



ELSEVIER

Contents lists available at ScienceDirect

Engineering

journal homepage: www.elsevier.com/locate/eng



Research
Energy Batteries—Article

基于多模型融合驱动的锂离子动力电池荷电状态和容量联合估计研究

熊瑞^{a,*}, 王桀^a, Weixiang Shen^b, 田金鹏^{a,b}, 穆浩^a

^a Department of Vehicle Engineering, School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081, China

^b Faculty of Science, Engineering and Technology, Swinburne University of Technology, Hawthorn, VIC 3122, Australia

ARTICLE INFO

Article history:

Received 1 June 2020

Revised 19 August 2020

Accepted 25 October 2020

Available online 9 February 2021

关键词

荷电状态

容量估计

模型融合

比例-积分-微分观测器

硬件在环

摘要

锂离子动力电池(LIB)已成为各种电动载运工具的首选电源系统,包括电动汽车、电动轮船、电动火车和电动飞机。在全气候全寿命周期运行的电动载运工具中,锂离子电池的能量管理需要实时准确估计电池的荷电状态(SOC)和容量。本文提出了一种多阶段模型融合算法可协同估计SOC和容量。首先,基于正态分布假设,利用模型在不同老化状态下的残差均值和方差计算权重,建立参数稳定的融合模型。其次,将具有预测性的微分增益引入比例-积分观测器(PIO)以提高收敛速度。再次,将多阶段融合模型与比例-积分-微分观测器(PIDO)结合,建立了一种融合算法,可实现复杂应用环境下SOC和容量的协同估计。然后,讨论了融合算法的收敛性和抗噪性能。最后,搭建硬件在环平台,验证了融合算法的性能。不同老化状态和温度下的验证结果表明,融合算法可以实现SOC和容量的高精度协同估计,误差分别在2%和3.3%以内。

© 2021 THE AUTHORS. Published by Elsevier LTD on behalf of Chinese Academy of Engineering and Higher Education Press Limited Company. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. 引言

随着能源短缺和空气污染加剧,国际上汽车消费大国相继制定了禁止燃油汽车的计划,这将不可避免地加速交通工具的电气化[1]。由于循环寿命长、能量密度高、成本低等优点,锂离子动力电池(LIB)已成为电动汽车、电动船、电动火车和电动飞机常用的储能单元[2–3]。在电动载运工具中,电池管理系统(BMS)在动力电池的安全运行过程中发挥着关键作用,其主要功能是实时准确估计荷电状态(SOC)和容量。由于锂离子电池是复杂的化学系统,SOC和容量之间存在耦合效应[4]。此外,老化和宽温度范围的复杂工况对电动载运工具中的锂离子电

池影响较大,难以准确协同估计SOC和容量。

1.1. 文献综述

现有的SOC估计方法主要分为三类[5],如图1(a)所示,主要包括基本法、基于模型的方法和数据驱动的方法。基本法主要包括查表法和安时积分法。查表法对电压测量精度要求高且电池静置时间长[6],不适用于实车应用。当锂离子电池的初始SOC和真实容量已知时,可采用安时积分法估计SOC,但该方法依赖于高精度的电流传感器[7]。基于模型的方法通常使用电化学模型(EM)、等效电路模型(ECM)和分数阶模型(FOM)等[8]进行SOC闭环估计。其中,观测器可实现SOC高精度和强鲁棒性估计[9],包括Luenberger观测器[10]、滑模观测器

* Corresponding author.

E-mail address: rxiong@bit.edu.cn (R. Xiong).

[11]、H无穷观测器[12]、无迹粒子滤波器[13]和比例积分观测器 (PIO) [9]等。根据文献[14]知, PIO观测器具有更高的SOC估计精度, 但其收敛速度较慢且存在超调现象。数据驱动的SOC估计方法依赖于黑箱模型, 需要大量的训练数据, 在实际应用时易出现过拟合现象[15]。数据模型融合方法是数据驱动的估计方法之一, 通过融合在线数据训练和模型拟合来准确估计SOC [4]。在全生命周期宽温度范围工况应用时, 该方法具有一定的局限性。

电池容量与健康状态 (SOH)、剩余寿命和SOC的估计密切相关。现有的容量估计方法主要分为三类, 如图1(b)所示, 包括数据驱动方法、基于模型的方法和数据分析方法[16]。数据分析方法包括充电曲线法[2]、容量增量分析 (ICA) 法[17]、差分电压分析 (DVA) 法等[18]。该类方法严重依赖于恒流充电/放电曲线, 在实际应用中很少使用。基于模型的方法通常使用电化学模型[19]、等效电路模型[5]和分数阶模型等[20]闭环估计容量, 在特定工况下具有较高的精度。一般来说, 在一定温度范围内, 这些方法具有较高的准确性。然而, 当动力电池的温度变化较大时, 精度有所下降。数据驱动的方法主要包括机器学习方法[21]和经验方法[22]。该类方法需要大量的训练数据来保证估计结果的稳定性和精度。

1.2. 研究目的及创新性

现有的SOC和容量估计方法在特定的场景下具有较高的精度, 如短期运行 (忽略老化) 和特定温度区间等。图1(c)总结了现有SOC和容量估计方法存在的不足。针对这些问题, 本文开展了以下工作: ①为实现小电流激励下稳定的模型参数在线更新, 从多阶段模型中提取残差的均值和方差, 基于正态分布假设计算概率密度函数 (PDF), 然后计算融合权重, 建立融合模型, 最终实现小电流激励下模型参数的实时稳定更新。②将具有预测性的微分误差增益引入PIO/比例积分微分观测器 (PIDO) 中, 提高了状态估计的收敛速度。③将融合模型和PIDO结合建立了一种新的状态估计算法框架, 实现了宽温度范围全生命周期下SOC和容量的准确协同估计。硬件在环 (HIL) 验证表明, 该算法可以较好地兼顾估计精度和实时性。

1.3. 本文结构

本文的剩余部分结构如下: 第2节介绍了实验、电池建模和融合模型; 第3节介绍了PIDO的设计和多阶段融合算法; 第4节展示了验证结果和相应的讨论, 然后是HIL验证结果; 最后一节为本文结论。

2. 电池模型及融合方法

2.1. 电池测试

本文建立了动力电池测试平台, 基于测试数据建立电池模型及验证算法。该平台包括BT2000电池充放电系统和恒温箱等[23], 其中BT2000电池测试系统由美国Arbin生产, 由主机计算机控制并用于动力电池的充放电测试, 该系统具有较高的电压和电流测量精度 (满量程0.02%~0.05%)。恒温箱可为被测电池提供恒定的环境温度。本文的被测对象为25 A·h的锂离子动力电池, 上、下截止电压分别为4.2 V和2.8 V。测试流程包括老化循环测试和宽温度特性测试。老化循环测试采用12.5 A电流循环充放电加速电池老化[24]。特性测试包括静态容量测试、开路电压 (OCV) 测试、混合脉冲功率特性 (HPPC) 测试[25]和工况测试, 其中, 静态容量测试用于标定电池容量, 以确定SOH的状态。OCV测试用于确定OCV-SOC曲线, 该曲线是SOC估计的关键, HPPC测试用于辨识模型参数。工况测试用于验证模型和算法。测试结果表明, 该动力电池经过600次老化循环后, 容量衰减到80%以下, 在电动载运工具中可视为动力电池寿命到达终点。

2.2. 电池模型

为较好地兼顾算法的实时性和估计的精准性, 采用带有1个电阻-电容 (RC) 网络的电池等效电路模型来描述电池的动态特性[26], 离散控制方程的表达式如下[27]:

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k + \mathbf{B}i_{L,k} \\ \mathbf{U}_k = \mathbf{C}\mathbf{x}_k + \mathbf{D}i_{L,k} \end{cases} \quad (1)$$

式中, k 为采样时刻, \mathbf{x}_{k+1} 为 $k+1$ 时刻的状态向量, \mathbf{x}_k 为 k 时刻的状态向量, \mathbf{A} 为状态转移矩阵, \mathbf{B} 为控制矩阵, \mathbf{C} 为输出矩阵, \mathbf{D} 为反馈矩阵, $\mathbf{x}_k = [z_k, U_{d,k}]^T$, $\mathbf{A} =$

$$\begin{bmatrix} 1 & 0 \\ 0 & \exp(-\frac{\Delta t}{T_d}) \end{bmatrix}, \mathbf{B} = \begin{bmatrix} -\frac{\eta\Delta t}{C_{\max}} \\ R_d[1 - \exp(-\frac{\Delta t}{T_d})] \end{bmatrix}, \mathbf{C} = \begin{bmatrix} \frac{\partial U_{ocv,k}}{\partial z_k} & -1 \end{bmatrix},$$

$\mathbf{D} = R_0$, $i_{L,k}$ 为 k 时刻输入电流, U_k 为 k 时刻端电压, $U_{ocv,k}$ 为 k 时刻开路电压, $U_{d,k}$ 为 k 时刻极化电压, R_0 为欧姆内阻, T_d 为极化时间常数, R_d 为极化内阻, z_k 为 k 时刻SOC。电流为正值时表示放电。 C_{\max} 为电池最大可用容量, Δt 为采样间隔, η 为库伦效率。模型参数可从不同温度下的实验数据中提取, 然后构建模型参数与温度和SOC的函数, 如开路电压 (U_{ocv}) 可由式 (2) 计算, R_0 、 R_d 和 T_d 可由式 (3) 建模表征, 其中 K_n 为开路电压系数, S_m 为其他模型参数多项式拟合系数, 参数辨识结果可由最小二乘算法

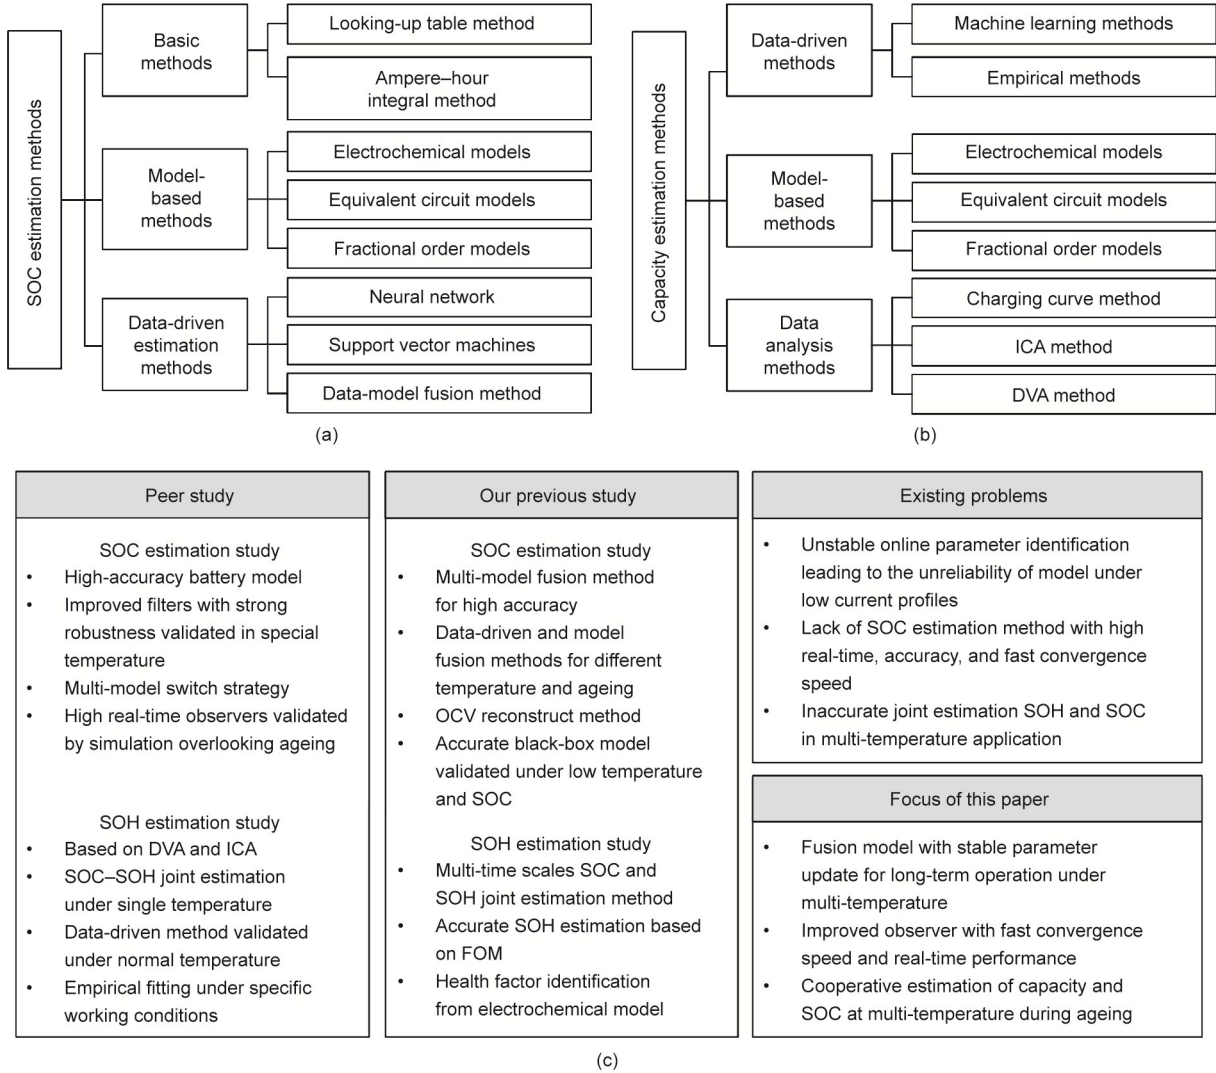


图1. SOC和容量估计方法综述。(a) SOC估计方法主要分类；(b) 容量估计方法主要分类；(c) SOC和容量估计方法存在的问题及本文的研究重点。ICA: 容量增量分析；DVA: 差分电压分析；SOH: 健康状态；OCV: 开路电压；FOM: 分数阶模型。

确定[28]。

$$U_{ocv}(T, z) = K_9(T)z^9 + K_8(T)z^8 + K_7(T)z^7 + K_6(T)z^6 + K_5(T)z^5 + K_4(T)z^4 + K_3(T)z^3 + K_2(T)z^2 + K_1(T)z + K_0(T) \quad (2)$$

式中, T 为电池表面温度; z 为SOC。

$$f(T, z) = S_5(T)z^5 + S_4(T)z^4 + S_3(T)z^3 + S_2(T)z^2 + S_1(T)z + S_0(T) \quad (3)$$

式中, f 为模型参数-温度-SOC拟合函数。

2.3. 参数辨识

循环600次后, 筛选电池在多个温度和8个老化点(0、100、200、300、400、480、550和600次循环)下的数据建立电池模型并验证所提出的算法。为了兼顾全生命周期电池模型的复杂性和准确性, 采用0次循环(SOH=

1)、300次循环(SOH=0.91)和600次循环(SOH=0.76)对三个老化状态的电池测试数据分别建立电池模型, 并将其命名为模型1、模型2和模型3, 确定三种模型的参数。由于动力电池最大可用容量受温度影响, 本文采用25 °C下的容量标定值计算动力电池的SOH。表1为OCV-SOC-T模型的参数。表2为 R_0 -SOC-T模型的参数。图2为SOH=0.76时的模型参数。

2.4. 单模型的局限性

单个模型对某个老化程度的数据具有较好的适应性, 例如, 模型2是基于300次老化数据建立的模型, 适用于该老化状态, 具有较高的电压预测精度。在全生命周期中, 电池运行于不同的老化状态, 因此单一模型的精度会下降, 测试结果如图3所示。

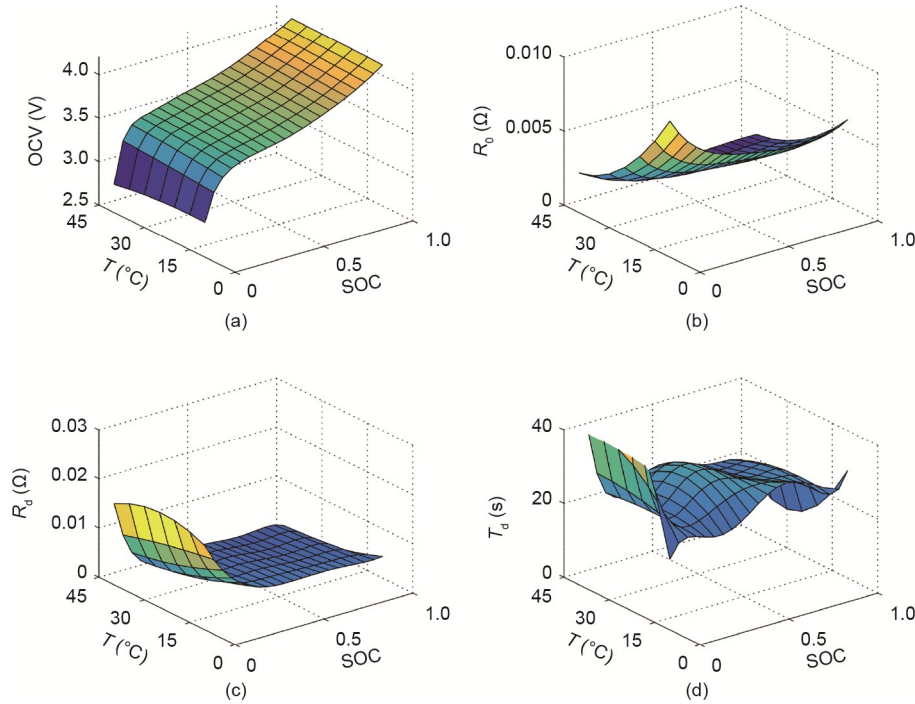


图2. 0次循环被测电池模型参数。(a) 开路电压；(b) 欧姆内阻；(c) 极化内阻；(d) 时间常数。

表1 0次循环OCV-SOC-T函数

Parameter	Coefficient
$K_9(T)$	$-1.415T^2 + 100.506T - 822.714$
$K_8(T)$	$7.014T^2 - 504.21T + 4125.619$
$K_7(T)$	$-14.69T^2 + 1070.851T - 8739.83$
$K_6(T)$	$16.901T^2 - 1252.23T + 10180.88$
$K_5(T)$	$-11.619T^2 + 878.238T - 7114.06$
$K_4(T)$	$4.867T^2 - 377.507T + 3053.534$
$K_3(T)$	$-1.217T^2 + 97.745T - 791.834$
$K_2(T)$	$0.172T^2 - 14.472T + 117.182$
$K_1(T)$	$-0.0124T^2 + 1.116T - 8.377$
$K_0(T)$	$0.000377T^2 - 0.0361T + 3.698$

表2 0次循环 R_0 -SOC-T函数

Parameter	Coefficient
$S_5(T)$	$0.00062T^2 - 0.0338T + 0.3238$
$S_4(T)$	$-0.00169T^2 + 0.0915T - 0.841$
$S_3(T)$	$0.00172T^2 - 0.0918T + 0.796$
$S_2(T)$	$-0.000793T^2 + 0.0414T - 0.324$
$S_1(T)$	$0.000156T^2 - 0.00778T + 0.0451$
$S_0(T)$	$-0.0000047T^2 + 0.0000147T + 0.00931$

图3 (a) 中蓝线表示基于0次循环构建的模型1在全生命周期下的电压预测误差。该模型在0次老化下具有较高的测试精度。随着老化水平的增加, 电压预测均方根误差 (RMSE) 逐渐增加。绿线为模型2全生命周期下的电压预测误差, 该模型是基于300次循环数据建立的, 在

100~400次循环过程中具有较高的精度, 但对于新电池和严重老化的电池适应性较差。红线为模型3在全生命周期下的测试精度, 该模型基于600次循环数据构建而成, RMSE随着电池老化而降低, 该模型在480~600次循环过程中具有较高的电压预测精度。相同的, 在10℃下各模型具有相似的现象, 如图3 (b) 所示。因此, 基于单一老化点建立的模型难以实现全生命周期准确的电压预测和SOC估计。

2.5. 融合模型设计

为改善单一模型的老化局限性, 本文提出了多阶段模型融合方法, 可实现全生命周期下电压的准确预测。利用电压测量值与预测值间的误差计算各个模型的权重, 建立实时的加权融合模型。融合模型的参数由公式 (4) 计算。

$$\begin{cases} R_{0,F,k} = \sum_{i=1}^p g_{i,k} R_{0,i,k} \\ R_{d,F,k} = \sum_{i=1}^p g_{i,k} R_{d,i,k} \\ T_{d,F,k} = \sum_{i=1}^p g_{i,k} T_{d,i,k} \end{cases} \quad (4)$$

式中, p 为待融合模型的数量; i 为第 i 个待融合的模型; $g_{i,k}$ 为第 i 个模型 k 时刻的权重; $R_{0,i,k}$ 为第 i 个模型 k 时刻的欧姆电阻; $R_{d,i,k}$ 和 $T_{d,i,k}$ 分别为第 i 个模型 k 时刻的极化电阻和时间常数; $R_{0,F,k}$ 为 k 时刻融合模型的欧姆电阻; $R_{d,F,k}$ 为 k 时刻融合模型的极化电阻; $T_{d,F,k}$ 为 k 时刻融合模型的极化




图3. 基于不同老化程度模型的电压预测误差分析。(a) 25 °C下的验证结果；(b) 10 °C下的验证结果。RMSE：均方根误差。

时间常数。

由于计算量小和实时性高，递归最小二乘（RLS）算法常用于在线识别电池参数[29]。该方法的主要挑战是小电流激励下参数辨识误差较大[30]。图4为融合方法和带遗忘因子的RLS算法的模型在线辨识结果。在工况的前315 s内电流激励为零，仅用电压信息难以准确辨识模型参数。为此，RLS在该工况下常采用停止更新的方式保证参数的稳定性，并利用历史参数来估计SOC [28]。与RLS相比，融合方法具有边界约束，在低电流下依然可以辨识出稳定的参数。三个模型的融合权重如图4（d）所示。由图3（b）中的单个模型的预测精度知，模型2的RMSE最小，模型3的RMSE最大，因此模型2的权重最大，模型3的权重最小。结果表明：所提出的融合策略可以在正态分布假设的基础上，通过模型残差分析有效地计算融合权重。

融合模型验证结果如图5所示，模型1、2和3分别基

于0、300和600次循环老化测试数据建立。25 °C下，融合模型在全生命周期内的RMSE均小于0.018 V，低于模型1、2和3的电压预测误差均方根值。同样10 °C下，融合模型的最大RMSE为0.04 V，低于模型1、2和3的电压预测误差均方根值。结果表明，在全生命周期不同温度下，融合模型比单一模型具有更小的电压预测误差。

3. 状态估计方法

3.1. 比例-积分-微分观测器

PIO在文献[9]中首次用于动力电池SOC估计。由于忽略了反馈误差的微分，该观测器在SOC估计时出现超调并且收敛速度较慢。为了提高收敛速度并抑制超调，本文将误差的微分引入PIO，改进的观测器称为比例-积分-微分观测器，如图6所示。

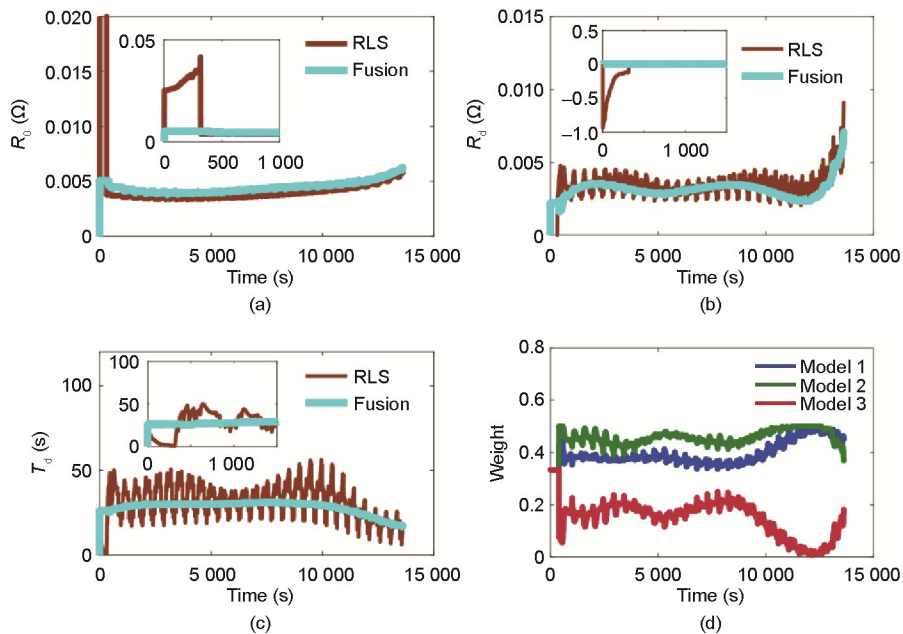


图4. 100循环10 °C下融合模型参数。(a) 欧姆电阻；(b) 极化电阻；(c) 时间常数；(d) 权重。




图5. 融合模型精度分析。(a) 25 °C下验证结果；(b) 10 °C下验证结果。




图6. 观测器原理。(a) PI观测器；(b) PID观测器。Ut: 端电压； K_p : 比例增益； K_i : 积分增益； K_D : 微分增益； \hat{U}_t : 被观测的端电压； \hat{x} : 被观测的状态向量； \int : 积分运算； d/dt : 微分运算。

利用PIDO的离散方程，基于端电压跟踪反馈实现锂离子电池SOC估计：

$$\begin{cases} \hat{x}_{k+1} = A\hat{x}_k + Bi_{L,k} + K_p e_k + K_i \omega_k + K_D \frac{e_k - e_{k-1}}{\Delta t} \\ \hat{U}_t = C\hat{x}_k + Di_{L,k} \\ e_k = U_t - \hat{U}_t \\ \omega_{k+1} = \omega_k + e_k \Delta t \end{cases} \quad (5)$$

式中， e_k 是 k 时刻的测量误差； ω_k 是 k 时刻误差积分； K_p 、 K_i 和 K_D 分别为比例增益、积分增益和微分增益； \hat{U}_t 为预测的端电压。被观测的状态包括SOC和极化电压。当微分增益为零，则PIDO变为PIO。

对于真实状态 x_k ，其估计误差(γ_k)为 $x_k - \hat{x}_k$ 。误差系统可以从方程(1)和方程(5)推导出来。

$$\begin{cases} \gamma_{k+1} = (A - K_p C - \frac{K_D C}{\Delta t})\gamma_k - K_i \omega_k + \frac{K_D C}{\Delta t} \gamma_{k-1} \\ \omega_{k+1} = \omega_k + C\gamma_k \Delta t \\ e_k = C\gamma_k \end{cases} \quad (6)$$

定义误差系统的状态向量为 $\mathfrak{R}_k = [\gamma_k \ \gamma_{k-1} \ \omega_k]^T$ ，式

(6)可改写为：

$$\begin{cases} \mathfrak{R}_{k+1} = A_e \mathfrak{R}_k \\ A_e = \begin{bmatrix} A - K_p C - \frac{K_D C}{\Delta t} & \frac{K_D C}{\Delta t} & -K_i \\ I_{2 \times 2} & 0_{2 \times 2} & 0_{1 \times 2} \\ C\Delta t & 0_{2 \times 1} & 1 \end{bmatrix} \end{cases} \quad (7)$$

式中， $K_p, K_i, K_D \in \mathbb{R}^{2 \times 1}$ ； $A \in \mathbb{R}^{2 \times 2}$ ； $C \in \mathbb{R}^{1 \times 2}$ 。误差系统的状态转移矩阵 $A_e \in \mathbb{R}^{5 \times 5}$ 为满秩。 I 为单位矩阵。

为证明估计误差的收敛性， A_e 可以改写为如下形式：

$$\begin{cases} A_e = A_0 - B_0 K C_0 \\ A_0 = \begin{bmatrix} A & 0_{2 \times 2} & 0_{2 \times 1} \\ I_{2 \times 2} & 0_{2 \times 2} & 0_{2 \times 1} \\ C\Delta t & 0_{1 \times 2} & 1 \end{bmatrix} \\ B_0 = [I_{2 \times 2} \ 0_{2 \times 2} \ 0_{1 \times 2}]^T \\ C_0 = \begin{bmatrix} C & 0_{1 \times 2} & 0 \\ 0_{1 \times 2} & 0_{1 \times 2} & 1 \\ C/\Delta t & C/\Delta t & 0 \end{bmatrix} \\ K = [K_p \ K_i \ K_D] \end{cases} \quad (8)$$

式中， K 为待确定的增益矩阵； A_0 、 B_0 、 C_0 为定义的过程

矩阵。

定理1: 若存在 \mathbf{P} 和 $\bar{\mathbf{K}}$ 满足下列的线性不等式, 则误差系统收敛, 其中 \mathbf{P} 和 $\bar{\mathbf{K}}$ 为待定矩阵。

$$\begin{cases} \begin{bmatrix} \mathbf{P} & \mathbf{A}_0 \mathbf{P} - \mathbf{C}_0^T \bar{\mathbf{K}}^T \mathbf{B}_0^T \\ \mathbf{P} \mathbf{A}_0 - \mathbf{B}_0 \bar{\mathbf{K}} \mathbf{C}_0 & \mathbf{P} \end{bmatrix} > 0 \\ \mathbf{P} = \begin{bmatrix} \mathbf{P}_{11} & 0 & 0 \\ 0 & \mathbf{P}_{22} & \mathbf{P}_{23} \\ 0 & \mathbf{P}_{32} & \mathbf{P}_{33} \end{bmatrix} > 0 \\ \bar{\mathbf{K}} = \mathbf{P}_{11} \mathbf{K} \end{cases} \quad (9)$$

证明: 定义李雅普诺夫函数: $\Psi_k = \mathfrak{R}_k^T \mathbf{P} \mathfrak{R}_k$, 李雅普诺夫函数可改写为下式:

$$\Delta \Psi_k = \Psi_{k+1} - \Psi_k = \mathfrak{R}_k^T (\mathbf{A}_e^T \mathbf{P} \mathbf{A}_e - \mathbf{P}) \mathfrak{R}_k \quad (10)$$

若存在矩阵 \mathbf{P} , 使得:

$$\mathbf{A}_e^T \mathbf{P} \mathbf{A}_e - \mathbf{P} < 0 \quad (11)$$

式中, \mathbf{K}_p 、 \mathbf{K}_i 和 \mathbf{K}_d 采用遗传算法确定, 遗传算法的适应度函数为:

$$J = \sqrt{\frac{1}{L} \sum_{k=1}^L \gamma_k^T \gamma_k} \quad (12)$$

式中, J 为适应度函数; L 为优化数据长度。当误差系统渐进稳定, 收敛至平衡点时, 状态向量也收敛至真实值。

3.2. 协同估计方法

融合思想常用于遥感预测和环境感知领域, 通过多个测量信息融合为决策控制提供参考[31]。基于不同老化状态建立的融合模型可用于动力电池全生命周期 SOC 估计。融合模型的核心是基于不同模型的权重计算融合模型的状态。文献[32]采用式 (13) 计算融合状态。

权重值是由端电压残差 (RETV) 统计确定的。 $\boldsymbol{\rho}_{i,k}$ 是第 i 个模型 k 时刻的状态向量。 $\boldsymbol{\ell}_k$ 是 k 时刻的融合状态。本文中 $\boldsymbol{\ell}$ 指的是 SOC 和容量。当 RETV 增加时, SOC 估计的精度降低。

$$\begin{cases} \boldsymbol{\ell}_k = \sum_{i=1}^p \mathcal{G}_{i,k} \boldsymbol{\rho}_{i,k} \\ \sum_{i=1}^p \mathcal{G}_{i,k} = 1 \end{cases} \quad (13)$$

本文采用贝叶斯理论计算融合权重, 假设模型电压跟踪误差服从正态分布, 故第 i 个模型的概率密度函数可由式 (14) 计算得到:

$$f_{Y(k)|\boldsymbol{\theta}_i, Y(k-1)}(Y(k)|\boldsymbol{\theta}_i, Y(k-1)) = \frac{1}{(2\pi)^{\frac{1}{2}} |s_{i,k}|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} \bar{\mathbf{r}}_{i,k}^T s_{i,k} \bar{\mathbf{r}}_{i,k}\right) \quad (14)$$

$$\begin{cases} r_{i,k} = \mathbf{U}t_k - \widehat{\mathbf{U}}t_{i,k} \\ s_{i,k} = \frac{1}{p-1} \sum_{j=k-L_m+1}^k (r_{i,j} - \bar{r}_{i,k})^2 \end{cases} \quad (15)$$

式中, Y 为模型的输出; $\boldsymbol{\theta}$ 为模型参数的向量; $\widehat{\mathbf{U}}t_{i,k}$ 为 k 时刻被观测的第 i 个模型的端电压。 $r_{i,k}$ 为第 i 个模型在 k 时刻的 RETV 的残差, $\bar{r}_{i,k}$ 为第 i 个模型从 j 时刻到 k 时刻的 RETV 的平均残差; $s_{i,k}$ 是第 i 个模型在 k 时刻残差的方差, 与统计窗口长度 L_m 有关。通常 L_m 越大, 对模型跟踪误差的统计就越客观。但较大的 L_m 会降低算法的实时性。本文通过权衡计算时间和 SOC 估计精度优化 L_m 长度 (见下节表 6 中的结果)。残差和方差可以通过式 (15) 计算得到, 若 k 小于 L_m 时, 初始值为 1。

现有的权重计算方法依赖于条件概率, 该概率代表每个模型贡献的权重[32]。条件概率严重限制了权重的实时变化。为此, 本文使用残差的方差改进权重更新:

$$\mathcal{G}_{i,k} = \frac{1}{p-1} \left[1 - \frac{f_{Y(k)|\boldsymbol{\theta}_i, Y(k-1)}(Y(k)|\boldsymbol{\theta}_i, Y(k-1))s_{i,k}}{\sum_{j=1}^p f_{Y(k)|\boldsymbol{\theta}_j, Y(k-1)}(Y(k)|\boldsymbol{\theta}_j, Y(k-1))s_{j,k}} \right] \quad (16)$$

图 7 为多阶段模型融合估计框架。首先实时采样电池电流、电压和温度, 将最后时刻估计的 SOC 输入模型 1~3 中, 基于式 (2) 和式 (3) 计算模型参数; 然后, 将模型参数 (包括欧姆电阻、极化电阻、时间常数和容量) 输入 PIDO 中, 基于 PIDO 的输出计算各模型的状态和电压跟踪误差。最后计算模型 1~3 的权值, 并加权计算 SOC 和容量, 其中 C_{a_i} 是第 i 个模型的容量, 与温度有关, 该方法实现了容量和 SOC 的解耦。最后, 通过式 (13) 计算融合状态。算法 1 对所提出的多阶段模型融合方法框架进行了总结。该方法的主要参数如表 3 所示。

4. 结果和讨论

4.1. SOC 估计验证

在已知初始荷电状态的情况下, 真实容量由静态容量测试确定, 真实 SOC 可以通过安时积分法标定。在不同的循环下验证了 SOC 估计, 初始 SOC 设置为 0.5, 而真实的 SOC 为 1。从图 8、图 9 可以看出, 相比模型 1~3, 融合方法提供的 SOC 是三种模型中最精确的。全生命周期 25 °C 下, 融合算法输出的 SOC 最大误差 (MAXE) 均在 3% 以内, 小于单个模型 1~3 估计的结果, 其中模型 1 在 0 次循环时具有较高的估计精度, 随着电池老化加剧, 模型 1 的 MAXE 增加到 4.8%。模型 2 在 100~480 次循环下具有

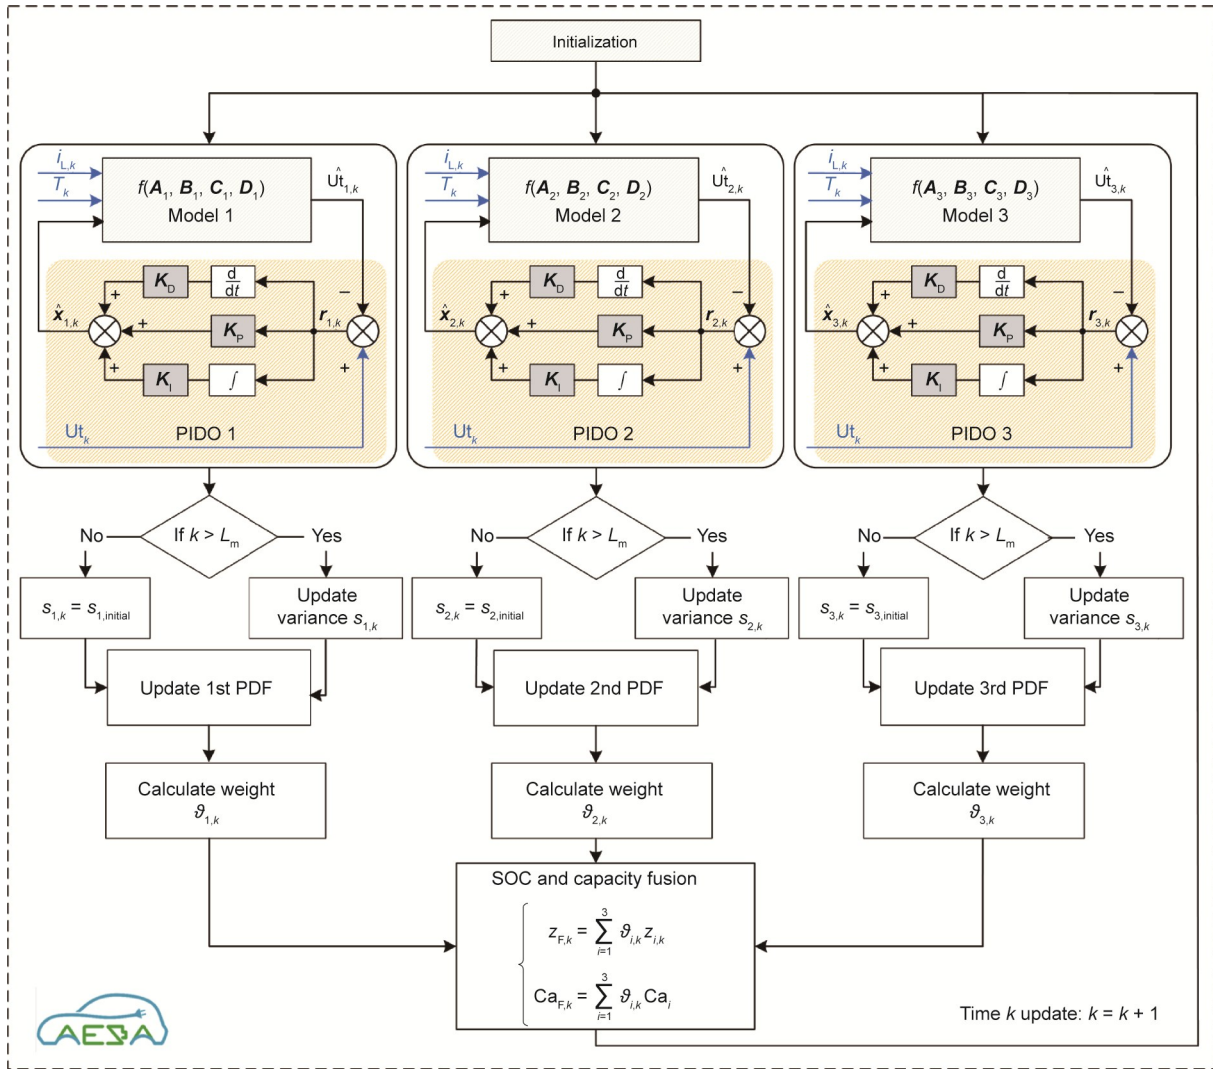


图7. 多阶段模型融合估计框架。Ca_{F,k}: k时刻融合容量; s_{i,initial}: 第i个模型初始方差。

较高的SOC估计精度，但在600次循环下，模型2的MAEX增加到3.6%。模型3在600次循环下具有最高的估计精度。10℃下的验证结果与25℃下的现象相似，测试结果如表4所示。尽管在某些循环区间，融合模型的SOC估计精度低于单一模型，但总体而言融合方法在全生命周期具有更好的SOC估计精度，这是加权融合的主要优点。此外，由于三种模型的观测器参数一致，融合方法的收敛时间与三种单一模型相似。由于窗口长度 L_m 影响算法的复杂度和SOC估计精度，较优的 L_m 值可权衡算法实时性和SOC估计精度。 L_m 值对计算时间和SOC估计精度的量化结果如表5所示。算法仿真平台的配置为Intel Core i7-8550U中央处理器（CPU）1.8 GHz，8 GB随机存取存储器（RAM）笔记本电脑。结果表明：当 L_m 大于600时，SOC精度无显著提高，计算时间显著增加。因此，本文取优化后的 $L_m=500$ 。

4.2. SOC和容量联合估计

4.2.1. 验证1(SOH=0.94)

算法中SOC初值为0.5，初始容量为20 A·h，工况真实SOC为1.0，电池最大可用容量为24.09 A·h。10℃下SOC和容量联合估计结果如图10所示。融合方法估计的SOC的MAXE为1.76%。在测试工况的前100 min内，基于模型1的SOC估计与融合方法具有相似的精度。由于初始容量不准，模型1的SOC估计误差增至3.6%。相比其他两个模型，模型2具有更好的精度，表明当前工况下该动力电池的电压响应特性更接近于模型2的预测特性。但模型2的收敛时间比其他两个模型更长，可达35 min。该工况下，模型3的SOC估计精度最差，表明模型3难以准确跟踪动力电池的电压响应。图10(c)表明融合方法可以准确估计容量，其中容量估计值的平均绝对误差(MAE)为1.48%，RMSE为1.78%。

算法1 多阶段模型融合算法计算流程

Initialization: $\hat{\mathbf{x}}_{1,0}, \hat{\mathbf{x}}_{2,0}, \hat{\mathbf{x}}_{3,0}, \mathbf{K}_p, \mathbf{K}_i, \mathbf{K}_d, \omega_{1,0}, \omega_{2,0}, \omega_{3,0}, s_{1,\text{initial}}, s_{2,\text{initial}}, s_{3,\text{initial}}, L_m$
Computation: for $k = 1, 2, \dots$

- Feedback correction based on PIDO: for $i = 1, 2, 3$
State correction:

$$\hat{\mathbf{x}}_{i,k+1} = \mathbf{A}_i \hat{\mathbf{x}}_k + \mathbf{B}_i i_{L,k} + \mathbf{K}_p e_{i,k} + \mathbf{K}_i \omega_{i,k} + \mathbf{K}_d \frac{e_{i,k} - e_{i,k-1}}{\Delta t}$$
Measurement update: $\widehat{\mathbf{U}}_{i,k} = \mathbf{C}_i \hat{\mathbf{x}}_{i,k} + \mathbf{D}_i i_{L,k}$
Feedback error: $e_{i,k} = \mathbf{U}t_k - \widehat{\mathbf{U}}_{i,k}, r_{i,k} = e_{i,k}$
Error integral: $\omega_{i,k+1} = \omega_{i,k} + e_{i,k} \Delta t$
- Weight update: for $i = 1, 2, 3$
If $k > L_m$
Calculate the variance of the RETV $s_{i,k} = \frac{1}{p-1} \sum_{j=k-L_m+1}^k (r_{i,j} - \bar{r}_{i,k})^2$
Else
Variance not updated: $s_{i,k} = s_{i,\text{initial}}$
End
Calculate the PDF:

$$f_{Y(k)|\theta, Y(k-1)}(Y(k) | \theta, Y(k-1)) = \frac{1}{(2\pi)^{\frac{1}{2}} |s_{i,k}|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} \mathbf{r}_{i,k}^T s_{i,k}^{-1} \mathbf{r}_{i,k}\right)$$
Weight update:

$$\vartheta_{i,k} = \frac{1}{p-1} \left[1 - \frac{f_{Y(k)|\theta, Y(k-1)}(Y(k) | \theta, Y(k-1)) s_{i,k}}{\sum_{j=1}^p f_{Y(k)|\theta, Y(k-1)}(Y(k) | \theta_j, Y(k-1)) s_{i,k}} \right]$$
Results fusion:
SOC estimation: $z_{F,k} = \sum_{i=1}^p \vartheta_{i,k} z_{i,k}$
Capacity estimation: $\text{Ca}_{F,k} = \sum_{i=1}^p \vartheta_{i,k} \text{Ca}_i \sum_{i=1}^p \vartheta_{i,k} \text{Ca}_i$

表3 融合算法参数

Index ($i = 1, 2, 3$)	Value
Initial value of state $\hat{\mathbf{x}}_{i,0}$	[0,0.5] ^T
Integral error $\omega_{i,0}$	0
Proportional gains \mathbf{K}_p	[0.01,0.00095] ^T
Integral gains \mathbf{K}_i	[0.000045,0.000066] ^T
Differential gains \mathbf{K}_d	[0.004,0.005] ^T
Initial value of variance $s_{i,\text{initial}}$	1

图11为25℃下SOC和容量的估计结果,结果表明:融合方法的估计误差与10℃下的结果相似且收敛时间相近。此外,融合方法的SOC估计最大绝对误差(MAXE)为2.1%,RMSE为1.12%,容量估计的MAXE为2.11%,RMSE为2.2%。

4.2.2. 验证2(SOH=0.89)

10℃下SOC和容量估计结果及误差如图12所示。结果表明:在所有模型中,融合方法误差最小,逼近真实SOC,平均误差(MAE)为0.31%,RMSE为0.39%,

MAXE为1.21%;此外,基于融合算法的容量估计误差在3%以内,平均估计误差为1.45%,RMSE为1.59%,最大绝对误差为2.37%。相比模型1~3,融合方法具有更小的SOC估计误差,主要原因是单一模型无法准确预测当前电池的端电压。

图13为25℃下SOC和容量估计结果及误差。融合算法的SOC估计MAE、RMSE和MAXE分别为0.55%、0.74%和1.55%;此外,容量估计的最大误差均在3.3%以内,平均误差为1.19%,RMSE为1.41%,最大绝对误差为3.25%。

4.3. 鲁棒性评估

4.3.1. 收敛性分析

算法的收敛性能在实际应用中尤为重要,尤其是BMS突然受到干扰中断未及时保存计算结果的情况。为了模拟该场景,分别对电池处于不同初始SOC,如1、0.9、0.8、0.7、0.6和0.4(真实初始SOC为0.5)的情况进行测试。其中PIO和PIDO的比例增益 \mathbf{K}_p 和积分增益 \mathbf{K}_i 相同,如表3所示。测试结果如图14所示,结果表明:PIDO可以在5min内快速稳定地收敛至真实值,而PIO需30min才能收敛至真实值。PIDO的收敛速度在中低SOC区间有所降低,但依然优于PIO。因此,PIDO的收敛速度优于PIO,这表明将误差的微分项引入反馈增益中可显著改善算法的收敛速度。

4.3.2. 抗噪性测试

在BMS硬件开发过程中,差分电路的测量精度将决定BMS中单体电压和电流的采样误差,测量精度主要依赖于模数转换器产生的白噪声。其中电压信号中的白噪声主要由模数转换器及差分电路引起;根据霍尔电流传感器的测量原理,电流信号的测量偏差是由元件的零漂移引起的,是一种非零均值的偏置噪声[33]。

为探究电压传感器噪声对融合算法估计精度的影响,将方差0.001~1的白噪声注入电压信号中[34]。SOC和容量的估计误差如图15(a)所示。结果表明:注入方差为0.1的白噪声后,SOC估计的MAE和RMSE分别增加了60%和51%,容量估计的MAE和RMSE分别增加了125%和93%,故电压白噪声对SOC估计误差的影响小于容量估计误差,主要原因是注入白噪声后端电压与真实端电压相差较大,模型1~3难以准确描述,导致融合方法的权重严重失真,因此加权后的容量误差较大。

为分析电流传感器噪声对估计精度的影响,分别向电流信号中注入均值为0.5A、0.2A、0.1A、0.05A、0.005A




图8. 550次循环25 °C下SOC估计结果。(a) SOC估计结果；(b) 估计误差。




图9. 25 °C下不同老化阶段估计结果。(a) 最大估计误差；(b) RMSE。MAXE: 最大估计误差。

表4 10 °C下不同老化阶段估计结果

Cycle	Model 1		Model 2		Model 3		Fusion model	
	MAXE	RMSE	MAXE	RMSE	MAXE	RMSE	MAXE	RMSE
0	0.02160	0.0051	0.0333	0.0180	0.1026	0.0646	0.0420	0.0254
100	0.03570	0.0120	0.0170	0.0056	0.0870	0.0553	0.0227	0.0124
200	0.04430	0.0170	0.0080	0.0018	0.0761	0.0505	0.0146	0.0075
300	0.04220	0.0220	0.0113	0.0062	0.0625	0.0413	0.0099	0.0043
400	0.05090	0.0204	0.0099	0.0042	0.0689	0.0459	0.0106	0.0051
480	0.05596	0.0308	0.0280	0.0176	0.0425	0.0285	0.0328	0.0146
550	0.08460	0.0487	0.0549	0.0344	0.0169	0.0100	0.0491	0.0259
600	0.14320	0.0780	0.1156	0.0709	0.0246	0.0130	0.0874	0.0517

表5 L_m 对实时性和SOC估计误差的影响

Length of L_m	Average calculation time (s)	SOC RMSE
300	1.690	0.00791
400	1.714	0.00772
500	1.732	0.00753
600	1.833	0.00748
700	1.921	0.00742
800	1.922	0.00741
900	1.923	0.00740

的偏置噪声，噪声方差为 $0.01 A^2$ 。SOC和容量的估计误差如图15(b)所示。结果表明：偏置噪声对融合算法的估计精度影响较小，主要原因是该方法以端电压为唯一跟踪目标，电流信号仅用于SOC的先验估计。因此，该方法更依赖于电压测量精度，对电流噪声具有较强的鲁棒性。

4.4. 硬件在环验证

4.4.1. 硬件在环测试平台

为了充分测试融合算法的可应用性，本文基于自主开发的BMS建立了HIL测试平台进行验证测试，测试平台包括BT2000（美国Arbin Instruments）、恒温箱、上位机、电源、电芯、CAN总线分析仪、电池管理系统[35]，如图16所示。电池管理系统由电池监控单元（BMU）和电池控制单元（BCU）组成。BMU用于采集电池电压和温度。BCU用于控制锂离子电池系统的安全性和一致性，并执行SOC、SOH等核心算法。电池管理系统的主要技术参数如表6所示。电池电压由BMU中的LT6804芯片测量，精度约为3 mV。电流传感器采用LEM公司的BMS专用霍尔式电流传感器，型号为CAB-300C，最大测量噪声在0.5 A以内[23]。若干周期后的电池数据用于算法验证。环境温度 $40\text{ }^\circ\text{C}$ ，被测电池实际容量为 $26\text{ A}\cdot\text{h}$ 。

4.4.2. BMS算法测试

在HIL验证前，对融合算法的计算时间进行了讨论，如表7所示[36–37]。结果表明：融合方法的实时性优于联合无迹卡尔曼滤波器。融合算法的Matlab/Simulink模型如图17所示，其中“Voltage,”为BMS实时测量的电压和电流数据，采用Simulink代码工具箱自动生成标准的嵌入式C代码。在集成开发软件中配置算法的输入、输出和执行周期等参数。

输入是单体电压、电流和温度。BMU以100 ms采样




图10. SOC和容量估计结果 (10 °C, SOH=0.94)。 (a) SOC估计结果; (b) SOC估计误差; (c) 容量估计结果。

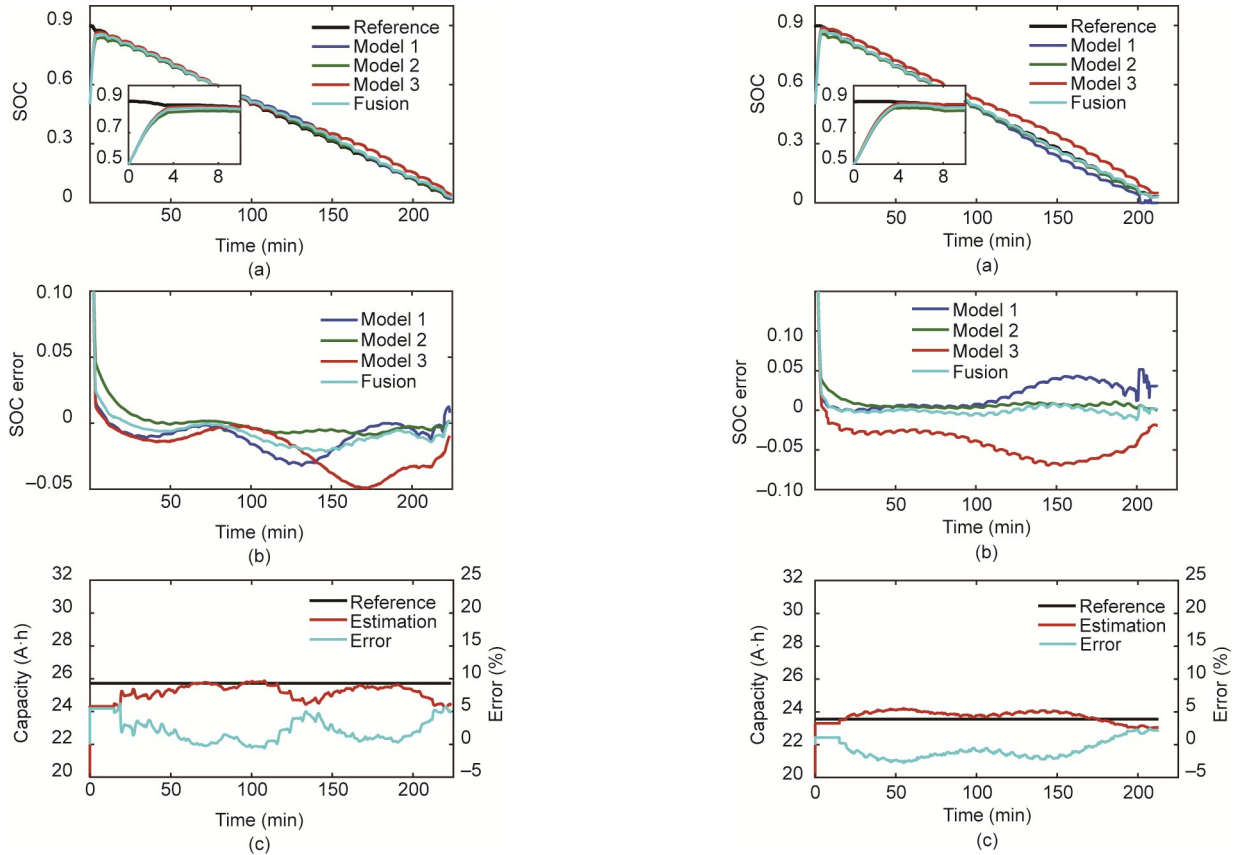


图11. SOC和容量估计结果 (25 °C, SOH = 0.94)。 (a) SOC估计结果; (b) SOC估计误差; (c) 容量估计结果。

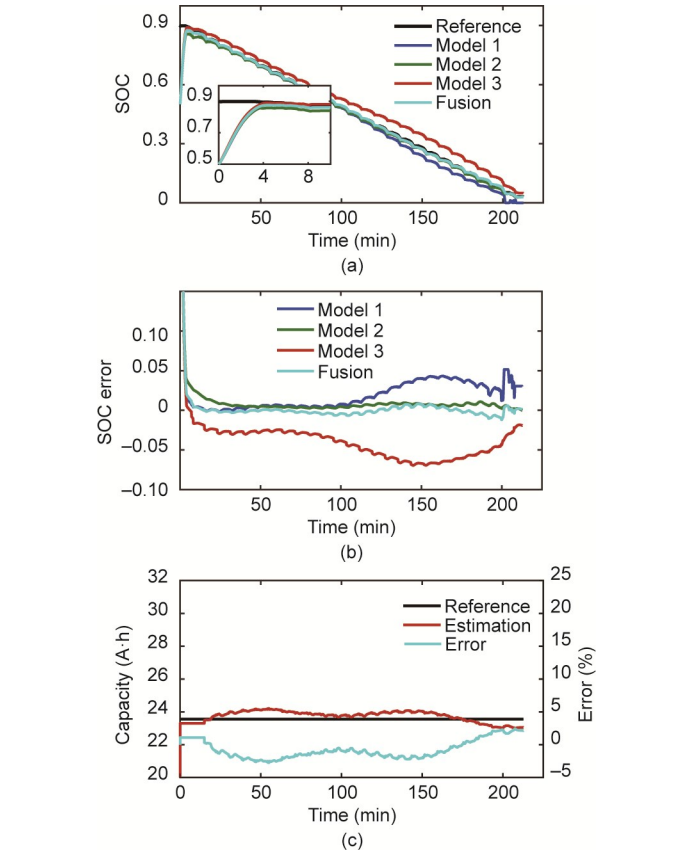


图12. SOC和容量估计结果 (10 °C, SOH = 0.89)。 (a) SOC估计结果; (b) SOC估计误差; (c) 容量估计结果。

周期测量电压和温度, 电流值由CAB300C在100 Hz下测量。输出是估计的SOC和容量。算法执行周期为1 s。此外, 为了计算每个模型的融合权重, 需实时存储各模型的历史RETV。当 L_m 为500时, 微控制器(MCU)需要存储1500个浮点数据, 本文选用了主流的32位MCU, 完全可以满足存储需求。

4.4.3. 结果分析

被测电池的SOC范围为1~0.5。分别开展了两种测试: HIL1用于测试状态估计的精度, HIL2用于验证算法的收敛性。算法中SOC初始值为0.5, 验证结果如图18所示。在HIL1测试中, SOC估计的MAXE为0.88%, 容量

估计的MAXE为3.1%。HIL2测试模拟了BMS突然复位的场景, 即BMS在测试的第76分钟突然复位, 融合算法开始估计SOC和容量, 并在第86分钟收敛于3%的指定误差范围内。

因此, HIL1测试表明融合算法可以准确估计SOC和容量, HIL2测试表明, 当BMS突然复位后, SOC和容量估计结果能够快速稳定地收敛到真实值。该融合算法在应用中的主要特点如下:

(1) 在不同老化水平下, 融合模型参数是SOC和温度的函数, 可以实现模型参数的稳定更新。权重更新方法可保证模型参数具有较好的实时性。

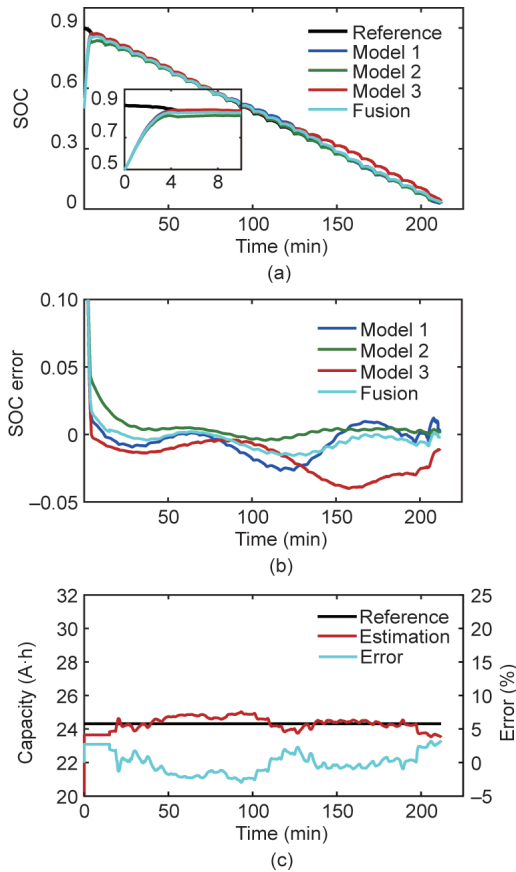


图 13. SOC 和容量估计结果 (25 °C, SOH = 0.89)。(a) SOC 估计结果; (b) SOC 估计误差; (c) 容量估计结果。




图 14. 收敛性表现。(a) SOC 估计结果; (b) SOC 估计误差。PI: 比例积分观测器。

(2) 模型的电压跟踪误差 (RETV) 用于实时计算融合权重。

(3) 该框架实现了 SOC 和容量的解耦估计。由于模

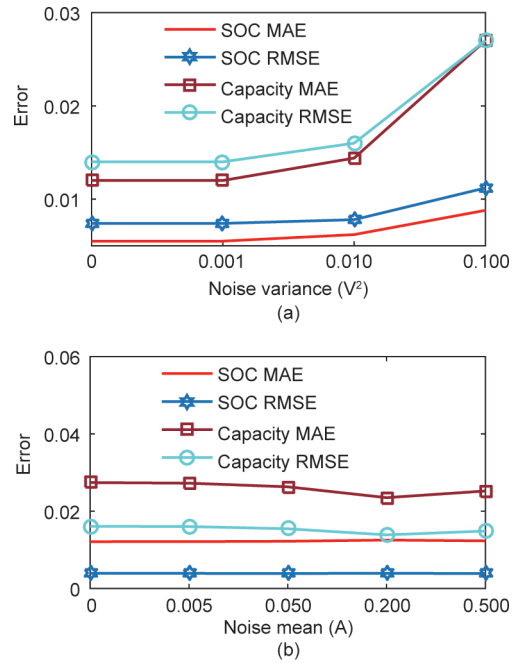


图 15. 抗噪性表现。(a) 抗电压噪声表现; (b) 抗电流噪声表现。

表 6 BMS 主要技术参数

Index	BMU	BCU
Micro-controller unit	MC9S12XS256	MPC5644A
Kernel	16-bit HCS12	32-bit e200z4
Memory	4 Kb RAM, 256Kb flash	192 Kb RAM, 4Mb flash
CAN channel	1	3
Frequency (MHz)	48	150




图 16. 硬件在环验证台架。PC: 个人计算机。

型输入 SOC 是前端融合的结果, 输入容量为老化阶段的最大可用容量, 实现了 SOC 与容量的解耦。

5. 结论

本文提出了一种多阶段老化参数融合驱动模型和 PI-

表7 不同算法计算时间比较[36–37]

Method	Calculation time (s)	Simulation length (s)	Core processor
Muti-scale framework with extended Kalman filter (EKF) [36]	2.210	27 000	Intel Core i5 760 CPU 2.8 GHz and 4 GB RAM
Joint unscented Kalman filter [37]	3.813	8 500	Intel Core i7-6700 CPU 3.4 GHz and 8 GB RAM
Proposed fusion method	1.732	12 714	Intel Core i7-8550U CPU 1.8 GHz and 8 GB RAM

RAM: random access memory.

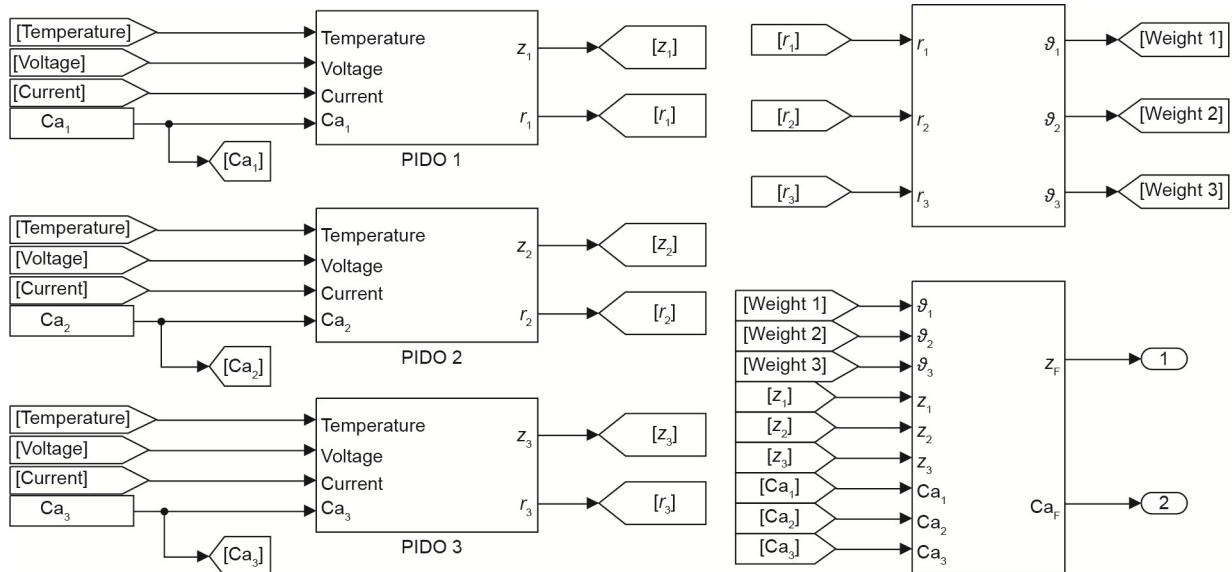


图17. 融合算法的Simulink模型。




图18. 硬件在环验证结果。(a) SOC估计结果；(b) 容量估计结果。

DO新框架，实现了复杂工况下SOC和容量的准确估计。实验和HIL结果验证了该融合算法的有效性。三个主要结论如下：

(1) 采用融合方法辨识参数，可实时获得稳定的模型

参数，克服了RLS算法工况敏感性的不足。与单一模型相比，多级融合模型实现了不同温度和老化状态下更精确的电压预测。在10℃时，预测电压的RMSE值在40 mV以内。

(2) 提出了基于融合模型和PIDO的多状态协同估计框架，实现了宽温度范围内老化电池SOC和容量的准确估计。不同老化状态下，25℃时SOC最大估计误差(MAXE)在3%以内。HIL测试结果表明，该方法能够有效地实现SOC和容量的实时估计，且具有较高的精度，最大SOC估计误差为0.88%，容量估计最大误差为3.1%。

(3) 与PIO相比，本文改进的PIDO能够更好地抑制电流噪声且收敛速度提高6倍。

致谢

本研究得到了国家重点研发计划(2017YFB0103802)和国家自然科学基金(51922006和51707011)的支持。动力电池实验测试由北京理工大学先进储能科学与应用课题组(AESA)支持。

Compliance with ethics guidelines

Rui Xiong, Ju Wang, Weixiang Shen, Jinpeng Tian, and Hao Mu declare that they have no conflict of interest or financial conflicts to disclose.

References

- [1] Xiong R, Ma S, Li H, Sun F, Li J. Towards a safer battery management system: a critical review on diagnosis and prognosis of battery short circuit. *iScience* 2020;23(4):101010.
- [2] Eddahech A, Briat O, Vinassa JM. Determination of lithium-ion battery state-of-health based on constant-voltage charge phase. *J Power Sources* 2014;258:218–27.
- [3] Xiong R, Pan Y, Shen W, Li H, Sun F. Lithium-ion battery aging mechanisms and diagnosis method for automotive applications: recent advances and perspectives. *Renew Sustain Energy Rev* 2020;131:110048.
- [4] Verma MKS, Basu S, Patil RS, Hariharan KS, Adiga SP, Kolake SM, et al. On-board state estimation in electrical vehicles: achieving accuracy and computational efficiency through an electrochemical model. *IEEE Trans Veh Technol* 2020;69(3):2563–75.
- [5] Xiong R, Yang R, Chen Z, Shen W, Sun F. Online fault diagnosis of external short circuit for lithium-ion battery pack. *IEEE Trans Ind Electron* 2020;67(2):1081–91.
- [6] Zheng Y, Ouyang M, Han X, Lu L, Li J. Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles. *J Power Sources* 2018;377:161–88.
- [7] Waag W, Fleischer C, Sauer DU. Critical review of the methods for monitoring of lithium-ion batteries in electric and hybrid vehicles. *J Power Sources* 2014; 258:321–39.
- [8] Wang Y, Gao G, Li X, Chen Z. A fractional-order model-based state estimation approach for lithium-ion battery and ultra-capacitor hybrid power source system considering load trajectory. *J Power Sources* 2020;449:227543.
- [9] Xu J, Mi CC, Cao B, Deng J, Chen Z, Li S. The state of charge estimation of lithium-ion batteries based on a proportional–integral observer. *IEEE Trans Veh Technol* 2014;63(4):1614–21.
- [10] Hu X, Sun F, Zou Y. Estimation of state of charge of a Lithium-Ion battery pack for electric vehicles using an adaptive Luenberger observer. *Energies* 2010;3(9): 1586–603.
- [11] Chen X, Shen W, Cao Z, Kapoor A. A novel approach for state of charge estimation based on adaptive switching gain sliding mode observer in electric vehicles. *J Power Sources* 2014;246:667–78.
- [12] Zhu Q, Li L, Hu X, Xiong N, Hu GD. H_∞ -based nonlinear observer design for state of charge estimation of lithium-ion battery. *IEEE Trans Veh Technol* 2017; 66(12):10853–65.
- [13] Wang Y, Chen Z. A framework for state-of-charge and remaining discharge time prediction using unscented particle filter. *Appl Energy* 2020;260:114324.
- [14] Xu J, Cao B, Cao J, Zou Z, Mi CC, Chen Z. A comparison study of the model based SOC estimation methods for lithium-ion batteries. In: *Proceeding of 2013 IEEE Vehicle Power and Propulsion Conference(VPPC)*; 2013 Oct 15–18; Beijing, China; 2013.
- [15] Hu X, Feng F, Liu K, Zhang L, Xie J, Liu B. State estimation for advanced battery management: key challenges and future trends. *Renew Sustain Energy Rev* 2019;114:109334.
- [16] Xiong R, Li L, Tian J. Towards a smarter battery management system: a critical review on battery state of health monitoring methods. *J Power Sources* 2018; 405:18–29.
- [17] Li Y, Abdel-Monem M, Gopalakrishnan R, Berecibar M, Nanini-Maury E, Omar N, et al. A quick on-line state of health estimation method for Li-ion battery with incremental capacity curves processed by Gaussian filter. *J Power Sources* 2018;373:40–53.
- [18] Wang L, Pan C, Liu L, Cheng Y, Zhao X. On-board state of health estimation of LiFePO₄ battery pack through differential voltage analysis. *Appl Energy* 2016; 168:465–72.
- [19] Bartlett A, Marcicki J, Onori S, Rizzoni G, Yang XG, Miller T. Electrochemical model-based state of charge and capacity estimation for a composite electrode lithium-ion battery. *IEEE Trans Control Syst Technol* 2016;24(2):384–99.
- [20] Xiong R, Tian J, Shen W, Sun F. A novel fractional order model for state of charge estimation in lithium ion batteries. *IEEE Trans Veh Technol* 2019;68(5): 4130–9.
- [21] Pan H, Lü Z, Wang H, Wei H, Chen L. Novel battery state-of-health online estimation method using multiple health indicators and an extreme learning machine. *Energy* 2018;160:466–77.
- [22] Petit M, Prada E, Sauvant-Moynot V. Development of an empirical aging model for Li-ion batteries and application to assess the impact of vehicle-to-grid strategies on battery lifetime. *Appl Energy* 2016;172:398–407.
- [23] Wang J, Xiong R, Li L, Fang Y. A comparative analysis and validation for double-filters-based state of charge estimators using battery-in-the-loop approach. *Appl Energy* 2018;229:648–59.
- [24] Li S, Pischinger S, He C, Liang L, Stapelbroek M. A comparative study of model-based capacity estimation algorithms in dual estimation frameworks for lithium-ion batteries under an accelerated aging test. *Appl Energy* 2018;212: 1522–36.
- [25] Shen P, Ouyang M, Lu L, Li J, Feng X. The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles. *IEEE Trans Veh Technol* 2018;67(1):92–103.
- [26] Tian J, Wang Y, Chen Z. Sensor fault diagnosis for lithium-ion battery packs based on thermal and electrical models. *Int J Electr Power Energy Syst* 2020; 121:106087.
- [27] Yu Q, Xiong R, Yang R, Pecht MG. Online capacity estimation for lithium-ion batteries through joint estimation method. *Appl Energy* 2019;255:113817.
- [28] Wei Z, Zou C, Leng F, Soong BH, Tseng KJ. Online model identification and state-of-charge estimate for lithium-ion battery with a recursive total least squares-based observer. *IEEE Trans Ind Electron* 2017;65(2):1336–46.
- [29] Wang Y, Liu C, Pan R, Chen Z. Modeling and state-of-charge prediction of lithium-ion battery and ultracapacitor hybrids with a co-estimator. *Energy* 2017; 121:739–50.
- [30] Ludovico CS, Bermudez JCM. A recursive least squares algorithm robust to low-power excitation. In: *Proceeding of 2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*; 2004 May 17–21; Montreal, QC, Canada; 2004.
- [31] Li W, Jia Y, Du J, Zhang J. Distributed multiple-model estimation for simultaneous localization and tracking with NLOS mitigation. *IEEE Trans Veh Technol* 2013;62(6):2824–30.
- [32] Lin C, Mu H, Xiong R, Cao J. Multi-model probabilities based state fusion estimation method of lithium-ion battery for electric vehicles: state-of-energy. *Appl Energy* 2017;194:560–8.
- [33] Cheng X, Wang S, Yao L. Li-ion battery pack state-of-charge estimation disturbed by colored noises. *Energy Procedia* 2017;105:4104–9.
- [34] Wei Z, Zhao J, Zou C, Lim TM, Tseng KJ. Comparative study of methods for integrated model identification and state of charge estimation of lithium-ion battery. *J Power Sources* 2018;402:189–97.
- [35] Dai K, Wang J, He H. An improved SOC estimator using time-varying discrete sliding mode observer. *IEEE Access* 2019;7:115463–72.
- [36] Hu C, Youn BD, Chung J. A multiscale framework with extended Kalman filter for lithium-ion battery SOC and capacity estimation. *Appl Energy* 2012;92:694–704.
- [37] Meng J, Boukhniifer M, Diallo D, Wang T. A new cascaded framework for lithium-ion battery state and parameter estimation. *Appl Sci* 2020;10(3):1009.