

带状态检测机制的ELM-UKF算法估计锂电池SOC策略*

谈发明 赵俊杰

(江苏理工学院,常州 213001)

【摘要】为解决无迹卡尔曼滤波(UKF)算法对锂电池荷电状态(SOC)估计精度不高的问题,结合极限学习机(ELM)与UKF间的互补优势,提出了一种带状态检测机制的ELM-UKF组合算法估计锂电池SOC。首先,算法利用UKF估计电池SOC的相关滤波数据作为样本集训练ELM模型,将训练成功的ELM模型用于在线补偿UKF的SOC估计误差,进而实现估计偏差的实时修正;其次,算法针对ELM模型预测输出设计了状态检测机制,以此减小ELM模型预测输出过拟合对SOC估计波形平滑度的影响。试验结果表明,相较于单一类型的算法,所提出的组合算法具有良好的鲁棒性和泛化性,能有效提升锂电池SOC的估计效果。

关键词: 荷电状态 无迹卡尔曼滤波 极限学习机 状态检测 精度

中图分类号: TM912 **文献标志码:** A **DOI:** 10.19620/j.cnki.1000-3703.20240516

Strategy for Estimation of Lithium-Battery SOC by ELM-UKF Algorithm with State Detection Mechanism

Tan Faming, Zhao Junjie

(Jiang Su University of Technology, Changzhou 213001)

【Abstract】To address the issue of low accuracy in estimating the State of Charge (SOC) of lithium batteries using the Unscented Kalman Filter (UKF) algorithm, a combined ELM-UKF algorithm with a state detection mechanism is proposed, leveraging the complementary advantages of Extreme Learning Machine (ELM) and UKF for estimating the SOC of lithium batteries. Firstly, the algorithm uses the relevant filtering data estimated by UKF for battery SOC as a sample set to train the ELM model. The successfully trained ELM model is then used to online compensate for the SOC estimation error of UKF, thereby achieving real-time correction of estimation deviations. Secondly, the algorithm designs a state detection mechanism for the predictive output of the ELM model to reduce the impact of overfitting in the ELM model's predictive output on the smoothness of the SOC estimation waveform. Experimental results show that, compared to single-type algorithms, the proposed combined algorithm exhibits good robustness and generalization, effectively enhancing the estimation performance of lithium battery SOC.

Key words: State of Charge (SOC), Unscented Kalman Filter (UKF), Extreme Learning Machine (ELM), State detection, Precision

【引用格式】谈发明,赵俊杰.带状态检测机制的ELM-UKF算法估计锂电池SOC策略[J].汽车技术,2025(2):46-54.

TAN F M, ZHAO J J. Strategy for Estimation of Lithium-Battery SOC by ELM-UKF Algorithm with State Detection Mechanism[J]. Automobile Technology, 2025(2): 46-54.

1 前言

估计锂电池荷电状态(State of Charge, SOC)是电池管理系统的核心功能之一。鉴于电池内部的复杂化学反应呈现出强非线性特征,因此SOC无法直接测量,只能通

过电池的电压、电流及温度等可测量参数来间接估计^[1]。

目前,基于状态模型的无迹卡尔曼滤波(Unscented Kalman Filter, UKF)算法估计锂电池SOC技术受到众多学者关注^[2]。由于UKF能够以二阶以上的精度近似高斯非线性系统状态的后验均值与方差,所以其非线性分

*基金项目:国家自然科学基金青年科学基金项目(61803186);江苏省工程师学会重点研究课题(JSIE2024ZD06)。

通信作者:谈发明(1981—),男,高级工程师,主要研究方向为电子设备的分析与控制,tfm@jsut.edu.cn。

布统计量的精度较高^[3],适用于锂电池的非线性动态模型,在SOC估计的收敛速度、估计精度及鲁棒性方面表现较好^[4];文献[5]通过实时修正电池模型的状态和测量噪声协方差对UKF进行改进,将估计ICR18650-22FM锂电池SOC的均方根误差由1.52%降至0.33%,但改进后精度受电池模型和非高斯噪声的影响仍较大,易出现滤波不收敛的情况,泛化能力有待提升^[6-7];为了取得更高精度,基于神经网络的智能算法估计锂电池SOC,在训练成功的神经网络模型中输入电池的可测参数,可以直接预测SOC,该方法操作方便且适用于各种锂电池^[8-10]。其中,极限学习机(Extreme Learning Machine, ELM)基于结构风险最优原则,具有不易陷入局部最优、结构简单、参数易整定、学习时间短等优点,文献[11]采用优化算法自适应寻优ELM模型参数,将预测10 A·h锰酸钾锂电池SOC的平均绝对误差由7.8%降至1.1%,但基于ELM模型预测精度仍受限于训练方法和样本数量^[12-13];针对以上两种技术存在的缺陷,神经网络和卡尔曼滤波(Kalman Filter, KF)相结合估计SOC的算法成为新的研究方向^[14-17],利用神经网络的自学和逼近能力,优化补偿KF算法的SOC估计误差,同时降低对电池模型的精度要求^[18-21],文献[19]利用训练成功的BP神经网络模型对UKF的SOC估计误差进行补偿,将估计NCR18650BD锂电池SOC的最大误差由7.46%降至2.18%。但此方法在神经网络预测过拟合输出时,不仅无法起到误差补偿目的,反而可能引起SOC估计结果波动剧烈,严重时会导致KF算法滤波发散。

综上所述,针对INR18650-20R锂电池,本文以非线性动态Nernst模型为基础,设计带状态检测机制的ELM-UKF组合算法估计锂电池SOC,该算法能降低电池模型参数变化、非高斯噪声干扰等不确定因素对SOC估计精度的影响,同时避免ELM模型预测输出过拟合造成的SOC估计结果波动剧烈。

2 电池建模及参数辨识

考虑到锂电池工作时呈现的非线性特征,选用非线性动态Nernst模型,该模型能较好地描述电池系统的复杂性,具有阶数低、结构简单、易工程实现等优点^[22],同时也便于电池的特性分析及参数辨识。结合安时积分法,建立离散化的电池非线性动态Nernst模型如下:

状态方程:

$$x_k = x_{k-1} - \eta i_k \Delta t / C + w_k \quad (1)$$

式中: x_k 为 k 时刻SOC状态值; i_k 为 k 时刻电池的工作电流; η 为充电效率; C 为电池额定容量; Δt 为采样周期; w_k

为状态噪声,是满足正态分布的高斯白噪声。

测量方程为:

$$y_k = E_o - R_1 i_k + k_1 \ln(x_k) + k_2 \ln(1 - x_k) + v_k \quad (2)$$

式中: y_k 为 k 时刻电池的端电压; E_o 为电池开路电压; R_1 为电池欧姆内阻; k_1 、 k_2 为拟合系数; v_k 为测量噪声,是满足正态分布的高斯白噪声。

利用递推最小二乘法辨识Nernst模型中测量方程的 E_o 、 R_1 、 k_1 及 k_2 4个参数,此方法要求输入电流 i_k 为持续激励^[23],具体辨识步骤为:

步骤一:定义数据向量 $\Phi_k = [1, i_k, \ln(x_k), \ln(1 - x_k)]$;待估向量 $\hat{\theta}_k = [E_o, R_1, k_1, k_2]$;最小二乘形式表示为 $y_k = \Phi_k^T \theta_k + \varphi_k$,其中, φ_k 为误差函数。

步骤二:设定待估向量 $\hat{\theta}_k$ 的初值 $\hat{\theta}_0$ 以及协方差矩阵 G_k 的初值 G_0 。其中, $\hat{\theta}_0$ 可根据先验知识来赋值,但对于Nernst模型而言,存在正负及大小无法预知的拟合系数 k_1 及 k_2 ,因此, $\hat{\theta}_0$ 中各参数可以设为0或者极小的数值; $G_0 = \sigma^2 I$, I 为4阶单位矩阵,改变标量 σ 的大小可以调整辨识参数的收敛速度, σ 通常取较大数量级的数值^[24]。

步骤三:利用递推公式迭代求解最优 $\hat{\theta}_k$,直至达到最大迭代次数:

$$\begin{cases} \hat{\theta}_k = \hat{\theta}_{k-1} L_k [U_{L,k} - \Phi_k^T \hat{\theta}_{k-1}] \\ L_k = G_{k-1} \Phi_k^T [\Phi_k^T G_{k-1} \Phi_k + 1]^{-1} \\ G_k = G_{k-1} - \Phi_k^T \Phi_k G_{k-1} \end{cases} \quad (3)$$

式中: L_k 为增益矩阵。

3 ELM-UKF算法估计锂电池SOC

3.1 UKF算法估计SOC

将式(1)、式(2)建立的电池非线性动态Nernst模型描述为:

$$\begin{cases} f(x_{k-1}, i_k) = x_{k-1} - \eta i_k \Delta t / C \\ g(x_k, i_k) = E_o - R_1 i_k + k_1 \ln(x_k) + k_2 \ln(1 - x_k) \\ x_k = f(x_{k-1}, i_k) + w_k \\ y_k = g(x_k, i_k) + v_k \end{cases} \quad (4)$$

UKF主要利用非线性无迹变换迭代和更新式(4)所示模型的状态和测量协方差。首先构造出的一组Sigma点,以非线性映射方式传递状态量的统计特性,再通过加权统计线性回归法估计状态量的均值和协方差,进一步迭代便可得到状态估计^[3]。UKF估计SOC的具体步骤如下:

a. 初始化:

$$\begin{cases} \hat{x}_0 = E[x_0] \\ P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T] \end{cases} \quad (5)$$

式中: \hat{x} 为状态初值, P_0 为状态协方差初值。

b. 依据状态后验均值 \hat{x}_{k-1} 和协方差 P_{k-1} 计算出 $(2n+1)$ 个 Sigma 点 $\chi_{k-1,j} (j=0,1,2,\dots,2n)$ 及相应权值 κ_j :

$$\begin{cases} x_{k-1,j} = \hat{x}_{k-1}, & j = 0 \\ x_{k-1,j} = \hat{x}_{k-1} + \sqrt{n+\lambda} (\sqrt{P_{k-1}}), & j = 1,2,\dots,n \\ x_{k-1,j} = \hat{x}_{k-1} - \sqrt{n+\lambda} (\sqrt{P_{k-1}}), & j = n+1,\dots,2n \end{cases} \quad (6)$$

$$\begin{cases} \kappa_0^m = \lambda/(n+\lambda) \\ \kappa_0^c = \kappa_0^m + (1-\alpha^2 + \psi) \\ \kappa_i^c = \kappa_i^m = 1/[2(n+\lambda)] \end{cases}$$

式中: n 为状态向量维数; κ^m 为权值均值, κ^c 为权值协方差; ψ 为调节权值协方差估计精度的参数, 通常取 $\psi=2$; $\alpha (0 \leq \alpha \leq 1)$ 为点集到均值点的距离; $\lambda = \alpha^2(n+\varepsilon) - n$ 为尺度调节因子; ε 为次级尺度调节因子; 根据经验值, 取 $\alpha = 0.01, \varepsilon = 0$ 。

c. 时间更新: 各 Sigma 点通过状态方程传递, 计算出状态均值 $\hat{x}_{k/k-1}$ 和协方差 $P_{k/k-1}$:

$$\begin{cases} \chi_{k,j} = f(\chi_{k-1,j}, i_k), & j = 0,1,2,\dots,2n \\ \hat{x}_{k/k-1} = \sum_{j=0}^{2n} \kappa_j^m \chi_{k,j} \\ P_{k/k-1} = \sum_{j=0}^{2n} \kappa_j^c (\chi_{k,j} - \hat{x}_{k/k-1})(\chi_{k,j} - \hat{x}_{k/k-1})^T + Q \end{cases} \quad (7)$$

式中: Q 为系统状态噪声协方差。

d. 测量更新: 各 Sigma 点通过测量方程传递, 计算出测量均值 \hat{y}_k 、测量协方差 $P_{yy,k}$ 以及状态和测量互协方差 $P_{xy,k}$:

$$\begin{cases} y_{j,k} = g(\chi_{k,j}, i_k), & j = 0,1,2,\dots,2n \\ \hat{y}_k = \sum_{j=0}^{2n} \kappa_j^m y_{j,k} \\ P_{xy,k} = \sum_{j=0}^{2n} \kappa_j^c (\chi_{k,j} - \hat{x}_{k/k-1})(y_{j,k} - \hat{y}_k)^T \\ P_{yy,k} = \sum_{j=0}^{2n} \kappa_j^c (y_{j,k} - \hat{y}_k)(y_{j,k} - \hat{y}_k)^T + R \end{cases} \quad (8)$$

式中: R 为测量噪声协方差。

e. 计算卡尔曼增益 K_k , 并更新状态后验均值 \hat{x}_k 和协方差 P_k :

$$\begin{cases} K_k = P_{xy,k} P_{yy,k}^{-1} \\ \hat{x}_k = \hat{x}_{k/k-1} + K_k e_k \\ P_k = P_{k/k-1} - K_k P_{yy,k} K_k^T \end{cases} \quad (9)$$

式中: $e_k = y_k - \hat{y}_k$ 为测量残差信息。

针对锂电池的非线性系统, 相较于其他类型 KF 算法, UKF 估计 SOC 的性能优势较为明显, 但经验法设定的固定噪声方差初值难以适应运行工况的变化, SOC 估计效果受到电池模型参数变化、非高斯噪声干扰等不确定因素的影响仍会较大^[4]。

3.2 利用 ELM 改进 UKF

ELM 是一种单隐层前馈神经网络的新型算法, 具

备强劲的学习和复杂映射能力, 在回归预测方面性能优异^[25]。利用 ELM 对 UKF 进行改进, 可充分发挥出 ELM 和 UKF 两种算法之间的互补优势, 弥补单一 UKF 估计锂电池 SOC 存在的缺陷, 降低对电池模型精度的依赖, 减小不规则噪声干扰的影响, 达到提升 SOC 估计精度的目的。具体实现步骤如下:

步骤一: 建立起三输入一输出的回归型 ELM 模型, 收集 UKF 估计 SOC 过程中的 N 组相关滤波数据, 考虑电池非线性和时变的系统特点, 在 UKF 众多类型的滤波数据中, 应选择具有代表性且能够直接影响 SOC 估计效果的关键类型数据, 以此作为 ELM 模型离线训练及测试使用的样本集。定义样本集为 $\{(s_k, z_k)\}_{k=1,2,\dots,N}$, 其中, $s_k = [s_{k1}, s_{k2}, s_{k3}]$ 为模型输入数据, s_{k1} 对应测量残差新息 v_k , s_{k2} 对应卡尔曼增益 K_k , s_{k3} 对应状态后验均值 \hat{x}_k ; z_k 为模型输出数据, 对应 UKF 的 SOC 估计误差 $(x_k - \hat{x}_k)$ 。

步骤二: 使用线性归一的方法将样本集中的数据处理为均值为 0、均方差为 1 的标准数据, 消除各变量间由于量纲不同而带来的影响, 使数据在不同尺度下具有可比性, 增强 ELM 模型的鲁棒性和泛化性。

步骤三: 构建的预测 SOC 估计误差的 ELM 模型如图 1 所示, 利用样本集中的数据对模型进行离线训练, 求解出 ELM 模型的隐层节点输出权值矩阵, 定义 ELM 模型隐层节点数量为 1, 各隐层节点通过 Sigmoid 激活函数特征映射^[8]。




图1 预测SOC估计误差的ELM模型

ELM模型的输出为:

$$\sum_{i=1}^l \beta_i \text{sig}(\omega_i s_k + b_i) = z_k, \quad k = 1, \dots, N \quad (10)$$

式中: $\omega_i = [\omega_{i1}, \omega_{i2}, \omega_{i3}]^T$ 为连接输入节点和第 i 个隐含层节点之间的权值, b_i 为第 i 个隐层节点偏移量, β_i 为第 i 个隐层节点输出权值。

将式(10)以矩阵形式表示为:

$$H\beta = Z \quad (11)$$

式中: Z 为期望输出矩阵, β 为输出权值矩阵, H 为隐含层输出矩阵。

$$H = \begin{bmatrix} sig(\omega_1 s_1 + b_1) & \cdots & sig(\omega_l s_1 + b_l) \\ \vdots & & \vdots \\ sig(\omega_1 s_N + b_1) & \cdots & sig(\omega_l s_N + b_l) \end{bmatrix}_{N \times l} \quad (12)$$

在ELM中,若权值 ω_i 和偏置 b_i 被随机确定,则矩阵 H 也会被唯一确定。对式(11)中 H 求逆,将训练单隐层神经网络转化为求解式(13)所示的线性系统,接着可计算出范数最小且唯一的解 β 。至此,已构建完成所需的ELM模型。

$$\beta = H^+ Z \quad (13)$$

式中: H^+ 为矩阵 H 的Moore-Penrose广义逆。

步骤四:利用训练成功的ELM模型辅助UKF实时在线估计电池SOC。

在SOC估计过程中,将UKF当前时刻滤波数据 v_k 、 K_k 、 \hat{x}_k 输入到训练成功的ELM模型中,ELM模型预测输出当前时刻的SOC估计误差 z_k ,再利用 z_k 与UKF的状态后验均值 \hat{x}_k 进行求和,便可得到ELM融合UKF算法的最优SOC估计值 $\hat{x}_k = \hat{x}_k + z_k$,并将此值作为下一时刻的状态值继续进行迭代。

3.3 引入状态检测机制

锂电池的实际运行工况复杂,会受温度、干扰噪声、放电倍率、自放电以及老化等^[1]因素影响。因此,无法全面获取UKF滤波数据用于ELM模型的训练,即ELM模型存在训练数据量不足的情况。

在ELM模型辅助UKF估计SOC的过程中,由于ELM模型训练数据量的不足,极易出现ELM模型当前输入数据与训练集的分布不一致,进而产生预测输出过拟合,可能导致SOC估计结果波动剧烈,严重时甚至会出现滤波发散。鉴于此,提出了ELM模型预测输出状态检测机制:

$$\gamma_k = \begin{cases} z_k, & z_k < \zeta \\ 0, & (z_k > \zeta, k = 1) \\ \gamma_{k-1}, & (z_k > \zeta, k > 1) \end{cases} \quad (14)$$

式中: ζ 为检测阈值, γ_k 为 k 时刻的误差补偿值。

在此机制中,利用ELM模型预测输出 z_k 与 ζ 进行数值比较,判断是否出现过拟合,根据判断结果及当前所处的时刻取不同的 γ_k ,以此在线补偿UKF。此时,引入状态检测机制后的ELM融合UKF算法的最优SOC估计值 \hat{x}_k 修正为 $\hat{x}_k = \hat{x}_k + \gamma_k$, \hat{x}_k 。较未引入状态检测机制的波动幅度有所减小,算法的实现流程如图2所示。

在图2所描述算法的核心部分,引入状态检测机制后,当ELM模型预测输出 z_k 小于 ζ 时,误差补偿值 γ_k 可直接采用 z_k ;当 z_k 大于 ζ 时,则判定 z_k 为过拟合输

出,继续判断当前是否处于SOC估计起始时刻,若是,则过拟合是由SOC状态初值与实际初值之间较大误差所造成,此时 γ_k 取0,ELM模型不参与在线补偿UKF,直至 z_k 小于 ζ ;若否,则表明过拟合发生在SOC估计过程中,是由于ELM模型输入数据与训练测试集分布不一致所造成,则 γ_k 仍沿用前一时刻的误差补偿值 γ_{k-1} 。

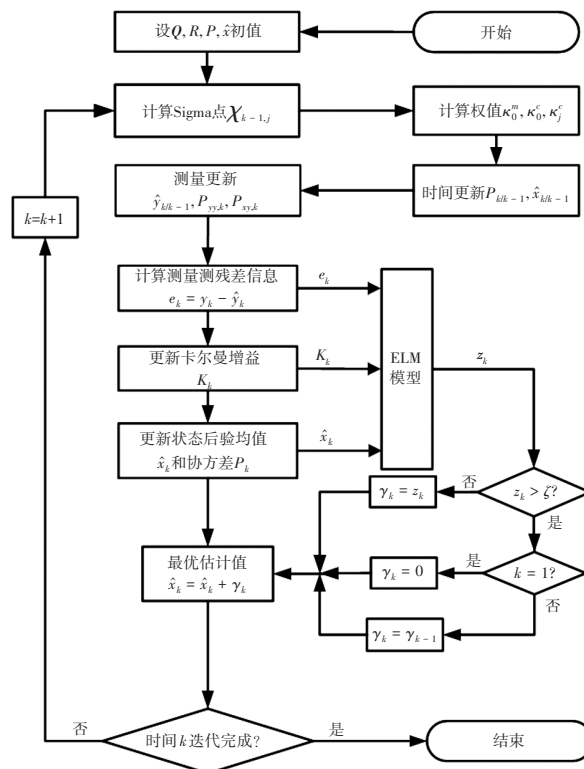


图2 带状态检测机制的ELM-UKF算法实现流程

4 验证与分析

研究对象为型号INR18650-20R的单体动力锂电池,具体参数如表1所示,该锂电池具有高能量密度、长寿命、较小的自放电率、低内阻及高放电平台等优点,在电动汽车领域具有广泛的应用。

表1 锂电池的主要参数

标称容量/A·h	标称电压/V	电压范围/V	标准充电	尺寸/mm×mm	质量/g
2	3.6	2.5~4.2	CCCV/1 A/4.20 V	18×65	40

美国马里兰大学利用Arbin BT2000设备在恒温25℃条件下对上述锂电池进行测试,并公开了测试数据集,其中包含多循环联邦城市行驶工况(Federal Urban Driving Schedule, FUDS)、动态应力测试(Dynamic Stress Test, DST)工况、激励驾驶工况(US06 Supplemental FTP Driving Schedule, US06)以及北京动态应力测试工况(Beijing Dynamic Stress Test, BJDST)4种不同动态循环

工况下的测试数据,用于算法验证。

验证结果的评价采用平均相对误差(Mean Relative Error, MRE)、均方根误差(Root Mean Squared Error, RMSE)以及最大绝对误差(Maximum Absolute Error, MAE)3种误差指标。

经调试,算法涉及到的相关参数设置如下:


递推最小二乘法参数设置:待估向量 θ_0 中各参数初值为 10^{-3} ;协方差矩阵初始值 $G_0=10^6I$ 。

UKF算法参数设置:状态协方差矩阵 $P_0=10^{-2}$;系统状态噪声协方差 $Q=10^{-4}$;测量噪声协方差 $R=10^{-1}$ 。


ELM模型参数设置:隐层节点数量设定为50;随机生成各隐层节点的输出权值和偏移量;状态检测机制中的检测阈值 $\zeta=0.05$ 。

4.1 辨识锂电池Nernst模型的参数


锂电池在FUDS工况下的电流变化剧烈且为持续激励的方式,因此,此工况能够满足利用递推最小二乘法辨识Nernst模型参数的要求。图3a、图3b为采集到的电池电压和电流数据,图3c为根据电池容量变化计算出的实际SOC数据,上述3组数据对应Nernst模型测量方程的已知参数;图3d为递推最小二乘法根据测量方程已知参数辨识模型未知参数 E_0 、 R_1 、 k_1 及 k_2 的收敛过程。




(a)FUDS工况采集的电压



(b)FUDS工况采集的电流



(c)FUDS工况实际SOC



(d)参数辨识收敛过程


图3 数据采集及参数辨识过程

从图3d可以看出,各参数辨识曲线具有相似的收敛特性,均在时间迭代6 000 s之后趋于稳定,模型参数最终辨识结果如表2所示。


表2 Nernst模型参数辨识结果

参数	E_0/V	R_1/Ω	k_1	k_2
取值	3.49	0.08	0.01	-0.28

根据表2建立锂电池的非线性动态Nernst模型,并在FUDS工况下验证所建模型预测电压的精度,结果如图4所示。



(a)实测与模型预测电压



(b)模型预测电压误差

图4 FUDS工况下实测端电压与预测电压比较

图4中Nernst模型预测电压和实测端电压之间贴合度较高,二者之间误差在 $-0.02\sim 0.07$ V范围内分布,误差指标RMSE为0.95%,MRE为0.21%,说明所建模型在FUDS工况下预测锂电池端电压的精度较高,参数辨识的方法可行有效。

4.2 建立预测SOC估计误差的ELM模型

在FUDS工况下,收集UKF估计锂电池SOC全过程的相关滤波数据,经归一化处理作为建立ELM模型所需的训练及测试样本集。为了验证所建模型的预测效果,需对样本集中的数据进行排列,这里将其中的奇数项数据用于模型的训练,偶数项数据用于模型的测试。利用训练成功的ELM模型来预测UKF的SOC估计误差,结果如图5所示。




图5 ELM模型预测输出与SOC估计误差比较

图5中,UKF的SOC估计误差虽然整体变化起伏较大且相邻值之间小幅波动较为剧烈,但ELM模型预测输出始终保持了较好的变化跟踪响应速度,与SOC估计误差之间咬合紧密,进一步分析ELM模型的预测误差,如图6所示。

图6中,ELM模型的预测误差在 $\pm 2\%$ 范围内分布较为均匀,误差指标RMSE为1.46%,预测精度较高,虽然在某些测试点出现了小幅过拟合的情况,但总体的泛化性能较为优异,能够有效辅助UKF提升估计SOC的精度。




图6 ELM模型预测误差

4.3 验证状态检测机制

选用DST工况验证改进算法中状态检测机制的有效性,鉴于UKF在DST工况下估计SOC的滤波数据未用于ELM模型的训练,因此,在DST工况下,必然存在部分ELM模型输入数据与训练集数据的分布不一致,进而会在某些时刻产生模型预测输出过拟合,引入状态检测机制前、后SOC估计效果的对比如图7所示。




图7 引入状态检测机制前、后的估计效果

图7中,在ELM模型预测输出过拟合的时刻,ELM-UKF未引入状态检测机制的SOC估计结果波动较为剧烈,而引入状态检测机制后,能实时检测ELM模型预测输出的大小,并根据实际情况对UKF的SOC估计结果做出合适的误差补偿,从图7中的细节放大部分可见,带状状态检测机制的ELM-UKF具备了良好的矫正性能,改善SOC估计波形平滑度的效果非常明显。进一步分析引入状态检测机制前、后的SOC估计误差,如图8所示。




图8 引入状态检测机制前、后的估计误差

图8中,ELM-UKF未引入状态检测机制时,SOC估计误差指标MAE高达21.2%;而引入状态检测机制改进

后,误差均分布在 $\pm 2.5\%$ 的较小范围内,说明在ELM模型预测输出过拟合时,状态检测机制完全能够有效地抑制SOC估计结果的剧烈波动。

4.4 验证变工况估计效果

选取了FUDS、DST、US06以及BJDST 4种动态循环工况验证算法估计SOC的效果,结果如图9~图12所示。

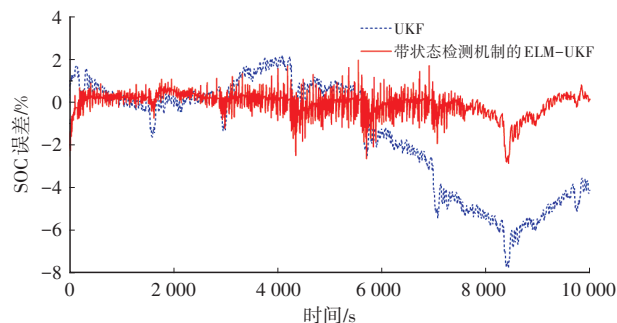


图9 FUDS工况SOC估计结果比较




图10 DST工况下SOC估计结果比较




图11 US06工况下SOC估计结果比较

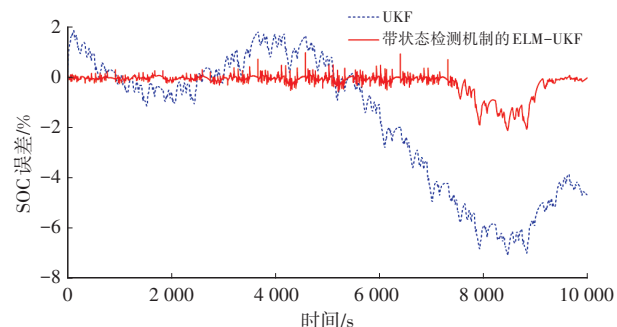


图12 BJDST工况下估计结果比较

从图9~图12中的误差分布可看出,UKF的SOC估计效果呈现一般,这是由于其设定的固定噪声方差无法

减小电池模型精度和不规则噪声干扰的影响;而带状态检测机制的ELM-UKF相较于UKF则有了很大的改善,这是由于其具备的自适应调节能很好地修正UKF的估计误差,并有效地降低估计结果的波动幅度。但在US06工况下,带状态检测机制的ELM-UKF估计效果相较于其他3种工况稍差,主要是由于ELM模型过度学习了训练样本数据的噪声和细节,未能很好地泛化到US06工况数据,从而导致模型预测输出补偿UKF的估计误差不到位。

表3 不同工况下估计SOC的误差指标 %

算法	工况	RMSE	MRE	MAE
UKF	FUDS	3.04	10.58	7.83
	DST	3.03	12.29	7.28
	US06	1.96	6.56	4.19
	BJDST	3.17	12.22	7.04
带状态检测机制的ELM-UKF	FUDS	0.56	1.39	2.88
	DST	0.59	1.45	3.43
	US06	1.17	3.58	3.12
	BJDST	0.49	1.2	2.1

从表3中可以看出,带状态检测机制的ELM-UKF将UKF的SOC估计误差指标RMSE由1.96%~3.17%降低至0.49%~1.17%,MRE由6.65%~12.22%降至1.2%~3.58%,MAE由4.19%~7.83%降至2.10%~3.43%。上述数据充分证明,在不同的工况下,相较于UKF,带状态检测机制的ELM-UKF具有良好的泛化性和鲁棒性。

4.5 验证变温度估计效果

锂电池在不同温度条件下工作时,其内部具有各异的化学反应,导致预设的电池模型参数不准确,主要体现在电池容量和欧姆内阻^[26],对于依赖电池模型精度的算法,模型参数的变化会直接影响到SOC估计精度。图13为0℃和45℃条件下利用DST工况验证改进算法的SOC估计效果。

图13中,0℃时算法估计SOC的误差高于45℃条件下的误差,这是由于低温时电池容量和欧姆内阻的变化差异较高温时明显,导致低温时电池模型的精度更低。另外,带状态检测机制的ELM-UKF在两种温度条件下均可补偿并优化SOC估计误差,相较于UKF,对电池模型的容错性能更好,SOC估计效果明显提高。

根据表4可总结得出,在不同的温度条件下,虽然带状态检测机制的ELM-UKF误差指标数据更优异,在一定程度上降低了温度变化对电池模型精度所产生的影响,但受限于ELM模型训练方法和样本数据的选

择,低精度电池模型对SOC估计结果带来的影响仍相对较大。

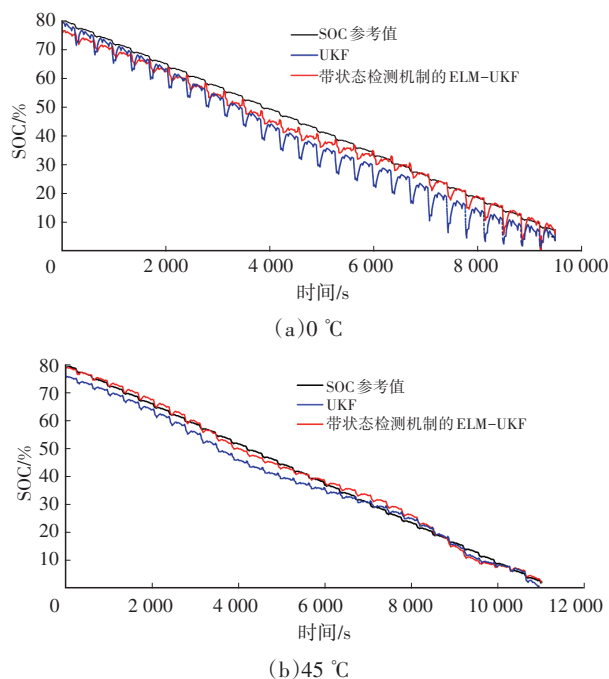


图13 不同温度条件下的估计效果比较

表4 不同温度下估计SOC的误差指标

算法	温度/°C	RMSE/%	MRE/%	MAE/%
UKF	0	5.78	13.33	15.67
	45	3.08	7.01	6.14
带状态检测机制的ELM-UKF	0	2.98	4.56	4.79
	45	1.58	3.93	3.61

5 结束语

本文提出了一种带状态检测机制的ELM-UKF组合算法,利用INR18650-20R锂电池测试数据对算法的SOC估计性能进行了验证,得到如下结论:

a. 在锂电池SOC估计的过程中,ELM与UKF相辅相成,预测SOC估计误差的ELM模型能实时对UKF的估计偏差进行有效补偿,大幅提升了SOC估计精度。

b. 当ELM模型输入数据与训练样本集的分布不一致时,设计的状态检测机制可以明显改善ELM模型预测输出过拟合对SOC估计波形平滑度造成的影响。

c. 在不同的工况和温度下,带状态检测机制的ELM-UKF相较于UKF,SOC估计精度更高,各类误差指标均控制在5%以内,全面提升了锂电池SOC估计的泛化性和鲁棒性。

参考文献

[1] 王义军,左雪. 锂离子电池荷电状态估算方法及其应用场景综述[J]. 电力系统自动化,2022,46(14):193-207.

WANG Y J, ZUO X. Review on Estimation Methods for State of Charge of Lithium-Ion Battery and Their Application Scenarios[J]. Automation of Electric Power Systems, 2022, 46(14): 193-207.

[2] 高铭琨,徐海亮,吴明铂. 基于等效电路模型的动力电池SOC估计方法综述[J]. 电气工程学报,2021,16(1):90-102.

GAO M K, XU H L, WU M B. Review of SOC Estimation Methods for Power Battery Based on Equivalent Circuit Model[J]. Journal of Electrical Engineering, 2021, 16(1): 90-102.

[3] 徐立友,马可,杨晴霞,等. 基于卡尔曼滤波的动力电池SOC估算[J]. 江苏大学学报(自然科学版),2024,45(1):24-29.

XU L Y, MA K, YANG Q X, et al. SOC Estimation of Power Battery Based on Kalman Filter[J]. Journal of Jiangsu University (Natural Science Edition), 2024, 45(1): 24-29.

[4] 吴忠强,尚梦瑶,申丹丹,等. 基于神经网络和MS-AUKF算法的蓄电池荷电状态估计[J]. 中国电机工程学报,2019,39(21):6336-6344.

WU Z Q, SHANG M Y, SHEN D D, et al. SOC Estimation of Battery by MS-AUKF Algorithm and BPNN[J]. Proceedings of the CSEE, 2019, 39(21): 6336-6344.

[5] CHEN Z, YANG L, ZHAO X, et al. Online State of Charge Estimation of Li-Ion Battery Based on An Improved Unscented Kalman Filter Approach[J]. Applied Mathematical Modelling, 2019, 70(7): 532-544.

[6] HUANG C, WANG Z, ZHAO Z, et al. Robustness Evaluation of Extended and Unscented Kalman Filter for Battery State of Charge Estimation[J]. IEEE Access, 2018: 27617-27628.

[7] MENG J, LUO G, GAO F. Lithium Polymer Battery State-of-Charge Estimation Based on Adaptive Unscented Kalman Filter and Support Vector Machine[J]. IEEE Transactions on Power Electronics, 2015: 2226-2238.

[8] 于仲安,邵昊晖,陈可怡. 基于IGWO-BP神经网络的锂离子电池SOC估计[J]. 电源技术,2023,47(9):1153-1157.

YU Z A, SHAO H H, CHEN K Y. SOC Estimation of Lithium-Ion Battery Based on IGWO-BP Neural Network[J]. Chinese Journal of Power Sources, 2023, 47(9): 1153-1157.

[9] 张小辉,许傲然,王秀平. 回溯搜索算法改进RBF算法的锂离子电池SOC估算研究[J]. 电测与仪表,2020,57(18):146-152.

ZHANG X H, XU A R, WANG X P. Research on Lithium-Ion Battery SOC Estimation Based on Backtracking Search Algorithm and Improved RBF Algorithm[J]. Electrical Measurement & Instrumentation, 2020, 57(18): 146-152.

[10] WEI M, YE M, LI J B, et al. State of Charge Estimation for Lithium-ion Batteries Using Dynamic Neural Network Based on Sine Cosine Algorithm: [J]. Proceedings of the

- Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2022, 236(2/3): 241-252.
- [11] 胡坚, 刘超. NTLBO算法优化ELM的SOC预测方法[J]. 计量学报, 2022, 43(1): 92-96.
- HU J, LIU C. The SOC Prediction Method of ELM Optimized by NTLBO Algorithm[J]. ACTA Metrologica Sinica, 2022, 43(1): 92-96.
- [12] 毛玲, 温佳林, 赵晋斌, 等. 基于集成ELM的锂离子电池充电截止电压下的SOC和SOH联合估计[J]. 电力系统保护与控制, 2023, 51(11): 86-95.
- MAO L, WEN J L, ZHAO J B, et al. Joint Estimation of SOC and SOH at Lithium-Ion Battery Charging Cut-Off Voltage Based on An Ensemble Extreme Learning Machine[J]. Power System Protection and Control, 2023, 51(11): 86-95.
- [13] 缪家森, 成丽珉, 吕宏水. 基于PSO-ELM的储能锂电池荷电状态估算[J]. 电力工程技术, 2020, 39(1): 165-169+199.
- MIAO J S, CHENG L M, LYU H S. Estimation of State of Charge of Energy Storage Lithium Battery Based on PSO-ELM[J]. Electric Power Engineering Technology, 2020, 39(1): 165-169+199.
- [14] 孔祥创, 赵万忠, 王春燕. 基于BP-EKF算法的锂电池SOC联合估计[J]. 汽车工程, 2017, 39(6): 648-652.
- KONG X C, ZHAO W Z, WANG C Y. Co-Estimation of Lithium Battery SOC Based on BP-EKF Algorithm[J]. Automotive Engineering, 2020, 39(1): 165-169+199.
- [15] XING L, LING L, WU X. Lithium-Ion Battery State-of-Charge Estimation Based on A Dual Extended Kalman Filter and BPNN Correction[J]. Connection Science, 2022, 34: 2332-2363.
- [16] LIN J, YANG X, ZHOU J, et al. Algorithm of BPNN-UKF Based on A Fusion Model for SOC Estimation in Lithium-Ion Batteries[J]. IETPower Electronics, 2023, 16(5): 856-867.
- [17] 刘兴涛, 李坤, 武骥, 等. 基于EKF-SVM算法的动力电池SOC估计[J]. 汽车工程, 2020, 42(11): 1522-1528+1544.
- LIU X T, LI K, WU J, et al. State of Charge Estimation for Traction Battery Based on EKF-SVM Algorithm[J]. Automotive Engineering, 2020, 42(11): 1522-1528+1544.
- [18] PASCHERO M, STORTI G L, RIZZI A. A Novel Mechanical Analogy-Based Battery Model for SOC Estimation Using A Multicell EKF[J]. IEEE Transactions on Sustainable Energy, 2016, 7(4): 1695-1702.
- [19] 杨帆, 和嘉睿, 陆鸣, 等. 基于BP-UKF算法的锂离子电池SOC估计[J]. 储能科学与技术, 2023, 12(2): 552-559.
- YANG F, HE J R, LU M, et al. SOC Estimation of Lithium-Ion Batteries Based on BP-UKF Algorithm[J]. Energy Storage Science and Technology, 2023, 12(2): 552-559.
- [20] 李军, 张俊, 张世义. 基于ABP-EKF算法的锂电池SOC估计[J]. 重庆交通大学学报(自然科学版), 2021, 40(3): 135-140.
- LI J, ZHANG J, ZHANG S Y. Lithium Battery SOC Estimation Based on ABP-EKF Algorithm[J]. Journal of Chongqing Jiaotong University (Natural Science), 2021, 40(3): 135-140.
- [21] XIAO D, LI B Y, SHAN J W, et al. SOC Estimation of Vanadium Redox Flow Batteries Based on the ISCSO-ELM Algorithm[J]. ACS Omega, 2023, 8(48): 45708-45714.
- [22] 毕军, 康燕琼, 邵赛. 纯电动汽车动力锂电池Nernst模型参数辨识[J]. 汽车工程, 2015, 37(6): 725-730.
- BI J, KANG Y Q, SHAO S. Parameters Identification of Nernst Model for Power Lithium-ion Battery of Pure Electric Vehicles[J]. Automotive Engineering, 2015, 37(6): 725-730.
- [23] 谈发明, 赵俊杰, 王琪. 动力电池SOC估计的一种新型鲁棒UKF算法[J]. 汽车工程, 2019, 41(8): 944-952.
- TAN F M, ZHAO J J, WANG Q. A Novel Robust UKF Algorithm for SOC Estimation of Traction Battery[J]. Automotive Engineering, 2019, 41(8): 944-952.
- [24] 李泽宇, 王晓磊, 张世彪, 等. 基于递推最小二乘法的锂离子电池等值参数在线识别[J]. 山东电力技术, 2021, 48(2): 1-6+16.
- LI Z Y, WANG X L, ZHANG S B, et al. On-line Identification Parameters of Lithium-Ion Least Square Method[J]. Shandong Electric Power, 2021, 48(2): 1-6+16.
- [25] ZHANG C, WANG S, YU C. Novel Improved Particle Swarm Optimization-Extreme Learning Machine Algorithm for State of Charge Estimation of Lithium-Ion Batteries[J]. Industrial & Engineering Chemistry Research, 2022, 61(46): 17209-17217.
- [26] 靳立强, 孙志祥, 刘志茹, 等. 不同温度下锂电池剩余电量估算的仿真研究[J]. 汽车工程, 2019, 41(5): 590-598+606.
- JIN L Q, SUN Z X, LIU Z L, et al. Simulation Study on State of Charge Estimation of Lithium-Ion Battery at Different Temperatures[J]. Automotive Engineering, 2019, 41(5): 590-598+606.

(责任编辑 王 一)

修改稿收到日期为2024年7月5日。