

DOI: 10.19783/j.cnki.pspc.241735

# 数据缺失下基于变递推间隔修正辅助模型的电池荷电状态估计

毛玲<sup>1</sup>, 赵建辉<sup>1,2</sup>, 林涛<sup>1</sup>, 赵晋斌<sup>3</sup>, 赵书东<sup>4</sup>, 毕俊辉<sup>5</sup>

(1. 上海电力大学电气工程学院, 上海 200090; 2. 上海送变电工程有限公司, 上海 200235; 3. 上海电力大学海上风电研究院, 上海 200090; 4. 重庆长安汽车股份有限公司, 重庆 400023; 5. 中国电子系统工程第四建设有限公司, 河北 石家庄 050081)

**摘要:** 在基于模型的锂离子电池荷电状态(state of charge, SOC)估计中, 传感器采集的数据对 SOC 估计至关重要。在实际应用中, 由于传感器随机故障, 可能导致数据缺失的问题, 将严重影响 SOC 估计的准确性。为了解决这一问题, 提出了一种基于变递推间隔修正辅助模型随机梯度的方法。首先, 引入了正态分布参数模拟传感器随机故障的情况。然后, 在数据缺失下, 通过定义已知数据点的整数序列, 采用基于变递推间隔的方法得到不可观测的数据, 并通过修正辅助模型随机梯度迭代算法补偿未知的信息向量参数。最后, 在参数辨识中引入了收敛指数和遗忘因子以提高参数的收敛速度和精度。实验结果表明, 所提方法在各种工况和不同缺失率下的平均绝对误差在 2.5% 以内, 表现出较强的鲁棒性。

**关键词:** 锂离子电池; 荷电状态; 数据缺失; 随机梯度; 辅助模型

## State of charge estimation of lithium-ion batteries under data loss based on a variable recursive interval correction auxiliary model

MAO Ling<sup>1</sup>, ZHAO Jianhui<sup>1,2</sup>, LIN Tao<sup>1</sup>, ZHAO Jinbin<sup>3</sup>, ZHAO Shudong<sup>4</sup>, BI Junhui<sup>5</sup>

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China; 2. Shanghai Power T&T Engineering Company Co., Ltd., Shanghai 200235, China; 3. Offshore Wind Power Research Institute, Shanghai University of Electric Power, Shanghai 200090, China; 4. Chongqing Changan Automobile Company Limited, Chongqing 400023, China; 5. The Fourth Construction Co., Ltd. of China Electronics System Engineering, Shijiazhuang 050081, China)

**Abstract:** In model-based state of charge (SOC) estimation for lithium-ion batteries, data collected by sensors are crucial for accurate SOC estimation. In practical applications, random sensor failures may lead to data loss, which can seriously affect the accuracy of SOC estimation. To address this problem, a method based on a variable recursive interval correction auxiliary model with stochastic gradient is proposed. First, a normal distribution parameter is introduced to simulate random sensor failures. Second, under conditions of data loss, a sequence of integers representing known data points is defined, and the unobservable data are obtained using a variable recursive interval approach. The unknown information vector parameters are then compensated through a correction auxiliary model stochastic gradient iterative algorithm. Finally, a convergence index and forgetting factor are introduced into parameter identification to improve convergence speed and accuracy. Experimental results show that the proposed method achieves a mean absolute error within 2.5% under various operating conditions and different data loss rates, demonstrating strong robustness.

This work is supported by the Natural Science Foundation of Shanghai (No. 21ZR1425300).

**Key words:** lithium-ion battery; SOC; data loss; stochastic gradient; auxiliary model

## 0 引言

随着温室效应问题的日益加剧, 清洁无污染的

电动汽车近年来被广泛推广<sup>[1-3]</sup>。其中, 锂离子电池凭借其能量密度高、重量轻、记忆效应低、长周期的可靠性以及低自放电率等诸多优势, 广泛应用于新能源汽车、储能系统、精密医疗设备乃至航空航天等领域<sup>[4-7]</sup>。为了确保电池的安全性和可靠性, 需要先

基金项目: 上海市自然科学基金项目资助 (21ZR1425300)

进的电池管理系统(battery management system, BMS)快速、准确地监测电池荷电状态(state of charge, SOC)<sup>[8]</sup>。通过准确估计 SOC, BMS 能够优化充放电控制策略, 从而延长电池的使用寿命<sup>[9]</sup>。但是由于电池电化学反应、充放电机等多方因素的影响, 会导致电池剩余电量呈现非线性。因此, 准确估算电池的 SOC 是 BMS 的研究难点之一。

目前常见的电池 SOC 估算方法包括开路电压法、电化学阻抗谱法、安时积分法、基于数据驱动和基于模型的方法等<sup>[10]</sup>。开路电压法实时性较好, 但开路电压的获取需要将电池长时间的静置<sup>[11]</sup>, 且车辆在实际行驶过程中需频繁启停、加速和减速, 这种方法不适用于电池 SOC 的在线估计。安时积分法因不能考虑当前电池的实际应用环境和状况, 估计精度低, 电流积分过程中存在误差并且需要准确的起始 SOC 否则会导致长期误差累积<sup>[12]</sup>。电化学阻抗谱法的优点是通过测量电池在不同频率下的阻抗响应, 获取丰富的频谱信息, 从而了解电池的内部状态。缺点是电池的阻抗会随着电池的老化而显著变化<sup>[13]</sup>。因此, 仅依据阻抗数据难以精确估计 SOC。

基于数据驱动的方法包括模糊控制器<sup>[14]</sup>、神经网络<sup>[15]</sup>、极限学习机<sup>[16]</sup>等。基于数据驱动的方法能自动学习得到 SOC 与充放电数据之间的关系, 避免了预测方法中存在的初始值难以确定的问题, 预测精度较高。然而, 该方法的应用前提是需要大量准确的历史工况数据和较长周期的模型训练和优化, 在实际应用中很难实现。

基于模型的方法包括等效电路模型(equivalent circuit model, ECM)<sup>[17]</sup>、电化学模型<sup>[18]</sup>及分数阶模型<sup>[19]</sup>等。其中, ECM 由于其高精度、良好的鲁棒性和较低的计算成本, 近年来被学者广泛应用。ECM 常应用于各种滤波技术, 包括卡尔曼滤波器<sup>[20]</sup>、H-∞ 观测器<sup>[21]</sup>、粒子滤波<sup>[22]</sup>等。其中, 卡尔曼滤波在 SOC 估算中表现优异, 对电池初始容量要求不高, 适用于解决线性问题。为了应用于锂离子电池系统非线性系统, 衍生了扩展卡尔曼滤波及其一系列的非线性变体。

总体来说, 上述方法在研究中取得了进展, 但在实际的应用环境中, 仍面临诸多挑战。对于电动汽车来说, 数据在测试到存储的过程中任何一个环节出错都可能导致数据缺失。环境因素、传感器故障<sup>[23]</sup>、网络不稳定以及数据传输中的干扰等因素也都有可能引起数据的缺失。

近年来, 学者们对于数据缺失的处理进行了深入研究, 并提出了众多的解决方案。文献[24]提出了一种插补法, 但该算法只能用于线性系统。然而,

现有的 SOC 研究通常假定传输数据是可得到的, 并且只含有传感器噪声, 而关于数据缺失下的 SOC 研究较少。当出现数据缺失时, 传统的模型方法可能会产生偏差甚至发散的问题。针对此问题, 文献[25]提出了一种抗数据不可用的非线性递归滤波算法。实验结果表明, SOC 值在低 SOC 区域和较高电压电流数据缺失率下精度较低。文献[26]提出了一种单位时延的方法, 在电压数据低缺失率下表现良好。文献[27]将异常数据分为更新停滞和缺失, 并提出了一种异常数据矫正方法, 矫正过后的数据进行 SOC 估计后的误差在 5%左右。

本文在数据随机缺失的情况下提出了一种变递推间隔修正辅助模型随机梯度算法, 能有效降低由数据随机缺失引起的模型参数偏差, 获得了更加精确的 SOC 估计结果。

## 1 锂离子电池建模与 SOC-OCV 测试

ECM 因其计算简单, 物理意义明确等优点被广泛应用于基于模型的电池 SOC 估计。准确的 ECM 是获得电池动态参数的关键, 也是参数辨识的基础。ECM 可分为内阻模型、 $n$  阶 RC 模型等, 一阶 RC 模型因结构简单、计算量适中且实用性较强被广泛应用。本文选择图 1 所示的一阶 RC 等效电路模型模拟电池在充放电过程中的电气特性。

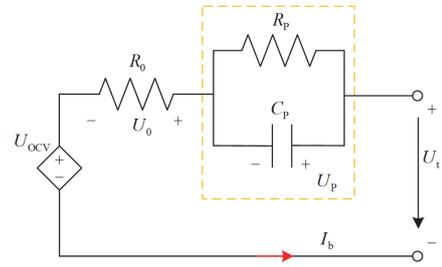


图 1 一阶 RC 等效电路模型

Fig. 1 The first-order RC equivalent circuit model

根据基尔霍夫定律, 电路方程可表示为

$$\begin{cases} I_b = -\frac{U_p}{R_p} + C_p \frac{dU_p}{dt} \\ U_t = U_{OCV} + U_p + I_b R_0 \end{cases} \quad (1)$$

式中:  $I_b$  为输入电流;  $U_p$  为极化电压;  $C_p$  为极化电容;  $R_p$  为极化电阻;  $U_t$  为电池端电压;  $U_{OCV}$  为开路电压;  $R_0$  为欧姆内阻。

将连续时间电路方程转换为离散时间电路方程, 式(1)进行离散化得到式(2)。

$$\begin{cases} U(k) = U_{OCV}(k) + U_p(k) + I_b(k)R_0(k) \\ U_p(k) = e^{-\frac{\Delta t}{R_p C_p}} U_p(k) + (1 - e^{-\frac{\Delta t}{R_p C_p}}) R_p(k) I_b(k) \end{cases} \quad (2)$$

式中： $U(k)$ 为开路电压； $k$ 为时间步长； $\Delta t$ 为相邻两个采样时间的间隔。通过定义 $U(s)=U_t-U_{ocv}$ 和拉普拉斯变换方程，将式(2)转换成频域中的传递函数，可以表示为

$$G(s)=\frac{U(s)}{I_b(s)}=R_0+\frac{R_p}{R_p C_p s+1} \quad (3)$$

式中： $s$ 为拉普拉斯算子。

本文使用双线性变换方法来获得离散系统的传递函数，其变换式为

$$s=\frac{2}{T_s}\cdot\frac{1-z^{-1}}{1+z^{-1}} \quad (4)$$

式中： $z$ 为离散时间系统中的复数频率变量； $T_s$ 为采样时间。

离散传递函数 $G(z)$ 为

$$G(z)=\frac{U(z^{-1})}{I_b(z^{-1})}=\frac{a_2+a_3}{1-a_1z^{-1}} \quad (5)$$

其中

$$\begin{cases} a_1=-\frac{T_s-2R_pC_p}{T_s+2R_pC_p} \\ a_2=-\frac{R_0T_s+R_pT_s+2R_0R_pC_p}{T_s+2R_pC_p} \\ a_3=\frac{R_0T_s+R_pT_s-2R_0R_pC_p}{T_s+2R_pC_p} \\ R_0=T_s\cdot\frac{a_2-a_3}{T_s+a_1}, R_p=2\cdot\frac{a_1a_2+a_3}{a_1^2-1} \\ C_p=\frac{T_s(a_1+1)^2}{-4a_1a_2a_3} \end{cases} \quad (6)$$

式(5)相应的差分方程为

$$U(k)=a_1U(k-1)+a_2I_b(k)+a_3I_b(k-1) \quad (7)$$

得到离散时间系统为

$$y(k)=\boldsymbol{\varphi}(k)\boldsymbol{\theta}(k)^T+v(k) \quad (8)$$

式中： $\boldsymbol{\varphi}(k)$ 为信息向量， $\boldsymbol{\varphi}(k)=[U(k-1) I_b(k) I_b(k-1)]$ ； $\boldsymbol{\theta}(k)$ 为待识别的参数向量， $\boldsymbol{\theta}(k)=[a_1 a_2 a_3]$ ； $v(k)$ 为零均值白色噪声。

模型参数辨识所需的 SOC 与开路电压(open circuit voltage, OCV)的关系曲线是影响 SOC 估计精度的核心因素，可通过 SOC-OCV 测试获取<sup>[29]</sup>。通过多项式拟合实验值，对不同阶次的多项式拟合结果进行比较。相较于低阶的多项式而言，高阶拟合结果更加接近提取值，但是与此同时计算成本也会随之上升，甚至导致过拟合的情况出现。因此，本文采用 8 阶多项式进行 SOC-OCV 曲线拟合，如图 2 所示。

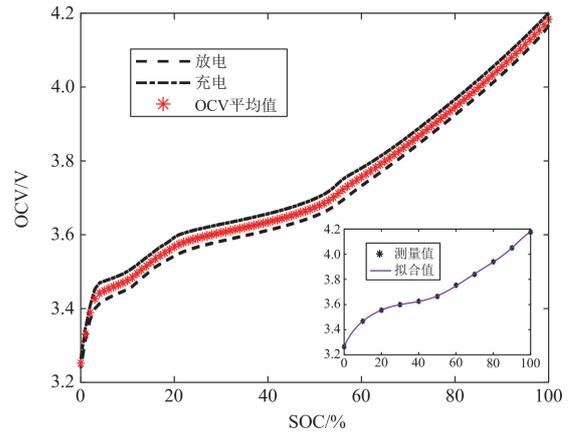


图 2 SOC-OCV 拟合曲线

Fig. 2 SOC-OCV fitting curves

$$U_{ocv}=p_8S_{oc}^8+p_7S_{oc}^7+p_6S_{oc}^6+p_5S_{oc}^5+p_4S_{oc}^4+p_3S_{oc}^3+p_2S_{oc}^2+p_1S_{oc}^1+p_0 \quad (9)$$

式中： $U_{ocv}$ 为开路电压； $p_0-p_8$ 为拟合系数。

## 2 基于 VIM-AM-SG 和 EKF 的 SOC 联合估计框架

### 2.1 数据缺失下基于 VIM-AM-SG 参数辨识方法

对于含有数据缺失的序列，常规随机梯度算法进行参数辨识已完全偏离真实值。为此，提出了变递推间隔修正辅助模型随机梯度(interval-varying modified auxiliary model stochastic gradient, VIM-AM-SG)算法，利用可测变量对辅助模型参数进行辨识，为原系统建立辅助模型，考虑到噪声的影响，实际输出模型如式(10)所示。

$$\begin{cases} y(k)=x(k)+v(k) \\ x(k)=\boldsymbol{\varphi}^T(k)\boldsymbol{\theta}(k) \end{cases} \quad (10)$$

式中： $y(k)$ 为实际测量的系统输出； $x(k)$ 为没有任何干扰的系统输出，由于实际系统中存在噪声干扰，不能直接测量。

假设输入数据 $I(k)$ 可得到，由于数据 $U(k)$ 存在缺失，为了处理缺失的数据，定义可得到数据点的整数序列： $0=k_1 < k_2 < k_3 < \dots < k_{m-1} < k_m$ ，并且 $k=k_m-k_{m-1} \geq 1$ ，因此当 $k=k_m$ 时，可得到观测数据 $y(k)$ 和 $\boldsymbol{\varphi}(k)$ 及缺失数据序列 $\{y(k_m), \boldsymbol{\varphi}(k_m)\}$ ， $m=0,1,2,\dots$ 。

通过在式(10)中用 $k_m$ 替换 $k$ ，得到变递推间隔方法的辨识模型，如式(11)所示。

$$\begin{cases} y(k_m)=u(k_m)+v(k_m) \\ u(k_m)=\boldsymbol{\varphi}^T(k_m)\boldsymbol{\theta}(k_m) \end{cases} \quad (11)$$

信息向量  $\varphi(k_m)$  由已知的  $I_b(k_m)$ 、 $I_b(k_m-1)$  和无噪未知变量  $U(k_m-1)$  构成, 这使得关系式无法递推实现, 因此利用辅助模型辨识思想, 利用系统的可测量信息(包括计算得到的信息)建立辅助模型, 用辅助模型  $U_a(k_m-1)$  代替信息向量  $\varphi(k_m)$  中的未知量  $U(k_m-1)$ , 带辅助模型的输出系统可以表示为

$$u_a(k_m) = \varphi_a^T(k_m) \theta_a(k_m) \quad (12)$$

根据辨识模型, 使用负梯度作为每次迭代的搜索方向, 极小化准则函数  $J(\theta)$  如式(14)所示。

$$J(\theta) = \frac{1}{2} [y(k_m) - \varphi^T(k_m) \theta(k_m)] \quad (13)$$

通过用  $y_a(k)$  代替不可测量的系统输出  $y(k)$ , 解决了信息向量中未知变量的问题, 也有效地降低了噪声干扰。缺失的数据  $\varphi_a(k)$  替换为  $\varphi_a(k_m)$ , 来确定数据的缺失, 可以得到估计输出的 VIM-AM-SG。基于一阶 RC 等效电路模型的 VIM-AM-SG 算法过程如下。

- 1) 初始化:  $\varphi(k)$ 、 $\theta(k)$ 、 $y(k)$ 、 $u_a(k_m)$ 、 $r$ 、 $\lambda$ , 其中  $r$  为收敛因子,  $\lambda$  为迭代变量;
- 2) 信息和参数向量:  $\theta(k) = [a_1 \ a_2 \ a_3]$ 、 $\varphi(k) = [U(k-1) \ I_b(k) \ I_b(k-1)]$ ;
- 3) 计算新息和收敛因子:  $e(k_m) = y(k_m) - \varphi_a^T(k_m) \theta_a(k_{m-1})$ 、 $r(k_m) = \lambda r(k_{m-1}) + \|\varphi_a(k_m)\|^2$ ;
- 4) 模型参数更新:  $\theta_a(k_m) = \theta_a(k_{m-1}) + \frac{\varphi_a(k_m)}{r^\varepsilon(k_m)} e(k_m)$ , 其中  $\varepsilon$  为幂指数,  $\frac{1}{2} < \varepsilon \leq 1$ 。
- 5) 计算辅助模型:  $u_a(k_m) = \varphi_a^T(k_m) \theta_a(k_m)$ 。

基于 VIM-AM-SG 方法的 SOC 估计流程如图 3 所示。将传感器中测量得到的电流数据和模拟的电压缺失数据输入到所建立的系统中, 一阶离散 RC 等效电路模型和变递推间隔辅助模型构造信息和参数向量, 采用 VIM-AM-SG 方法更新各个参数和辅助模型所代替缺失数据部分的参数向量, 并将更新后的各个参数输入到卡尔曼状态和观测方程中去。最后进行 SOC 估计, 同时更新此次过程中的状态方程和估计残差的协方差矩阵。

## 2.2 基于扩展卡尔曼滤波器的 SOC 估计

基于 SG 和扩展卡尔曼滤波器(expanded Kalman filter, EKF)的联合方法广泛应用于各种参数和状态协同估计。EKF 将状态空间引入滤波理论, 用状态方程描述白噪声作用下的线性系统随机信号过程。对于非线性系统, 用泰勒级数展开将非线性状态方程线性化。作为典型的非线性模型, ECM 不能直接应用, 因此本文基于 EKF 算法原理将其转化为近似

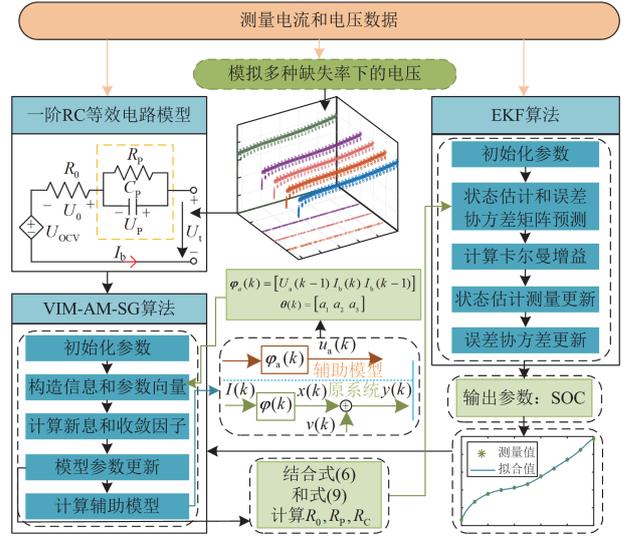


图 3 基于 VIM-AM-SG 参数辨识方法的 SOC 流程图

Fig. 3 SOC flow chart based on VIM-AM-SG parameter identification method

线性滤波问题。锂离子电池非线性系统的状态方程可以表示为

$$\begin{cases} \mathbf{x}_{i+1} = f(\mathbf{x}_i, u_i) + \mathbf{w}_i \\ \mathbf{y}_i = g(\mathbf{x}_i, u_i) + \mathbf{v}_i \end{cases} \quad (14)$$

式中:  $\mathbf{x}_{i+1}$  为状态变量;  $\mathbf{y}_i$  为系统输出变量;  $u_i$  为系统输入变量;  $i$  为采样时间;  $f$ 、 $g$  为系统的非线性函数;  $\mathbf{w}_i$  为独立、零均值的高斯噪声。

系统的线性化模型可以通过使用一阶泰勒级数对系统中的非线性函数进行线性化来获得。

$$\begin{cases} \mathbf{x}_{i+1} = \mathbf{A}_i \mathbf{x}_i + [f(\hat{\mathbf{x}}_i, u_i) - \mathbf{A}_k \hat{\mathbf{x}}_i] + \mathbf{w}_i \\ \mathbf{y}_{i+1} = \mathbf{H}_i \mathbf{x}_i + [g(\hat{\mathbf{x}}_i, u_i) - \mathbf{H}_k \hat{\mathbf{x}}_i] + \mathbf{v}_i \end{cases} \quad (15)$$

式中:  $\mathbf{A}_i$ 、 $\mathbf{H}_i$  分别为状态  $\mathbf{x}_i$  的状态转移雅可比矩阵和测量矩阵, 如式(16)所示。

$$\begin{cases} \mathbf{A}_i = \frac{\partial f[\mathbf{x}_i, u_i]}{\partial \mathbf{x}_i} = \begin{bmatrix} 1 - T_s/R_p C_p & 0 \\ 0 & 1 \end{bmatrix} \\ \mathbf{H}_i = \frac{\partial g[\mathbf{x}_i, u_i]}{\partial \mathbf{x}_i} = \begin{bmatrix} 1 & \frac{\partial U_{oc}}{\partial S_{oc}} \end{bmatrix} \end{cases} \quad (16)$$

通过对蓄电池的充放电电流进行积分, 则 SOC 表达式为

$$S_{oc}(t) = S_{oc}(0) - \frac{\int \eta I_b(t) dt}{C_N} \quad (17)$$

式中:  $S_{oc}(0)$  为 SOC 初值;  $\eta$  为充放电效率;  $C_N$  为标称容量。

从而可以根据图 3 所示的 EKF 算法的递归过程来预测和更新状态。

初始化参数

$$\mathbf{x}_0^+ = E(x_0), \mathbf{p}_0^+ = \text{var}(x_0) \quad (18)$$

式中:  $\mathbf{x}_0^+$  为状态参数的初始化;  $\mathbf{p}_0^+$  为协方差初始化。

状态估计和误差协方差矩阵预测

$$\hat{\mathbf{x}}_i^- = f(\hat{\mathbf{x}}_{i-1}^-, u_{i-1}), \mathbf{p}_{x,i}^- = \mathbf{A}_{i-1} \mathbf{p}_{x,i-1}^- + \mathbf{w}_{i-1} \quad (19)$$

式中:  $\hat{\mathbf{x}}_i^-$  为状态估计的预测值;  $\mathbf{p}_{x,i}^-$  为协方差矩阵的预测值;  $\mathbf{p}_{x,i}^+$  为更新后的协方差矩阵。

计算卡尔曼增益  $K_i$

$$K_i = \mathbf{p}_{x,i}^- \mathbf{H}_i^T (\mathbf{H}_i \mathbf{p}_{x,i}^- \mathbf{H}_i^T + \mathbf{v}_k)^{-1} \quad (20)$$

状态估计和协方差更新

$$\begin{cases} \hat{\mathbf{x}}_i^+ = \hat{\mathbf{x}}_i^- + K_i [y_i - g(\hat{\mathbf{x}}_i^-, u_i)] \\ \mathbf{p}_{x,i}^+ = \mathbf{p}_{x,i}^- - K_i \mathbf{H}_i \mathbf{p}_{x,i}^- \end{cases} \quad (21)$$

式中:  $\hat{\mathbf{x}}_i^+$  为更新后的状态估计。

### 3 实验验证与分析

#### 3.1 测试实验

电池的测试平台由 INR-18650 电池、温控室、NEWARE 测试系统和上位机组成, 电池的具体参数如表 1 所示。其中 NEWARE 测试系统用于促进电池在 DST 条件下的充放电循环。通过上位机运行的 MITS Pro 软件进行电池充放电过程中的电压、电流和温度数据的采集。实验装置用于完成电池的动态实验, 如图 4 所示。

表 1 测试电池的具体参数

Table 1 Specific parameters of test cell

| 标称容量     | 化学成分              | 电压截止上/下限    | 重量   |
|----------|-------------------|-------------|------|
| 2000 mAh | LiNiMnCo/Graphite | 4.2 V/2.5 V | 45 g |

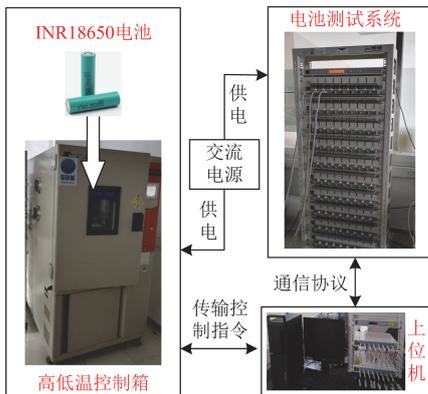


图 4 电池测试平台

Fig. 4 Battery test platform

为深入分析电池在复杂负载条件下的性能, 本文采用了动态应力测试(dynamic stress test, DST)工

况动态工况测试进行实验验证。图 5 为 DST 工况下的电流和电压曲线。

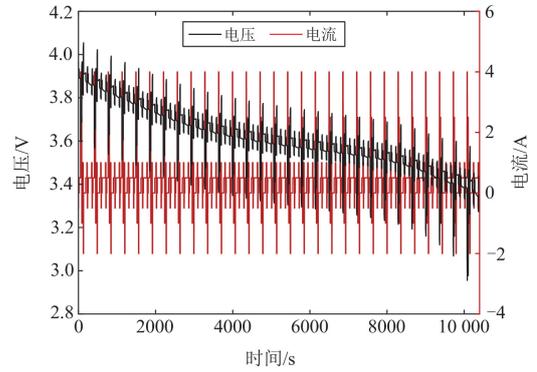


图 5 DST 工况下的电流和电压曲线

Fig. 5 Current and voltage curves under DST

在 DST 工况下, 通过引入正态参数模拟电压数据随机缺失, 通过设置缺失数据比例生成和设定一个阈值, 最终形成具有一定缺失率的数据集。本文将电压截止下限设置为阈值, 低于此阈值的数据点设置为缺失(0 或 NaN)。数据缺失的状态如图 6 所示。其中 Z 轴平面上的点分别表示缺失和可用的数据, 并且数据缺失的情况包括两种: 缺失输出前数据可用和缺失输出前数据缺失(异常)。电压信号同时存在随机单点缺失和连续块缺失。

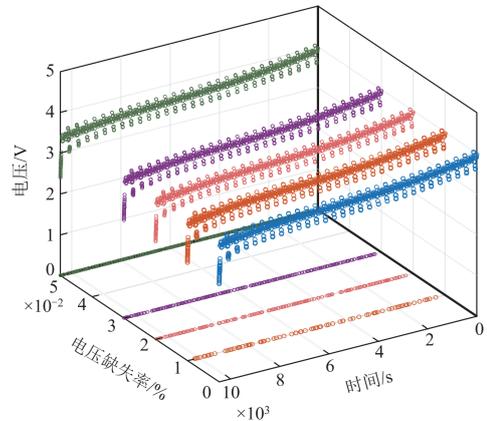


图 6 电压-时间-电压缺失率下的三维图

Fig. 6 Three-dimensional plot of voltage-time-missing rates

#### 3.2 DST 工况下数据缺失的 SOC 估计

实验首先在经典的 DST 工况下, 将完整循环下的电压数据通过引入正态参数模拟随机数据缺失, 并通过控制设置的比例达到不同的缺失率。通过上述建立的模型方法搭建仿真平台得到电池输出电压, 将估计值与在相同操作环境下得到的实验测量值进行比较, 并检查不同数据缺失率(5%、10%、20%和 30%)对模型 SOC 估计精度的影响。

传统的 SOC 方法是 will (stochastic gradient, SG) 和

EKF 相结合。同时, 为了使仿真环境更加接近真实的操作环境, 将原始的电流和电压数据分别添加均值为 0、方差为 1 的噪声, SOC 估计结果如图 7 所示。参考值是在无噪声环境下使用安时积分法获得的具有完整输入输出数据的 SOC 值。在 5% 和 10% 数据缺失率下, 由于缺失值随机分布, 传统 SOC 估计方法和本文所提方法都能在较高 SOC(60%~80%) 范围内跟随在基准值附近, 相比之下所提方法在整个 SOC 范围内都能跟随在基准值附近。但随着时间累积和缺失值的增加, 传统方法在 60% SOC 值以下已完全偏离参考值, 误差最大达到了 13.8%, 已不能精确反应 SOC。AM-SG 算法虽然能跟随参考值附近, 但误差也达到了 4%。与上述两种方法相比, 所提方法拥有较强的鲁棒性, 能更好地跟随在 SOC 附近, 最大误差不超过 1.5%。此外, MAE 和 RMSE 被用来量化评估算法的 SOC 估计性能, SOC 误差定量分析如表 2 所示。可以看出, 本文所提方法的 MAE 在 5%、10%、20% 和 30% 电压缺失率下都低于 SG-EKF 和 AM-SG-EKF。因此, VIM-AM-SG-EKF 方法在不同电压数据缺失率下都能获得良好的 SOC 估计性能。

不同数据缺失率下的 SOC 估计结果如图 8 所示。可以看出, 当数据缺失率增加到 20% 时, 初始 SOC 估计阶段也能跟随参考值, 但随着缺失率的增加, SG-EKF 方法逐渐偏离参考值, 波动较大, 收敛困难, 最大误差达到了 35.2%。相比之下, 本文所提方法在这些情况下仍然收敛到参考值附近。随着数据缺失率的增加, 工况结束时最大误差为 2.1%, 因此所提方法仍保持较高的鲁棒性。

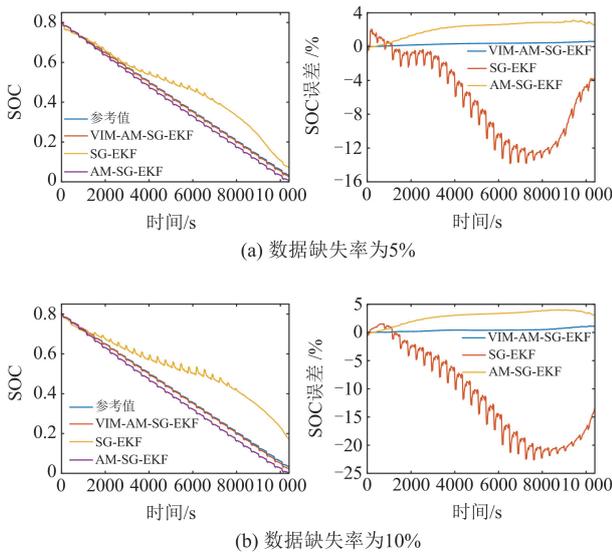
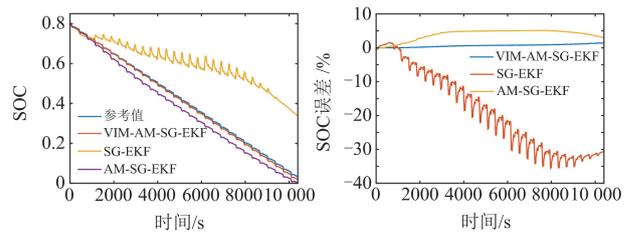


图 7 DST 工况下的 SOC 估计结果

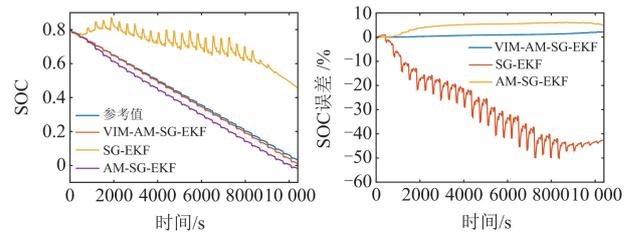
Fig. 7 SOC estimation results under DST

表 2 不同方法下的 SOC 误差分析

| 算法            | 评价指标/% | 电压缺失率/% |        |        |        |
|---------------|--------|---------|--------|--------|--------|
|               |        | 5       | 10     | 20     | 30     |
| SG-EKF        | RMSE   | 0.0774  | 0.1374 | 0.2212 | 0.3223 |
|               | MAE    | 0.0622  | 0.1145 | 0.1883 | 0.2901 |
| AM-SG-EKF     | RMSE   | 0.0233  | 0.0305 | 0.0421 | 0.0495 |
|               | MAE    | 0.0215  | 0.0284 | 0.0392 | 0.0462 |
| VIM-AM-SG-EKF | RMSE   | 0.0103  | 0.0140 | 0.0288 | 0.0268 |
|               | MAE    | 0.0096  | 0.0122 | 0.0188 | 0.0232 |



(a) 数据缺失率增加到 20%



(b) 数据缺失率增加到 30%

图 8 DST 工况下的 SOC 估计结果

Fig. 8 SOC estimation results under DST

### 3.3 不同数据缺失率和多种工况下的 SOC 估计验证

为了进一步验证所提 VIM-AM-SG 方法的性能, 在 3 种不同的工况下进行仿真测试, 包括联邦城市驾驶时间表(federal urban driving schedule, FUDS)、北京动态应力测试(Beijing dynamic stress test, BJDST)和城市交通拥堵与高速公路行驶时间表(urban dynamometer driving schedule, US06), 这是电动汽车测试手册中的典型电池工况<sup>[29]</sup>, 完整的测试曲线如图 9 所示。

为了验证算法的鲁棒性, 分析数据缺失对 SOC 估计的影响, 在相同的工作条件下, 将 3 种工况下的原始测量数据分别设置不同的缺失率(5%、10%、20% 和 30%)。在本文中, 所有估计参数的初始值都是相同的, 并且每种算法的 SOC 估计的准确性都是基于安时积分法获得的参考 SOC 值。所提算法在上述 3 种工况下的 SOC 估计结果及相应的估计误差如图 9 所示, SOC 误差定量分析如表 3 所示。

表 3 3 种工况下的 SOC 误差分析

Table 3 Analysis of SOC error under three conditions

| 不同工况  | 评价指标/% | 数据缺失率/% |       |       |       |
|-------|--------|---------|-------|-------|-------|
|       |        | 5       | 10    | 20    | 30    |
| BJDST | RMSE   | 1.027   | 1.506 | 1.928 | 2.437 |
|       | MAE    | 0.9006  | 1.309 | 1.659 | 2.047 |
| FUDS  | RMSE   | 0.7099  | 1.473 | 1.722 | 2.251 |
|       | MAE    | 0.5962  | 1.306 | 1.523 | 1.994 |
| US06  | RMSE   | 0.9757  | 1.347 | 1.902 | 2.860 |
|       | MAE    | 0.8641  | 1.159 | 1.661 | 2.281 |

从图 9 可以看出, SOC 估计误差会随着数据缺失率的增加而变大, 并且对于确定的缺失误差具有时间累积效应。当电压数据缺失率在 5%~20% 时, 3 种典型工况下估计误差均在 2.5% 以内。当数据缺失率增加到 30% 时, SOC 估计误差在工作条件结束时超过 2.5%, 但低于 3%, 其中在相同数据缺失率下 FUDS 的 SOC 估计误差略低于其他两种工况。因此, 上述验证结果表明, 所提方法仍然可以保持较高的 SOC 估计精度, SOC 误差与电压数据缺失率呈现出一定的正相关性<sup>[30]</sup>。

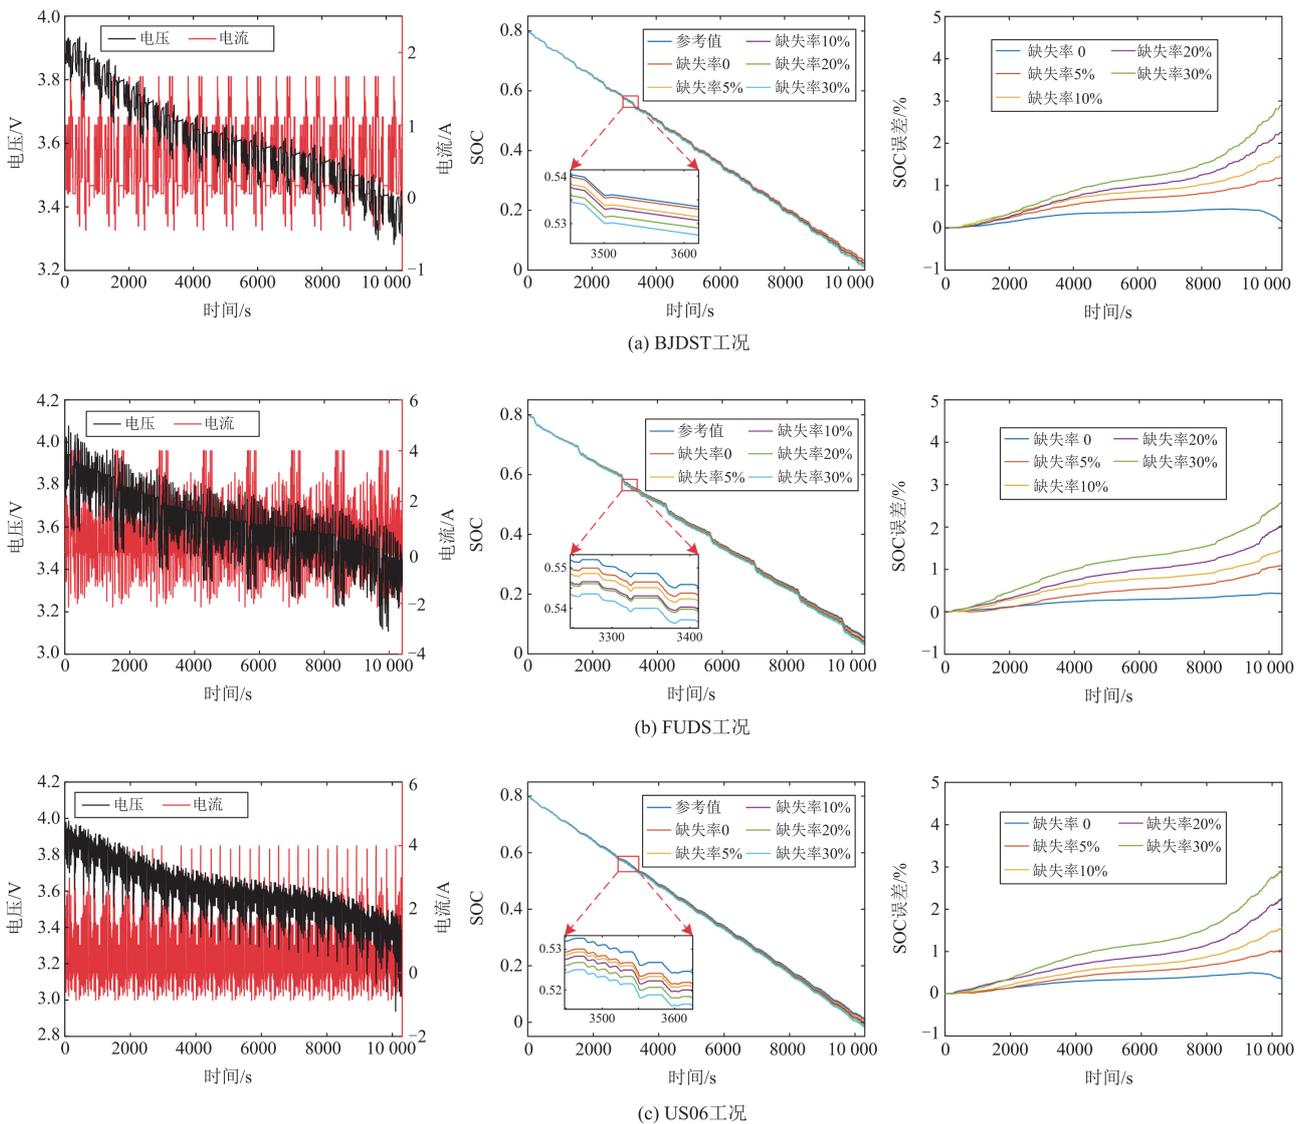


图 9 3 种工况下的 SOC 估计结果和误差

Fig. 9 SOC estimation results and errors under three working conditions

#### 4 结论

在实际的电池核心管理系统中, 面临着复杂多

变的情况, 在数据采集、传输和存储的过程中会出现不同形式的数据缺失。为解决基于 ECM 模型的 SOC 估计在数据缺失下表现较差的问题, 本文提出

了一种基于变递推间隔修正辅助模型随机梯度算法,来处理数据缺失下的状态参数辨识和 SOC 估计问题。该算法利用辅助模型对缺失数据进行电压补偿。其次,结合扩展卡尔曼滤波算法,降低了环境噪声引起的 SOC 估计误差。最后,在 DST 工况下验证了所提方法的可行性,在多种不同数据缺失率下,即使数据缺失率为 30%,所提方法的 RMSE 和 MAE 远小于 SG-EKF 和 AM-SG-EKF,并在多种动态工况下和不同数据缺失率下验证了所提方法的可靠性。该研究为解决电池在数据缺失情况下 SOC 估计误差较大的问题提供了可行的解决方案,有助于 BMS 的改进和优化。

### 参考文献

- [1] 范宏, 李嘉晖, 郭琦. 考虑用户充电决策行为的电动汽车充电引导策略[J]. 电力工程技术, 2023, 42(4): 23-30.  
FAN Hong, LI Jiahui, GUO Qi. Electric vehicle charging guidance strategy considering user charging decision-making behavior[J]. Electric Power Engineering Technology, 2023, 42(4): 23-30.
- [2] 贾俊, 范炜豪, 吕志鹏, 等. 用于电动汽车集群并网的直流变压器启动研究[J]. 发电技术, 2023, 44(6): 875-882.  
JIA Jun, FAN Weihao, LÜ Zhipeng, et al. Research on startup of DC transformer for electric vehicle cluster gridconnection[J]. Power Generation Technology, 2023, 44(6): 875-882.
- [3] 刘又榕, 林顺富, 沈运帷, 等. 计及电动汽车参与多元需求响应的微电网多时间尺度优化调度模型[J]. 电力建设, 2023, 44(10): 51-62.  
LIU Yourong, LIN Shunfu, SHEN Yunwei, et al. Multi-time-scale optimization scheduling model of microgrid with electric vehicles participating in multiple demand response[J]. Electric Power Construction, 2023, 44(10): 51-62.
- [4] QIN Yan, ADAMS S, YUEN C. Transfer learning-based state of charge estimation for lithium-ion battery at varying ambient temperatures[J]. IEEE Transactions on Industrial Informatics, 2021, 17(11): 7304-7315.
- [5] 赵珈卉, 田立亭, 程林. 锂离子电池状态估计与剩余寿命预测方法综述[J]. 发电技术, 2023, 44(1): 1-17.  
ZHAO Jiahui, TIAN Liting, CHENG Lin. Review on state estimation and remaining useful life prediction methods for lithium-ion battery[J]. Power Generation Technology, 2023, 44(1): 1-17.
- [6] 张志行, 韩雪冰, 冯旭宁, 等. 面向不同电流工况的锂离子电池改进 EECM 研究[J]. 电力工程技术, 2023, 42(4): 2-12.  
ZHANG Zhihang, HAN Xuebing, FENG Xuning, et al. Improved EECM for lithium-ion batteries under different current conditions[J]. Electric Power Engineering Technology, 2023, 42(4): 2-12.
- [7] 翟苏巍, 李文云, 周成, 等. 基于改进概率神经网络的储能电池荷电状态估计[J]. 智慧电力, 2024, 52(2): 94-100.  
ZHAI Suwei, LI Wenyun, ZHOU Cheng, et al. State-of-charge estimation of energy storage batteries based on modified probabilistic neural networks[J]. Smart Power, 2024, 52(2): 94-100.
- [8] 孙成虎, 张艳荣, 李涛, 等. 高可靠性电池管理系统设计及 IAP 在线升级[J]. 电源技术, 2024, 48(4): 639-700.  
SUN Chenghu, ZHANG Yanrong, LI Tao, et al. Design of high reliability battery management system and IAP online upgrade[J]. Chinese Journal of Power Sources, 2024, 48(4): 693-700.
- [9] REN Jiahui, MA Jinkai, WANG Honghong, et al. Comprehensive review on research methods for lithium-ion battery of state of health estimation and end of life prediction: methods, properties, and prospects[J]. Protection and Control of Modern Power Systems, 2025, 10(3): 146-165.
- [10] 郑涛, 孟令昆, 强雨泽, 等. 计及 SOC 影响的电化学储能系统低电压穿越控制策略[J]. 电力系统保护与控制, 2024, 52(13): 171-178.  
ZHENG Tao, MENG Lingkun, QIANG Yuze, et al. Low voltage ride-through control strategy for electrochemical energy storage systems taking account of SOC effects[J]. Proceedings of the CSEE, 2024, 52(13): 171-178.
- [11] 李文番, 杨骥, 马海峰, 等. 一种锂电池在线荷电状态估计算法[J]. 西安交通大学学报, 2024, 58(9): 164-172.  
LI Wenfan, YANG Kun, MA Haifeng, et al. An online state of charge estimation algorithm for lithium batteries[J]. Journal of Xi'an Jiaotong University, 2024, 58(9): 164-172.
- [12] CHANG Weien, KUNG Chungchun. An improved AhI method with deep learning networks for state of charge estimation of lithium-ion battery[J]. IEEE Access, 2024, 12: 55465-55473.
- [13] KONG Laiqiang, FANG Sidun, NIU Tao, et al. Fast state of charge estimation for lithium-ion battery based on electrochemical impedance spectroscopy frequency feature extraction[J]. IEEE Transactions on Industry Applications, 2024, 60(1): 1369-1379.
- [14] 廖力, 徐雅雯, 姜久春. 串联锂离子电池组均衡策略研究[J]. 电源技术, 2023, 47(1): 51-56.  
LIAO Li, XU Yawen, JIANG Jiuchun. Research on equalization strategy of series lithium-ion battery pack[J]. Chinese Journal of Power Sources, 2023, 47(1): 51-56.
- [15] 明彤彤, 赵晶, 王晓磊, 等. 基于改进 LSTM 的脉冲大倍率工况下锂电池 SOC 估计[J]. 电力系统保护与控制, 2021, 49(8): 144-150.  
MING Tongtong, ZHAO Jing, WANG Xiaolei, et al.

- SOC estimation of a lithium battery under high pulse rate condition based on improved LSTM[J]. *Power System Protection and Control*, 2021, 49(8): 144-150.
- [16] 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 Ling, WEN Jialin, ZHAO Jinbin, 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.
- [17] 邹国发, 高祥, 王春. 考虑锂电池多时间尺度效应的参数辨识与 SOC 估计方法[J]. *电力系统保护与控制*, 2024, 52(21): 71-80.  
ZOU Guofa, GAO Xiang, WANG Chun. Parameter identification and SOC estimation methods considering multi-timescale effect lithium batteries[J]. *Power System Protection and Control*, 2024, 52(21): 71-80.
- [18] 李清波, 张懋慧, 罗英, 等. 基于等效电路模型融合电化学原理的锂离子电池荷电状态估计[J]. *储能科学与技术*, 2024, 13(9): 3072-3083.  
LI Qingbo, ZHANG Maohui, LUO Ying, et al. Lithium-ion battery state of charge estimation based on equivalent circuit model[J]. *Energy Storage Science and Technology*, 2024, 13(9): 3072-3083.
- [19] 郑轶, 许永红, 张红光, 等. 基于分数阶模型多新息 UKF 动力电池 SOC 估算研究[J]. *电源技术*, 2024, 48(9): 1777-1788.  
ZHENG Yi, XU Yonghong, ZHANG Hongguang, et al. Research on SOC estimation of power battery based on fractional order model multi innovation UKF[J]. *Chinese Journal of Power Sources*, 2024, 48(9): 1777-1788.
- [20] 宋海飞, 王乐红, 原义栋, 等. 基于改进自适应卡尔曼滤波算法的锂离子电池荷电状态估计[J]. *电力系统保护与控制*, 2024, 52(20): 72-82.  
SONG Haifei, WANG Lehong, YUAN Yidong, et al. State of charge estimation of lithium-ion batteries based on improved adaptive Kalman filter algorithm[J]. *Power System Protection and Control*, 2024, 52(20): 72-82.
- [21] 刘芳, 余丹, 苏卫星, 等. 基于 AR-ECM 平均差异模型的串联电池组 SOC、容量多尺度联合估计方法[J]. *中国电机工程学报*, 2024, 44(10): 3937-3949.  
LIU Fang, YU Dan, SU Weixing, et al. Multi-scale joint estimation of SOC and capacity of series battery pack based on AR-ECM mean-difference model[J]. *Proceedings of the CSEE*, 2024, 44(10): 3937-3949.
- [22] YE Min, GUO Hui, XIONG Rui, et al. A double-scale and adaptive particle filter-based online parameter and state of charge estimation method for lithium-ion batteries[J]. *Energy*, 2018, 144: 789-799.
- [23] XIONG Rui, SUN Wanzhou, YU Quanqing, et al. Challenges and prospects of fault diagnosis on battery system of electric vehicles[J]. *Applied Energy*, 2020, 279.
- [24] MUKHOPADHYAY S, MUKHERJEE A. ImdLMS: an imputation based LMS algorithm for linear system identification with missing input data[J]. *IEEE Transactions on Signal Processing*, 2020, 68: 2370-2385.
- [25] CHEN Hui, TIAN Engang, WANG Licheng. State-of-charge estimation of lithium-ion batteries subject to random sensor data unavailability: a recursive filtering approach[J]. *IEEE Transactions on Industrial Electronics*, 2022, 69(5): 5175-5184.
- [26] JIE Hou, LIU Jiawei, CHEN Fengwei, et al. Robust lithium-ion state-of-charge and battery parameters joint estimation based on an enhanced adaptive unscented Kalman filter[J]. *Energy*, 2023, 271.
- [27] 欧阳天成, 徐裴行, 叶今禄, 等. 数据采集异常下的车用动力电池状态监测与故障诊断[J]. *中国电机工程学报*, 2023, 43(15): 6040-6050.  
OUYANG Tiancheng, XU Peihang, YE Jinlu, et al. States monitoring and fault diagnosis of vehicular power batteries under abnormal data acquisition[J]. *Proceedings of the CSEE*, 2023, 43(15): 6040-6050.
- [28] 朱卫平, 陈国旺, 卫志农, 等. 基于 VFFRLS 算法的锂电池参数辨识[J]. *电力工程技术*, 2023, 42(1): 226-233.  
ZHU Weiping, CHEN Guowang, WEI Zhinong, et al. Parameter identification of lithium-ion battery based on least squares algorithm with variable forgetting factor[J]. *Electric Power Engineering Technology*, 2023, 42(1): 226-233.
- [29] ZHENG Fangdan, XING Yinjiao, JIANG Jiuchun, et al. Influence of different open circuit voltage tests on state of charge online estimation for lithium-ion batteries[J]. *Applied Energy*, 2016, 183: 513-525.
- [30] WANG Juntao, SONG Jifeng, LI Yuanlong, et al. State of charge estimation for lithium-ion battery based on improved online parameters identification and adaptive square root unscented Kalman filter[J]. *Journal of Energy Storage*, 2024, 77.

收稿日期: 2024-12-25; 修回日期: 2025-07-04

作者简介:

毛玲(1981—), 女, 博士, 副教授, 主要研究方向为电动汽车有序充电、动力电池建模、状态估计及电动汽车与电网的互动等; E-mail: maoling2290@shiep.edu.cn

赵建辉(1998—), 男, 硕士研究生, 主要研究方向为锂离子电池荷电状态估计; E-mail: zjh1998@shiep.edu.cn

赵晋斌(1972—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为现代电力电子技术在电力系统中的应用和新能源发电技术。E-mail: zhaojinbin@shiep.edu.cn

(编辑 张颖)