式如下

$$\delta(t) = \frac{\beta_{soc}(T, t)}{\beta_{soc}(30, t)} \quad (4)$$

为了准确反映温度因子与动力电池容量之间的关系,引入 BP 神经网络训练,温度因子的 BP 神经网络预测模型采用温度和 β_{soc} 作为输入量,将温度因子作为输出量。根据不同恒温状态下的电池容量衰减测试数据进行训练,得到了不同温度下的温度

因子,这些温度因子构成了 BP 神经网络的训练数据集。由于两层的隐藏层就可以拟合任何精度的平滑函数映射,本模型中选取两个隐藏层,每层节点数设计为 6,选用正切 S 型传递函数,学习率设定为 0.01,目标误差设定为 1×10^{-7} 。BP 神经网络训练得到的神经网络温度因子如图 6 所示,其取值范围在 0~1 之间,反映不同温度相对于 30 °C 的容量衰减。




图 6 神经网络温度因子训练结果

Fig. 6 Training results of the neural network temperature factor

2 模型动态参数辨识

锂电池内部参数受放电深度、温度等多因素影响,基于离线辨识参数的模型计算结果会产生累积误差,导致估计状态与实际状态之间逐渐偏离,最终导致显著的电池 SOC 估计误差。因此,必须在线修正模型参数,以确保在温度变化条件下的模型精度。本文采用带遗忘因子的递推最小二乘法对等效电路模型参数进行实时估计,引入遗忘因子可以有效削弱数据饱和对后续参数辨识的影响。基于带遗忘因子的最小二乘法的参数辨识流程如下。

将式(1)的状态空间方程通过拉氏变换得到

$$U_{oc}(s) - U_i(s) = I(s) \left(R_o + \frac{R_p}{1 + R_p C_p s} \right) \quad (5)$$

定义输出 $y(s) = U_{oc}(s) - U_i(s)$, 传递函数 $G(s)$ 为

$$G(s) = R_o + \frac{R_p}{1 + R_p C_p s} \quad (6)$$

对式(6)所示传递函数进行双线性变换,令 $s = \frac{2}{T_s} \frac{1 - z^{-1}}{1 + z^{-1}}$, 有

$$G(z^{-1}) = [T_s(R_o + R_p) + 2R_o R_p C_p] / [(T_s + 2R_p C_p) + (T_s - 2R_p C_p)z^{-1}] + [T_s(R_o + R_p) - 2R_o R_p C_p]z^{-1} / [(T_s + 2R_p C_p) + (T_s - 2R_p C_p)z^{-1}] \quad (7)$$

式中: T_s 为采样时间。

在 k 时刻,对式(7)进行差分离散化,得到

$$y(k) = U_{oc}(k) - U_i(k) = a_1 y(k) + a_2 I(k) + a_3 I(k-1) \quad (8)$$

式中, a_1 、 a_2 、 a_3 为待辨识参数,分别可表示为

$$a_1 = \frac{2R_p C_p - 1}{2R_p C_p + 1}, \quad a_2 = \frac{R_o + R_p + 2R_o R_p C_p}{2R_p C_p + 1}, \quad a_3 = \frac{R_o + R_p - 2R_o R_p C_p}{2R_p C_p + 1}.$$

式(8)可以表述为

$$y(k) = \mathbf{m}^T \boldsymbol{\theta} \quad (9)$$

式中,向量 $\mathbf{m} = [y(k-1) \quad I(k) \quad I(k-1)]^T$; $\boldsymbol{\theta}$ 为待辨识参数, $\boldsymbol{\theta} = [a_1 \quad a_2 \quad a_3]^T$ 。

针对待辨识参数 $\boldsymbol{\theta}$, 含遗忘因子的最小二乘递推公式为

$$\begin{cases} \mathbf{K}(k) = \frac{\mathbf{P}(k-1)\mathbf{m}(k-1)}{\lambda + \mathbf{m}^T(k)\mathbf{P}(k-1)\mathbf{m}(k)} \\ \mathbf{P}(k) = \frac{1}{\lambda} [\mathbf{P}(k-1) - \mathbf{K}(k)\mathbf{m}(k)\mathbf{P}(k-1)] \\ \hat{\boldsymbol{\theta}}(k) = \mathbf{K}(k)[y(k) - \mathbf{m}^T(k)\hat{\boldsymbol{\theta}}(k-1)] + \hat{\boldsymbol{\theta}}(k-1) \end{cases} \quad (10)$$

式中: $\mathbf{K}(k)$ 为 k 时刻的增益矩阵; $\mathbf{P}(k)$ 为 k 时刻的协方差矩阵; $\hat{\boldsymbol{\theta}}(k)$ 为 k 时刻辨识到的参数; λ 为遗忘因子,当 $\lambda=1$ 时,带遗忘因子的递推最小二乘法转变为传统递推最小二乘法。

基于式(10)中观测值 $\hat{\boldsymbol{\theta}}$, 可以推导出等效电路模型的参数如下

$$\begin{cases} R_o = (a_2 - a_3) / (1 + a_1) \\ R_p = \left(1 + \frac{1 + a_1}{1 - a_1}\right) a_2 - \frac{R_o(1 + a_1)}{1 - a_1} - R_o \\ C_p = (1 + a_1) / 2R_p(1 - a_1) \end{cases} \quad (11)$$

此时,通过动力电池的电流测试数据、开路电压与 SOC 之间的对应关系就可以完成温度变化条件下等效电路模型参数的在线估计,FFRLS 参数辨识流程如图 7 所示。




图 7 FFRLS 参数辨识流程图

Fig. 7 Flowchart of the FFRLS parameter identification

3 温度因子修正的 SOC 估计方法

利用 FFRLS 在线辨识等效电路模型参数后, 随时间更新的电池模型可以准确反映电池本身的电压-电流响应。在此基础上, 结合动力电池开路电压和电池容量温度变化特性的研究, 需进一步采用温度因子修正 SOC 估计结果。

在温度变化情况下, 由于额定电压的变化, 会使 SOC 估计误差过大。结合 BP 神经网络训练得到的温度因子, 考虑温度变化修正的 SOC 为

$$\beta_{\text{SOC}}(T, t) = \beta_{\text{SOC}}(T, 0) - \frac{\int_0^t \eta^i(t) dt}{\delta(t) Q_t} \quad (12)$$

式中: $\beta_{\text{SOC}}(T, t)$ 表示动力电池在 T 温度下 t 时刻的考虑温度变化修正的 SOC; η 是库伦效率; $i(t)$ 为 t 时刻电池的电流。

本文在 FFRLS 辨识参数基础上, 采用 UKF 估计电池 SOC。根据 Thevenin 等效电路模型, 系统的状态空间方程为

$$\begin{bmatrix} \dot{\beta}_{\text{SOC}} \\ \dot{U}_p \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 0 & -\frac{1}{R_p C_p} \end{bmatrix} \begin{bmatrix} \beta_{\text{SOC}} \\ U_p \end{bmatrix} + \begin{bmatrix} -\frac{1}{C_n} \\ \frac{1}{C_p} \end{bmatrix} I \quad (13)$$

系统的观测方程为

$$U_t = U_{oc} - R_o I - U_p \quad (14)$$

将式(13)和(14)进行拉氏逆变换, 并进行离散化, 得到

$$\begin{bmatrix} \beta_{\text{SOC}}^{k+1} \\ U_p^{k+1} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & e^{-T/R_p C_p} \end{bmatrix} \begin{bmatrix} \beta_{\text{SOC}}^k \\ U_p^k \end{bmatrix} + \begin{bmatrix} -T_k/C_n \\ R_p - R_p e^{-T_k/R_p C_p} \end{bmatrix} I_k + \mathbf{w} \quad (15)$$

$$U_t^{k+1} = \left[\frac{dU_{oc}}{d\beta_{\text{SOC}}} - 1 \right] \begin{bmatrix} \beta_{\text{SOC}}^k \\ U_{p,k} \end{bmatrix} - R_o I_k + \mathbf{v} \quad (16)$$

式中: T_k 为离散步长; $\mathbf{w}$ 为系统状态噪声; $\mathbf{v}$ 为系统观测噪声。

无迹卡尔曼滤波算法需要 5 个基本参数, 分别是系统的状态维数 n , 采样点的分布状态 α , 权系数 β , 待选参数 p 和缩放比例 q 。本文研究的电池模型系统状态维数为 2, 分布状态 $\alpha=0.01$, 权系数 $\beta=2$ 。待选参数 p 通常为 0。缩放比例 q 按下式计算

$$q = \alpha^2(n+p) - n \quad (17)$$

无迹卡尔曼滤波算法初始化, 需要获取 $2n+1$ 个不同的采样点构建 sigma 点集, 其中第一组 sigma 采样点可以表示为

$$\begin{cases} \mathbf{x}_{k|k-1}^0 = \mathbf{X}_{k-1} \\ \mathbf{x}_{k|k-1}^i = \mathbf{X}_{k-1} + (\sqrt{(n+p)\mathbf{P}_{k-1}})_i, \\ \quad i = 1, 2, \dots, n \\ \mathbf{x}_{k|k-1}^i = \mathbf{X}_{k-1} - (\sqrt{(n+p)\mathbf{P}_{k-1}})_i, \\ \quad i = n+1, n+2, \dots, 2n \end{cases} \quad (18)$$

式中: $\mathbf{X}_k$ 是系统状态变量, 即 $\mathbf{X}_k = [\beta_{\text{SOC}} \ U_p]^T$; $\mathbf{P}$ 为协方差矩阵, $(\sqrt{(n+p)\mathbf{P}_{k-1}})_i$ 为矩阵经过 Cholesky 分解得到矩阵的第 i 列。

系统采样点权重为

$$\begin{cases} w_m^0 = \frac{q}{n+q} \\ w_c^0 = \frac{q}{n+q} + 1 - \alpha^2 + \beta \\ w_m^i = w_c^i = \frac{q}{2(n+q)}, i = 1, 2, \dots, 2n \end{cases} \quad (19)$$

式中: w_m^0, w_c^i 分别为第 i 个 sigma 点的均值权重和协方差权重。无迹卡尔曼滤波算法初始化后, 便可通过系统的状态空间方程进行预测。根据初始的 sigma 点预测系统状态

$$\mathbf{X}_{k|k-1} = \sum_{i=0}^{2n} w_m^i \mathbf{X}_{k-1}^i \quad (20)$$

式中: $\mathbf{X}_{k|k-1}$ 表示通过 $k-1$ 步对第 k 步进行预测的系统状态; $\mathbf{X}_{k-1}^i$ 表示第 i 个 sigma 点的系统状态。

此时, 系统协方差矩阵预测为

$$\begin{aligned} \mathbf{P}_{k|k-1} = & \sum_{i=0}^{2n} [\mathbf{w}_c^i (\mathbf{X}_{k|k-1}^i - \mathbf{X}_{k|k-1}) \cdot \\ & (\mathbf{X}_{k|k-1}^i - \mathbf{X}_{k|k-1})^T] + \mathbf{V} \end{aligned} \quad (21)$$

式中, $\mathbf{V}$ 为过程噪声。

根据式(21)对 sigma 点进行更新

$$\begin{cases} \mathbf{x}_k^0 = \mathbf{X}_{k|k-1} \\ \mathbf{x}_k^i = \mathbf{X}_{k|k-1} + (\sqrt{(n+\lambda)\mathbf{P}_{k-1}})_i, \\ \quad i = 1, 2, \dots, n \\ \mathbf{x}_k^i = \mathbf{X}_{k|k-1} - (\sqrt{(n+\lambda)\mathbf{P}_{k-1}})_i, \\ \quad i = n+1, n+2, \dots, 2n \end{cases} \quad (22)$$

采用观测方程对 $\mathbf{X}_k$ 进行观测, 用 $\mathbf{U}_{k|k-1}^i$ 表示

$$\mathbf{U}_{k|k-1} = \sum_{i=0}^{2n} w_c^i \mathbf{U}_{k|k-1}^i \quad (23)$$

式中, $\mathbf{U}_{k|k-1}$ 表示通过第 $k-1$ 步对第 k 步进行预测的系统观测矩阵; $\mathbf{U}_{k-1}^i$ 表示第 i 个 sigma 点的系统观测矩阵。

第二组 sigma 点的协方差观测预测矩阵为

$$\begin{aligned} \mathbf{P}_{k|k-1}^v = & \sum_{i=0}^{2n} [\mathbf{w}_c^i (\mathbf{U}_{k|k-1}^i - \mathbf{U}_{k|k-1}) \cdot \\ & (\mathbf{U}_{k|k-1}^i - \mathbf{U}_{k|k-1})^T] + \mathbf{R} \end{aligned} \quad (24)$$

状态预测与观测预测互协方差矩阵为

$$\mathbf{P}_{k|k-1}^{vu} = \sum_{i=0}^{2n} w_i^v (\mathbf{X}_k^i - \mathbf{U}_{k|k-1}) (\mathbf{U}_{k|k-1}^i - \mathbf{U}_{k|k-1})^T \quad (25)$$

随后,对系统 Kalman 增益矩阵 $\mathbf{K}_k$ 、系统状态 $\mathbf{X}_k$ 、协方差矩阵 $\mathbf{P}_k$ 分别进行更新。

$$\mathbf{K}_k = \mathbf{P}_{k|k-1}^{vu} (\mathbf{P}_{k|k-1}^v)^{-1} \quad (26)$$

$$\mathbf{X}_k = \mathbf{X}_{k|k-1} + \mathbf{K}_k (\mathbf{U}_k - \mathbf{U}_{k|k-1}) \quad (27)$$

$$\mathbf{P}_k = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{P}_{k|k-1}^v \mathbf{K}_k^T \quad (28)$$

本文基于神经网络和无迹卡尔曼滤波修正的动力电池 SOC,考虑温度的影响,建立动态参数的戴维南等效电路模型,根据动力电池的容量、电压和电流测试数据,利用 BP 神经网络训练得到表征电池容量衰减的神经网络温度因子,采用 FFRLS 实时辨识电池模型的内部参数,对模型进行修正。在此基础上,利用神经网络温度因子和 UKF 实时修正以实现温度变化条件下的精确 SOC 估计,具体流程图如图 8 所示。




图 8 基于神经网络和无迹卡尔曼滤波修正的 SOC 估计

Fig. 8 Modified SOC estimation based on neural networks and unscented Kalman filter

4 结果分析

为了验证本文新能源汽车动力电池 SOC 估计方法的有效性和准确性,针对新能源汽车专用低温

锂电池进行测试,基于多个循环 UDDS 工况测试结果进行分析和验证。

图 9 是电池测试平台,该测试平台由 SW-100 温控箱、Neware 可编程直流充放电测试仪 BTS-4008、中位机以及上位机组成。BTS-4008 测试仪根据上位机编制的工况程序对锂电池进行加载和测试,并且通过电压和电流传感器获得电池的实时输出电压和工作电流。然后,利用 Neware BTS 中位机对采集到的数据进行处理,并将实时工作电压和电流数据传输到上位机。可编程温控箱用来模拟温度变化环境。





图 9 锂电池实验测试平台


Fig. 9 Experimental test platform for lithium batteries

在实际应用中,欧姆内阻 R_0 是评估电池荷电状态和健康状态的重要指标,尤其在快速充放电过程中欧姆内阻直接影响电池的发热和能量损耗^[31]。因此,不同温度下欧姆内阻 R_0 的变化对于动力电池状态评估、能量管理具有重要的指导意义。图 10 展示了温度变化条件下锂电池模型参数的 FFRLS 辨识结果。图 10(a) 为温度变化条件下 Thevenin 等效电路模型的欧姆内阻 R_0 。在循环 UDDS 工况下的辨识结果。可以看出,温度变化对欧姆内阻 R_0 产生的影响显著,在低温 -15°C 条件下的欧姆内阻几乎是 40°C 的 4 倍。随着温度降低,欧姆内阻将逐渐增加,动力电池工作内部的损耗将增加,这也是动力电池随着温度降低性能衰减的重要原因。

FFRLS 在温度变化时较好地实现了锂电池等效电路模型的在线参数辨识。图 10(b) 分别展示了传统的递推最小二乘法 (RLS) 和混合功率脉冲特性 (HPPC) 离线参数辨识结果。在电池 $\beta_{\text{soc}} < 0.4$ 时,RLS 由于数据过饱和,与离线辨识参数产生了较大的偏离。与之相比,FFRLS 通过引入遗忘因子,在低 SOC 状态下,仍可以精确地进行在线参数辨识,为后续温度变化环境下的电池 SOC 精确估计提供了有效保障。



(a)不同温度下电池欧姆内阻的变化




(b)不同方法的欧姆内阻辨识结果对比

图 10 UDSS 工况下 FFRLS 参数辨识结果


Fig. 10 Results of FFRLS parameter identification under UDSS conditions

FFRLS 实现了不同环境温度下模型参数的准确辨识,在此基础上,可进行不同环境温度下的锂电池的 SOC 估计。图 11 展示了 30℃和循环 UDSS 工况下基于 UKF 的端电压和电池 SOC 估计结果。可以看出,动力电池的端电压预测值与真实值高度吻

合,UDSS 循环工况下最大绝对误差仅为 0.002 3 V。进一步,如图 11(b)所示,考虑温度变化的电池 SOC 估计方法可以准确地实现在 30℃下动力电池的 SOC 估计,SOC 平均绝对误差仅为 0.83%,SOC 最大估计误差为 2.4%,将误差控制在合理范围内。



(a)端电压估计结果




(b)SOC 估计结果

图 11 30℃和循环 UDSS 工况下估计结果


Fig. 11 Estimation results in 30℃ and cyclic UDSS conditions

低温环境会严重影响动力电池的输出性能。通常,新能源汽车配置了电池加热系统或保温措施以应对低温环境。在新能源汽车启动运行后,动力电池电芯面临的外部环境温度一般不低于-5℃^[32-33]。并且,通过多次试验,本文研究的锂电池在-20℃条件下无法完成 UDSS 工况对应的高频和高功率充放电测试,相应的 BTS-4008 充放电测试仪将出现报错记录。因此,本研究以 30℃为参考对象,选取 40℃、20℃、15℃、10℃、5℃、0℃、-5℃、-10℃和-15℃进行温度变化条件下的电池 SOC


估计研究,结果如图 12 所示。图 12 中 SOC 估计误差为考虑温度变化前后利用 UKF 预测误差与参考 SOC 的差值。在循环 UDSS 工况下,随着温度降低,传统电池 SOC 估计方法不能修正温度变化引起的 SOC 估计误差,导致电池 SOC 估计偏差逐渐增大。与之相比,考虑温度变化的 SOC 估计方法利用神经网络训练的温度因子和 UKF 对电池 SOC 进行修正,在不同温度下仍可以保持较高的电池 SOC 估计精度,有效削减了温度变化对电池 SOC 估计精度的影响。




(a) 40 °C 未修正结果




(b) 40 °C 修正后结果




(c) 20 °C 未修正结果




(d) 20 °C 修正后结果




(e) 15 °C 未修正结果




(f) 15 °C 修正后结果




(g) 10 °C 未修正结果



(h) 10 °C 修正后结果



(i) 5 °C 未修正结果



(j) 5 °C 修正后结果




图 12 UDDS 工况下电池 SOC 修正前后对比结果

Fig. 12 Comparative results before and after SOC correction under UDDS conditions

为进一步比较考虑温度变化的电池 SOC 估计方法与传统电池 SOC 估计方法的优劣,本文引进了平均绝对值误差(MAE, 设为 R_{MAE})和均方根误差(RMSE, 设为 R_{MSE})进行评价,定义如下

$$R_{MAE} = \frac{1}{n} \sum_{i=1}^n |\beta_{SOC} - \beta_{iSOC}| \times 100\% \quad (29)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\beta_{SOC} - \beta_{iSOC})^2} \times 100\% \quad (30)$$

式中: β_{SOC} 为电池 SOC 的参考真实值。

计算不同温度条件下动力电池 SOC 估计结果的 MAE,结果如表 4 所示。通过对比,传统电池 SOC 估计方法的 MAE 随着温度下降显著上升,从 30℃的 0.83%增加到-15℃的 7.01%。考虑温度变化修正后,电池 SOC 估计的 MAE 均显著降低,尤其是在低温环境下,电池 SOC 估计的 MAE 降低更为显著。在 40℃、20℃、15℃、10℃、5℃、0℃、-5℃、-10℃和-15℃条件下,电池 SOC 估计的平均绝对误差将分别削减 0.03%、0.56%、0.78%、1.01%、1.27%、1.64%、2.04%、2.75%和 2.77%。同时,随着温度下降,传统电池 SOC 估计方法的均方根误差也同样显著下降,在-15℃下 SOC 估计的均方根误差已经到达 6.10%,这表明估计过程中的波动性也显著增加,已经无法满足新能源汽车正常运行。而考虑温度变化修正后电池 SOC 估计的均方根误差,在各个温度下都产生了明显降低。这表明本文提出的方法在温度变化环境下对于提高电池 SOC 估计精度具有显著效果。在新能源汽车动力电池应用领域,考虑温度变化修正电池 SOC,对提升电池 SOC 监测的准确性和保证电池管理系统的可靠性具有重要意义。

表 4 不同温度 SOC 估计结果

Table 4 SOC estimation results at various temperatures					
温度/ ℃	$R_{MAE}/\%$		R_{MAE} 削减量/%	$R_{MSE}/\%$	
	传统	本文		传统	本文
40	0.90	0.87	0.03	1.09	1.02
30	0.83	0.83	0	1.02	0
20	1.34	0.78	0.56	1.72	1.38
15	1.61	0.83	0.78	1.95	1.29
10	2.12	1.11	1.01	2.78	2.01
5	2.94	1.67	1.27	2.99	1.77
0	3.98	2.34	1.64	3.83	2.36
-5	5.32	3.28	2.04	4.71	2.83
-10	6.61	3.86	2.75	5.78	3.93
-15	7.01	4.23	2.77	6.10	4.81

5 结 论

本文研究了考虑温度变化的新能源汽车动力电池 SOC 估计方法。在建立动态参数的 Thevenin 等效电路模型基础上,研究了电池开路电压的温度变化特性,并确定了电池开路电压与 SOC 之间的对应关系。同时,研究了电池容量的温度变化特性,采用 BP 神经网络训练得到容量随温度变化的神经网络

温度因子。进一步,在 FFRLS 实时辨识模型参数的基础上,采用神经网络温度因子和 UKF 实时修正电池 SOC。最终,实现了温度变化环境下新能源汽车动力电池 SOC 的精确估计,主要结论如下。

(1)通过 BP 神经网络训练得到容量随温度变化的神经网络温度因子,并引入该神经网络温度因子修正动力电池的容量,降低了温度变化对 SOC 估计精度的影响。

(2)采用 FFRLS 实现模型参数在线辨识,带遗忘因子的最小二乘法避免了传统最小二乘法的数据过饱和问题,实现了不同温度环境下模型参数的实时动态更新。

(3)在 FFRLS 实时辨识动力电池内部参数的基础上,结合神经网络温度因子,利用 UKF 对电池 SOC 进行修正,有效提高了温度变化环境下动力电池 SOC 的估计精度。

(4)在循环 UDDS 工况下进行了实验和仿真对比验证。结果表明:考虑温度变化的电池 SOC 估计方法在不同温度条件下能有效降低估计值的平均绝对误差。相比于传统的电池 SOC 估计方法,本文所提出的方法可显著提高 SOC 估计精度,在-15℃低温环境下,本文方法使 SOC 估计精度提高了 2.77%。

参考文献:

[1] ZHANG Fuming, OBEID E, BOU NADER W, et al. Well-to-wheel analysis of natural gas fuel for hybrid truck applications [J]. Energy Conversion and Management, 2021, 240: 114271.

[2] WANG Qun, ZHANG Ruixin, LÜ Shuaikang, et al. Open-pit mine truck fuel consumption pattern and application based on multi-dimensional features and XGBoost [J]. Sustainable Energy Technologies and Assessments, 2021, 43: 100977.

[3] 续丹, 毛景禄, 王斌, 等. 分布式电池电源模块储能系统的荷电状态均衡控制 [J]. 西安交通大学学报, 2019, 53(10): 79-85.

XU Dan, MAO Jinglu, WANG Bin, et al. A balance control scheme of SOC for power module energy storage systems with distributed batteries [J]. Journal of Xi'an Jiaotong University, 2019, 53(10): 79-85.

[4] WANG Yujie, ZHANG Xingchen, CHEN Zonghai. Low temperature preheating techniques for Lithium-ion batteries; recent advances and future challenges [J]. Applied Energy, 2022, 313: 118832.

[5] 周维, 刘鸿远, 徐彪, 等. 功率分流式混合动力矿用自卸车预测性等效燃油消耗最小控制策略研究 [J].

- 机械工程学报, 2021, 57(2): 200-209.
- ZHOU Wei, LIU Hongyuan, XU Biao, et al. Predictive equivalent consumption minimization strategy for power split hybrid electric mining truck [J]. Journal of Mechanical Engineering, 2021, 57(2): 200-209.
- [6] SUDARSHAN M, SEROV A, JONES C, et al. Data-driven autoencoder neural network for onboard BMS lithium-ion battery degradation prediction [J]. Journal of Energy Storage, 2024, 82: 110575.
- [7] CUI Zhenhua, KANG Le, LI Liwei, et al. A combined state-of-charge estimation method for lithium-ion battery using an improved BGRU network and UKF [J]. Energy, 2022, 259: 124933.
- [8] 王子毅, 朱承治, 周杨林, 等. 基于动态可重构电池网络的 OCV-SOC 在线估计 [J]. 中国电机工程学报, 2022, 42(8): 2919-2928.
- WANG Ziyi, ZHU Chengzhi, ZHOU Yanglin, et al. OCV-SOC estimation based on dynamic reconfigurable battery network [J]. Proceedings of the CSEE, 2022, 42(8): 2919-2928.
- [9] BIAN Xiaolei, WEI Zhongbao, LI Weihang, et al. State-of-health estimation of lithium-ion batteries by fusing an open circuit voltage model and incremental capacity analysis [J]. IEEE Transactions on Power Electronics, 2022, 37(2): 2226-2236.
- [10] XU Liqianun, WU Feng, CHEN Renjie, et al. Data-driven-aided strategies in battery lifecycle management: prediction, monitoring, and optimization [J]. Energy Storage Materials, 2023, 59: 102785.
- [11] 贞祥, 张鑫, 王超, 等. 基于联合参数辨识的粒子群优化扩展粒子滤波的锂电池荷电状态估计 [J]. 电工技术学报, 2024, 39(2): 595-606.
- YUN Xiang, ZHANG Xin, WANG Chao, et al. State of charge estimation of li-ion battery using particle swarm optimization extended Kalman particle filter based on joint parameter identification [J]. Transactions of China Electrotechnical Society, 2024, 39(2): 595-606.
- [12] AHMADZADEH O, WANG Yan, SOUDBAKHSH D. A data-driven framework for learning governing equations of li-ion batteries and co-estimating voltage and state-of-charge [J]. Journal of Energy Storage, 2024, 84(Part A): 110743.
- [13] SANTONI F, DE ANGELIS A, MOSCHITTA A, et al. A guide to equivalent circuit fitting for impedance analysis and battery state estimation [J]. Journal of Energy Storage, 2024, 82: 110389.
- [14] SAH B, KUMAR P. Charger integrated coestimation of parameters and states of battery [J]. IEEE Transactions on Power Electronics, 2023, 38(7): 7923-7932.
- [15] 戈斌, 罗阳, 李家玮, 等. 风光互补式电动汽车充电站储能锂电池的实时状态估计 [J]. 西安交通大学学报, 2023, 57(1): 55-65.
- GE Bin, LUO Yang, LI Jiawei, et al. Real-time state estimation of lithium batteries used for energy storage in electric vehicle charging stations with wind-solar complementary power system [J]. Journal of Xi'an Jiaotong University, 2023, 57(1): 55-65.
- [16] BELTRAN H, AYUSO P, VICENTE N, et al. Equivalent circuit definition and calendar aging analysis of commercial $\text{Li}(\text{Ni}_x\text{Mn}_y\text{Co}_z)\text{O}_2/\text{graphite}$ pouch cells [J]. Journal of Energy Storage, 2022, 52 (Part A): 104747.
- [17] SAQLI K, BOUCHAREB H, M'SIRDI N K, et al. Lithium-ion battery electro-thermal modelling and internal states co-estimation for electric vehicles [J]. Journal of Energy Storage, 2023, 63: 107072.
- [18] XU Xiaodong, TANG Shengjin, REN Huahua, et al. Joint state estimation of lithium-ion batteries combining improved equivalent circuit model with electrochemical mechanism and diffusion process [J]. Journal of Energy Storage, 2022, 56(Part B): 106135.
- [19] 孙金磊, 邹鑫, 顾浩天, 等. 基于 FFRLS-EKF 联合算法的锂离子电池荷电状态估计方法 [J]. 汽车工程, 2022, 44(4): 505-513.
- SUN Jinlei, ZOU Xin, GU Haotian, et al. State of charge estimation for lithium-ion battery based on FFRLS-EKF joint algorithm [J]. Automotive Engineering, 2022, 44(4): 505-513.
- [20] YU Quanqing, NIE Yuwei, LIU Shizhuo, et al. State of health estimation method for lithium-ion batteries based on multiple dynamic operating conditions [J]. Journal of Power Sources, 2023, 582: 233541.
- [21] XIA Lili, WANG Shunli, YU Chunmei, et al. Joint estimation of the state-of-energy and state-of-charge of lithium-ion batteries under a wide temperature range based on the fusion modeling and online parameter prediction [J]. Journal of Energy Storage, 2022, 52(Part C): 105010.
- [22] 余杰, 廖思阳, 徐箭, 等. 考虑环境温度的磷酸铁锂电池 SOC 实时修正及频率控制方法 [J]. 电工技术学报, 2023, 38(17): 4564-4573.
- YU Jie, LIAO Siyang, XU Jian, et al. Real-time SOC correction and frequency control method for LFP batteries considering ambient temperature [J]. Transac-

- tions of China Electrotechnical Society, 2023, 38(17): 4564-4573.
- [23] ZHANG Nan, DENG Tao, ZHANG Shuoqing, et al. Critical review on low-temperature li-ion/metal batteries [J]. *Advanced Materials*, 2022, 34(15): 2107899.
- [24] ZHANG Wei, LI Yuqing, ZHENG Caigui, et al. Surface urban heat island effect and its driving factors for all the cities in China: based on a new batch processing method [J]. *Ecological Indicators*, 2023, 146: 109818.
- [25] LIANG Huiwen, YANG Yun, HUI S Y R. Improvement of lithium-ion battery charging from the state-of-the-art industrial JEITA guidelines to a hybrid temperature-regulated current control [J]. *IEEE Transactions on Power Electronics*, 2022, 37(6): 6412-6423.
- [26] 申江卫, 高承志, 舒星, 等. 基于迁移模型的锂离子电池宽温度全寿命 SOC 与可用容量联合估计 [J]. *电工技术学报*, 2023, 38(11): 3052-3063.
- SHEN Jiangwei, GAO Chengzhi, SHU Xing, et al. Joint estimation of SOC and usable capacity of lithium-ion battery with wide temperature and full life based on migration model [J]. *Transactions of China Electrotechnical Society*, 2023, 38(11): 3052-3063.
- [27] FENG Fei, TENG Sangli, LIU Kailong, et al. Co-estimation of lithium-ion battery state of charge and state of temperature based on a hybrid electrochemical-thermal-neural-network model [J]. *Journal of Power Sources*, 2020, 455: 227935.
- [28] LIN Jiayuan, LIU Xinhua, LI Shen, et al. A review on recent progress, challenges and perspective of battery thermal management system [J]. *International Journal of Heat and Mass Transfer*, 2021, 167: 120834.
- [29] MOULIK B, DUBEY A K, ALI A M. A battery modeling technique based on fusion of hybrid and adaptive algorithms for real-time applications in pure EVs [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(3): 2760-2771.
- [30] ZHANG Feng, ZHI Hui, ZHOU Puzhe, et al. State of charge estimation of li-ion battery for underwater vehicles based on EKF-RELM under temperature-varying conditions [J]. *Applied Ocean Research*, 2021, 114: 102802.
- [31] YANG Haixu, HONG Jichao, LIANG Fengwei, et al. Machine learning-based state of health prediction for battery systems in real-world electric vehicles [J]. *Journal of Energy Storage*, 2023, 66: 107426.
- [32] 陈泽宇, 熊瑞, 李世杰, 等. 电动载运工具锂离子电池低温极速加热方法研究 [J]. *机械工程学报*, 2021, 57(4): 113-120.
- CHEN Zeyu, XIONG Rui, LI Shijie, et al. Extremely fast heating method of the lithium-ion battery at cold climate for electric vehicle [J]. *Journal of Mechanical Engineering*, 2021, 57(4): 113-120.
- [33] ZHANG Chuanwei, HUANG Jing, SUN Weixin, et al. Research on liquid preheating performance for battery thermal management of electric vehicles at low temperature [J]. *Journal of Energy Storage*, 2022, 55 (Part B): 105497.

(编辑 武红江 陶晴)