



基于ELM和MCCKF的锂离子电池SOC估计

王桥 叶敏 魏孟 廉高荣 武晨光

ELM- and MCCKF-based state of charge estimation for lithium-ion batteries

WANG Qiao, YE Min, WEI Meng, LIAN Gao-qi, WU Chen-guang

引用本文:

王桥, 叶敏, 魏孟, 廉高荣, 武晨光. 基于ELM和MCCKF的锂离子电池SOC估计[J]. *工程科学学报*, 2023, 45(6): 995–1002. doi: 10.13374/j.issn2095-9389.2022.05.10.003

WANG Qiao, YE Min, WEI Meng, LIAN Gao-qi, WU Chen-guang. ELM- and MCCKF-based state of charge estimation for lithium-ion batteries[J]. *Chinese Journal of Engineering*, 2023, 45(6): 995–1002. doi: 10.13374/j.issn2095-9389.2022.05.10.003

在线阅读 View online: <https://doi.org/10.13374/j.issn2095-9389.2022.05.10.003>

您可能感兴趣的其他文章

Articles you may be interested in

基于融合模型的锂离子电池荷电状态在线估计

Online estimation of the state of charge of a lithium-ion battery based on the fusion model

工程科学学报. 2020, 42(9): 1200 <https://doi.org/10.13374/j.issn2095-9389.2019.09.20.001>

基于鲁棒 H_∞ 滤波的锂离子电池SOC估计

Lithium-ion battery state of charge estimation based on a robust H_∞ filter

工程科学学报. 2021, 43(5): 693 <https://doi.org/10.13374/j.issn2095-9389.2020.09.21.002>

基于快速SR-UKF的锂离子动力电池SOC联合估计

Real-time SOC co-estimation algorithm for Li-ion batteries based on fast square-root unscented Kalman filters

工程科学学报. 2021, 43(7): 976 <https://doi.org/10.13374/j.issn2095-9389.2020.07.30.002>

锂离子电池安全性研究进展

Research progress on safety of lithium-ion batteries

工程科学学报. 2018, 40(8): 901 <https://doi.org/10.13374/j.issn2095-9389.2018.08.002>

无烟煤制备高性能锂离子电池负极材料的研究

High-performance anode materials based on anthracite for lithium-ion battery applications

工程科学学报. 2020, 42(7): 884 <https://doi.org/10.13374/j.issn2095-9389.2019.07.11.005>

基于CEEMDANLSTM组合的锂离子电池寿命预测方法

Combined prediction method of lithium-ion battery life based on CEEMDANLSTM

工程科学学报. 2021, 43(7): 985 <https://doi.org/10.13374/j.issn2095-9389.2020.06.30.007>

基于 ELM 和 MCSCKF 的锂离子电池 SOC 估计

王 桥¹⁾, 叶 敏¹⁾✉, 魏 孟^{1,2)}, 廉高荣¹⁾, 武晨光¹⁾

1) 长安大学公路养护装备国家工程研究中心, 西安 710064 2) 新加坡国立大学机械工程系, 新加坡 117576

✉通信作者, E-mail: mingye@chd.edu.cn

摘 要 为了减少噪声对锂离子电池荷电状态估计的影响, 本文提出一种新颖的基于极限学习机和最大相关熵平方根容积卡尔曼滤波的 SOC 估计方法。首先, 利用泛化性好、运行速度快的极限学习机作为卡尔曼滤波的测量方程; 其次, 基于灰狼优化算法, 极限学习机的超参数被优化以提高电池荷电状态的估计精度; 最后, 基于最大相关熵平方根容积卡尔曼滤波, 极限学习机的测量噪声被进一步减弱。所提方法可以简化极限学习机繁琐的调参过程, 且为闭环的 SOC 估计方法。所提方法在多工况和宽温度范围内被测试以验证其泛化性能。测试结果显示, 所提方法明显地提高了锂离子电池的荷电状态估计精度。同时, 对比其他算法, 所提方法的平均运行时间仅仅为长短时序列和循环门控单元网络的三分之一。当行驶工况复杂、温度变化区间较大时, 所提方法的均方根误差小于 1%, 最大误差小于 3%。当存在初始误差与环境噪声时, 所提方法显示出了优越的鲁棒性。

关键词 锂离子电池; 荷电状态估计; 极限学习机; 灰狼优化; 卡尔曼滤波; 鲁棒性估计

分类号 TM911.3

ELM- and MCSCKF-based state of charge estimation for lithium-ion batteries

WANG Qiao¹⁾, YE Min¹⁾✉, WEI Meng^{1,2)}, LIAN Gao-q¹⁾, WU Chen-guang¹⁾

1) National Engineering Research Center for Highway Maintenance Equipment, Chang'an University, Xi'an 710064, China

2) Department of Mechanical Engineering, National University of Singapore, Singapore 117576, Singapore

✉ Corresponding author, E-mail: mingye@chd.edu.cn

ABSTRACT Lithium-ion batteries are widely used in electric vehicles and energy storage systems. As a prerequisite for the safe and efficient application of lithium-ion batteries, battery management systems have received extensive attention worldwide. Among these prerequisites, the state of charge (SOC), as the basic parameter of battery management system online application, is crucial for the safe and efficient operation of battery management systems. However, measurement noise decreases the accuracy and robustness of the state of charge estimation. To reduce the impact of noise on the state of charge estimation of lithium-ion batteries, a novel SOC estimation method based on an extreme learning machine and a maximum correlation entropy square root volumetric Kalman filter is proposed in this paper. First, the extreme learning machine is used as the measurement equations of the Kalman filter because of its good generalization and fast running speed, and the voltage and current are selected as the model input; second, on the basis of the gray wolf optimization algorithm, the extreme learning machine hyperparameters are thoroughly optimized to improve the accuracy of the state of charge estimation for lithium-ion batteries; finally, on the basis of the framework of the maximum correlation entropy square root volumetric Kalman filter, a closed-loop estimation is realized to further reduce the state of charge estimation error caused by the measurement noise of voltage and current. The proposed method can simplify the time-consuming parameter adjustment of an extreme learning machine and show superior robustness under low-quality measurement. The proposed method is validated under multiple drive cycles and a wide temperature range to verify its generalization performance. The test results show that the proposed method

收稿日期: 2022-05-10

基金项目: 陕西省科技创新团队(2020TD0012); 中央高校基本科研业务费专项资金-长安大学优秀博士学位论文培育资助项目(300102252710); 陕西省重点研发计划资助项目(2023-GHYB-05)

substantially improves the accuracy of lithium-ion battery state of charge estimation. At the same time, the average running time of the proposed method is only one-third of that of long short memory neural networks and gate recurrent unit neural networks. Under complex driving conditions and a large temperature range, the root mean square error of the proposed method is less than 1%, and the maximum error is less than 3%. Furthermore, two case experiments are performed to evaluate the robustness of the proposed closed-loop estimation approach, and the results obtained when data have an initial state of charge error and measurement noise verify the superior robustness of the proposed approach compared with long short memory neural networks and gate recurrent unit neural networks.

KEY WORDS lithium-ion battery; state of charge; extreme learning machine; grey wolf optimizer; Kalman filter; closed-loop estimation

在全球化石能源枯竭与环境污染加剧的国际背景下, 电动车辆(Electrified vehicle, xEV)市场展示出了广阔的前景^[1]. 动力电池作为新能源车辆的动力来源及储能元件, 需要先进的电池管理系统(Battery management system, BMS)以确保其工作的安全性与高效性. 荷电状态估计(State of charge, SOC)作为 BMS 最重要的参数之一, 是均衡管理、充电控制和里程预测等其他模块高效运作的前提. 因此, 精确的 SOC 估计具有重要的意义^[2-3].

当前, 锂离子电池的 SOC 估计方法主要分为四大类, 包括: 安时积分法(Ampere hour integral, AHI)、开路电压法(Open circuit voltage, OCV)、基于模型的方法(Model based method)和数据驱动法(Data based method)^[4]. 安时积分法通过对电流进行积分来计算 SOC, 具有简单且易于应用的特点^[5]. 但安时积分法的 SOC 估计精度较低, 其准确性严重受限于初始 SOC 值和电流传感器的精度. OCV 与电池 SOC 具有较高的相关性, 因此可以通过对 OCV 与 SOC 进行点对点的标定来实现锂离子电池 SOC 的估计. 但开路电压的获取通常需要很长时间, 不能实现在线应用^[6]. 同时, OCV 对温度较为敏感. 因此, 当环境温度发生变化时, OCV-SOC 曲线会出现偏移. 基于模型的方法所采用的模型主要包括: 电化学模型、分数阶模型和等效电路模型. 此方法通常与卡尔曼滤波联合实现 SOC 的闭环估计^[7]. 由于卡尔曼滤波只能应用于线性系统, 一些非线性卡尔曼滤波被提出并应用于 SOC 估计, 包括: 扩展卡尔曼滤波(Extended Kalman filter, EKF), 无迹卡尔曼滤波(Unscented Kalman filter, UKF)和容积卡尔曼滤波(Cubature Kalman filter, CKF)^[8-11]. 基于模型方法的 SOC 估计精度主要依赖于精确的电池建模. 但由于电池内部动态特性的复杂性和运行环境的多样性, 精确的电池建模难以有效实现. 同时, 基于模型的方法的泛化性有限, 当环境温度与行驶工况发生变化时, 其精度会出现一定的波动. 基于大数据的快速发展, 数据驱动法受到

了越来越多的关注. 据统计, 车辆每天可以产生大于 4 TB 的数据量^[12-14]. 同时, 近年来出现了大量的车辆大数据平台. 大数据平台与新能源车辆大数据的协同闭环发展, 有利于数据驱动方法的快速发展. 基于数据驱动的 SOC 估计方法主要包括: 高斯过程回归(Gaussian process regression, GPR)、循环神经网络(Recurrent neural network, RNN)和非循环神经网络. GPR 是一种常见的 SOC 估计方法, GPR 可直接得到预测结果的不确定性, 且通过最大边缘化的方式可以在节省算力的同时输出良好的正则化结果^[15]. 但 GPR 为非参数模型, 单次的计算均涉及所有的数据点. 因此, 当数据量较大时, GPR 的计算效率低下^[16]. 循环神经网络包括: 长短时记忆(Long short term memory, LSTM)和循环门控单元(Gated recurrent unit, GRU)已经被广泛的应用于序列处理问题, 且取得了不错的效果. LSTM 和 GRU 通过复杂的门控单元, 实现了如同电路一般的复杂结构, 可以实现长时间维度的数据记忆^[17-18]. 但 RNN 的训练通常需要较长时间. 当迭代次数超过 300 次时, 基于 CPU 的 RNN 训练通常需要 3000 s 以上, 且随着训练数据量的增大, 其训练时间会指数式的上升. 对比 RNN, 非循环神经网络的训练效率更高. 其中, 极限学习机(Extreme learning machine, ELM)随机产生输入层与隐含层间的连接权值及隐含层神经元的阈值, 且在训练过程中无需调整, 只需要设置隐含层神经元的个数, 便可以获得最优解. 因此, ELM 具有学习速度快、泛化性能好等优点^[19]. 但基于简单的单层 ELM 难以保证锂离子电池 SOC 估计的高精确性^[20-21]. 因此, 本文提出一种基于极限学习机和最大相关熵平方根容积卡尔曼滤波(Maximum correntropy square-root cubature Kalman filter, MCCKF)的 SOC 估计方法. 基于 MCCKF 方法, ELM 被设定为电池 SOC 的测量方程, 安时积分方程被设定为电池 SOC 的状态方程. 基于 MCCKF, 大大减少了 ELM 的 SOC 估计误差, 实现了精确的 SOC 估计. 同时为进一步减少

ELM 的测量误差, 本文提出利用灰狼优化(Grey wolf optimizer, GWO)对 ELM 的训练参数进行优化^[22]. 最后, 所提方法在多工况和宽温度范围内被测试以验证其泛化性能. 通过与 LSTM 和 GRU 进行多维度的对比, 验证了所提方法的优越性.

1 极限学习机

极限学习机在 2004 年由南洋理工大学提出, 以改进反向传播算法(Back propagation, BP)、提升学习效率并简化学习参数^[18]. 该算法随机产生输入层与隐含层间的连接权值及隐含层神经元的阈值, 具有学习速度快、泛化性能好等优点. ELM 的结构如图 1 所示, 是一种单隐含层前馈神经网络, 由输入层、隐含层和输出层组成, 输入层与隐含层、隐含层与输出层神经元间全连接. 温度数据与 SOC 的相关性较低^[23], 而电流电压作为直接可测得的电池外部信息, 不仅易于获得, 而且与 SOC 的相关性较高. 因此, 本文直接将电流电压数据作为 ELM 的输入, SOC 作为 ELM 的输出.

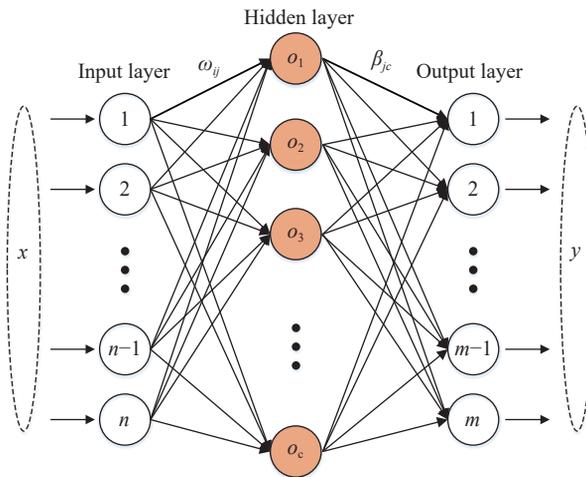


图 1 极限学习机拓扑结构

Fig.1 Topology of an extreme learning machine

假设有任意样本 $(\mathbf{x}_j, \mathbf{t}_j)$, 其中, $\mathbf{x}_j = [x_{j1}, x_{j2}, \dots, x_{jn}]^T$, $\mathbf{t}_j = [t_{j1}, t_{j2}, \dots, t_{jm}]^T$, 则含有 L 个隐含节点的单隐含层神经网络可表示为:

$$\sum_{i=1}^L \beta_i g(\omega_i \cdot \mathbf{x}_j + \mathbf{b}_i) = \mathbf{o}_j, j = 1, 2, \dots, N \quad (1)$$

其中, $g(x)$ 为激活函数, $\omega_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{in}]^T$ 是第 i 个隐含层单元的输入权重, \mathbf{b}_i 是第 i 个隐含层单元的偏置, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 是第 i 个隐含层单元的输出权重.

ELM 的目标是使得输入值的误差最小, 可表示为:

$$\mathbf{x} \sum_{j=1}^N \|\mathbf{o}_j - \mathbf{t}_j\| = 0 \quad (2)$$

即存在对应的 ω_i 、 \mathbf{x}_j 和 \mathbf{b}_i , 使得:

$$\sum_{i=1}^L \beta_i g(\omega_i \cdot \mathbf{x}_j + \mathbf{b}_i) = \mathbf{t}_j, j = 1, 2, \dots, N \quad (3)$$

并可用矩阵表示为:

$$\mathbf{H} \cdot \boldsymbol{\beta} = \mathbf{T} \quad (4)$$

其中, \mathbf{H} 是隐含层节点的输出, $\boldsymbol{\beta}$ 为输出权重, \mathbf{T} 为期望输出值.

2 最大相关熵平方根容积卡尔曼滤波

本文选用的卡尔曼滤波是容积卡尔曼滤波(CKF)的改进版本, 即最大相关熵平方根容积卡尔曼滤波(MCCKF). 为了提高 SCKF 在处理非高斯噪声方面的性能, 提出了 MCCKF, 其详细流程见文献 [11]. 最大相关熵准则用于替代传统的最小均方误差准则, 以提高 CKF 的鲁棒性. 改进后的版本在处理高斯噪声时不仅保留了 SCKF 的优势, 而且在处理非高斯噪声时表现出很强的鲁棒性. MCCKF 的主要流程如表 1 所示.

表 1 MCCKF 主要流程

Table 1 Main procedure of MCCKF

Main procedure of MCCKF

Step 1: Set the initial value and the corresponding square root covariance matrix and set $t=1$.

Step 2: Calculate the cubature points and propagation cubature points of the state equation.

Step 3: Calculate the prior estimate and square the root covariance.

Step 4: Evaluate the cubature points and the propagation cubature points of the measurement equation.

Step 5: Define the square root covariance matrix of the updated measurement value with MCC, calculate the average value of the prior measurement, and get the updated square root covariance matrix.

Step 6: Compare the matrix transformation of the measured value with the threshold: If it is greater than the threshold, return to step 2; otherwise, go to the next step.

Step 7: Calculate the posterior state estimate and the corresponding square root covariance matrix, $t=t+1$ and return to step 2.

图 2 显示了本文的闭环 SOC 估计示意图. 基于闭环估计可以保证 SOC 估计在实际条件下的鲁棒性. 本文的 SOC 闭环估计基于 MCSCKF 滤波框架, 利用 GWO-ELM 对 SOC 估计建模, 并作为滤波

的测量方程, 按时积分法作为状态方程. 其中, GWO-ELM 的输入为电流与电压, 输出为 SOC, 按时积分方程的输入为电流, 输出为 SOC.

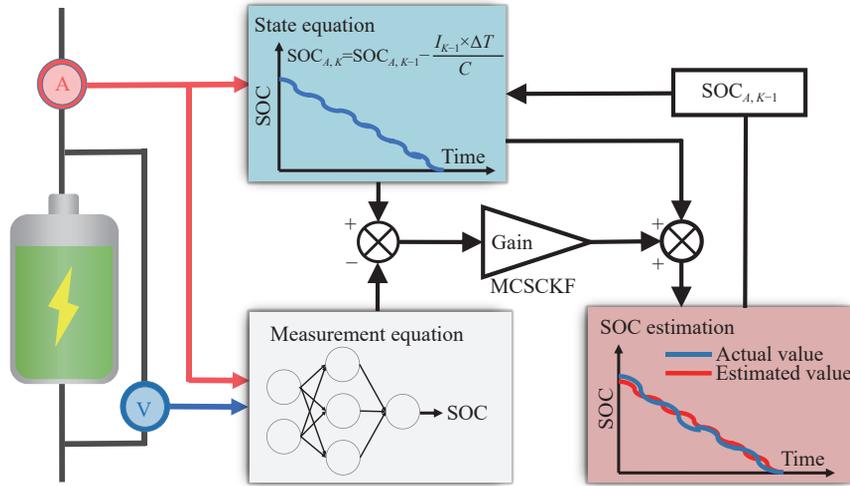


图 2 基于 MCSCKF 的 SOC 闭环估计

Fig.2 Closed-loop SOC estimation realized by MCSCKF

参考文献 [23], 温度数据与 SOC 的相关性较低. 因此本文仅将电压和电流作为 ELM 的输入. MCSCKF 滤波器的测量方程定义为:

$$y_t = f_{ELM}(U_t, I_t) + R_t \quad (5)$$

其中, f_{ELM} 表示 ELM 的计算, t 表示当前采样时间, U 和 I 表示电压和电流, R_t 表示测量噪声.

MCSCKF 滤波器的状态方程定义为:

$$SOC_{A,t} = SOC_{A,t-1} - \frac{I_{t-1} \cdot \Delta T}{C} + Q_k \quad (6)$$

其中, $SOC_{A,t}$ 表示当前采样时间按时积分法的 SOC 值, ΔT 表示当前采样间隔, C 表示电池容量, Q_k 表示过程噪声.

3 实验与测试

电池测试平台由电池测试系统、东莞贝尔 (DGBELL) 恒温箱、上位机和被测电池组成, 实验台如图 3 所示.

在本次实验中, 相同规格的两个 18650 电池被用来充放电测试, 其详细参数如表 2 所示. 额定容量为 2.2 A·h, 额定电压为 3.7 V, 重 43.8 g, 内阻小于 50 mΩ.

共采用 7 种行驶工况对被测电池进行测试, 分别是: 动态应力测试 (Dynamic stress test, DST)、北京动态应力测试 (Beijing dynamic stress test, BJDST)、高速公路驾驶循环 (Highway driving schedule, US06)、

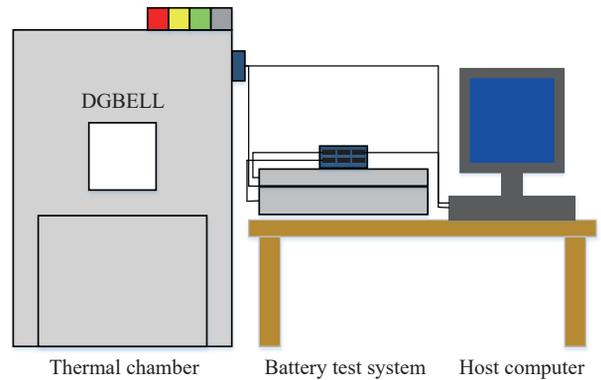


图 3 实验测试平台

Fig.3 Experimental test platform

表 2 被测电池详细参数

Table 2 Detailed parameters of tested battery

Test sample	Parameters	Value
	Normal capacity/(mA·h)	2200
	Normal voltage/V	3.7
	Weight/g	43.8
	Internal impedance/mΩ	≤50

联邦城市驾驶循环 (Federal urban driving schedule, FUDS)、城市道路循环 (Urban dynamometer driving schedule, UDDS) 和 2 种由前 5 种循环随机组成的行驶工况. 为模拟实验室温度和电池的正常工作温度, 分别采用 25 °C 和一个从 10 °C 到 40 °C 随机

变换的温度来测试电池. 被测电池使用 0.5C 的恒流恒压 (Constant current & constant voltage, CCCV) 对其进行充电, 直到电流小于 0.05C 以确保电池

充满. 随后, 对被测电池进行 30 min 的静置, 并开始之后的动态工况测试. 部分实验数据如图 4 所示.

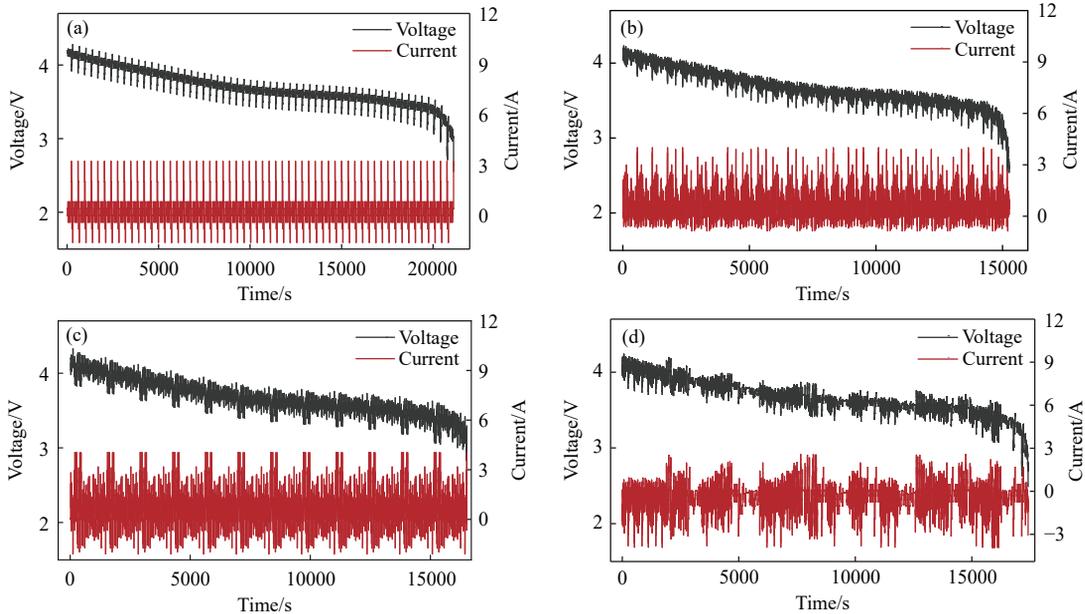


图 4 部分循环下被测样本的电流电压曲线. (a) DST 工况; (b) US06 工况; (c) FUDS 工况; (d) 随机混合工况-1

Fig.4 Current and voltage curves of the tested samples under partial cycles: (a) DST cycle; (b) US06 cycle; (c) FUDS cycle; (d) Mix-1

4 结果与讨论

本文的测试结果均基于一个配备 Intel core-i7 9700 的中央处理器. 为测试所提方法的泛化性能, 1 号电池的实验数据为训练数据, 2 号电池的实验数据为测试数据. 同时, 采用单一工况的实验数据为训练数据, 混合工况的实验数据为测试数据.

4.1 混合工况测试

为测试所提方法的泛化性能, 设计了一组随

机工况随机温度的测试实验, 分别命名为混合工况-1 和混合工况-2. 在这两种测试工况下, 被测样本从 10 °C 开始放电, 并在之后的 20 和 40 min 之后将环境温度分别增加至 20 °C 和 30 °C, 之后环境温度在 20 ~ 40 °C 之间随机变化. 测试循环由 DST、BJDST、US06、FUDS、UDDS 随机组成. 利用 LSTM 和 GRU 所提方法进行对比, 测试结果如图 5 和表 3 所示.

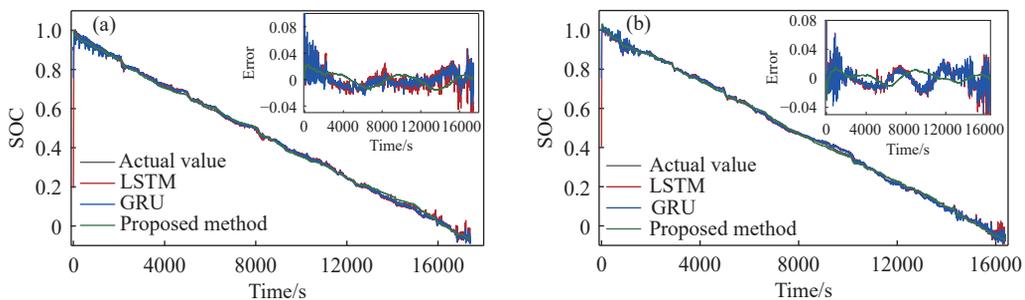


图 5 混合工况测试结果. (a) 混合工况-1 测试结果; (b) 混合工况-2 测试结果

Fig.5 SOC estimation results under a mixed drive cycle: (a) results under mix-1 cycle; (b) results under mix-2 cycle

从测试结果可以看出, 所提方法的运行时间和泛化性能均优于 LSTM 与 GRU. 在 Mix-1 工况下, 所提方法的最大误差为 2.299%, RMSE 为 0.92%, 平均运行时间为 970.54 s; 而 LSTM 和 GRU 的最大误

差分别为 80.442% 和 24.204%, RMSE 分别为 1.86% 和 1.08%, 平均运行时间分别为 3201.34 s 和 2993.41 s. 在 Mix-2 工况下, 测试结果类似, 所提方法的运行时间为 LSTM 和 GRU 的 1/3, 且测试最大误差与

表 3 混合工况测试结果

Table 3 SOC estimation results under a mixed drive cycle				
Methods	Drive cycle	Max error/%	RMSE/%	Average running time/s
LSTM	Mix-1	80.442	1.86	3201.34
	Mix-2	59.279	1.45	3371.71
GRU	Mix-1	24.204	1.08	2993.41
	Mix-2	24.355	1.11	3227.93
Proposed method	Mix-1	2.299	0.92	970.54
	Mix-2	3.054	0.61	1027.67

RMSE 优于 LSTM 和 GRU, 验证了所提方法的优越性. 相比较于单一的数据驱动方法, 所提方法结合了物理模型法和数据驱动法的优势, 在测试工况

与测试温度随机变化时, 表现出了更好的泛化性与鲁棒性.

4.2 鲁棒性测试

在应用 MCSCKF 时, 滤波的状态方程基于安时积分法, 如式 (6) 所示, 这意味着准确的初始 SOC 值至关重要. 然而, 由于锂离子电池在不同条件下的容量变化, 准确的初始 SOC 值很难获得. 另外, 重启电池管理系统时, 先前储存的 SOC 值可能会丢失. 因此, 在初始 SOC 值存在误差的情况下, 算法的校正能力至关重要. 本文共分 4 种情况进行了所提方法的校正能力测试, 分别为: 初始 SOC 精确, 初始 SOC 为 0.8, 初始 SOC 为 0.6, 初始 SOC 为 0.4. 测试结果如图 6 所示.

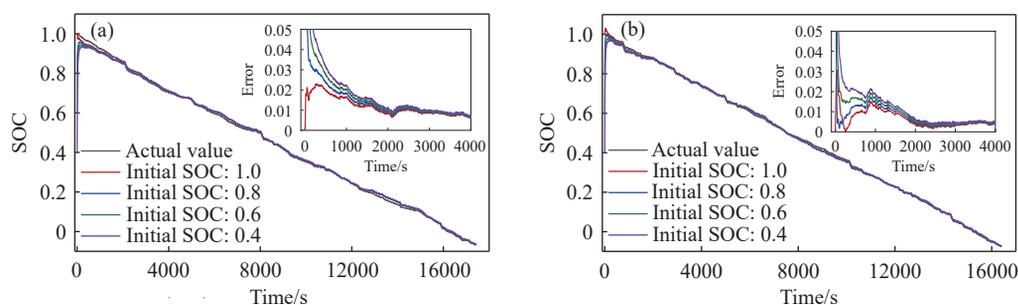


图 6 初始误差校正测试结果. (a) 混合工况-1 测试结果; (b) 混合工况-2 测试结果

Fig.6 Initial SOC error correction test results: (a) results under mix-1 cycle; (b) results under mix-2 cycle

从测试结果可以清楚的看出, 所提算法在 SOC 初值错误的情况下可以快速收敛至准确值. 当初始 SOC 值为 0.8 时, 两种混合工况下的误差均在 10 s 内收敛至 10% 以内, 并在之后的 20 s 内收敛至 5% 以内. 当初始 SOC 值为 0.6 时, 混合工况-1 下的误差在 38 s 时收敛至 10% 以内, 混合工况-2 下的误差则在 22 s 时收敛至 10% 以内. 当初始 SOC 值为 0.4 时, 混合工况-1 下的误差在 64 s 时收敛至 10% 以内, 混合工况-2 的误差则在 36 s 时收敛至 10% 以内. 混合工况-1 的收敛速度低于混合工况-2, 且在初值误差增大的同时变得更加明显. 经过数据分析发现, 混合工况-1 的初始电流为负, 意味着电池处于正常放电过程, 而混合工况-2 的初始电流为正和零, 这意味着少量的充电或搁置也许有利于初始 SOC 误差的校正工作. 因此, 在所测试的不同初始 SOC 情况下, 所提方法均可以快速的收敛至准确值, 这保证了所提方法的强鲁棒性.

为进一步测试所提方法在高噪声时的鲁棒性能^[24-26], 参照国标 GB/T38661—2020 规定的电池

测量精度要求, 电池单体电压测量误差绝对值不得大于 10 mV, 电流测量误差绝对值不得大于总量程的 2%. 因此, 需要在测试数据集的电压信号中加入幅值为 10 mV 的随机噪声, 电流信号中加入 120 mA 的随机噪声以测试 SOC 估算的鲁棒性能. 同时, 利用应用广泛的 LSTM 和 GRU 与所提方法进行比较, 测试结果如图 7 所示.

从测试结果可以清楚的看出, 所提方法在高噪声条件下仍可保证较高的估计精度, 显示了其良好的鲁棒性能与实际应用价值. 在两种混合工况下, 所提方法的绝对误差在初始的波动后, 均小于 5%. 相反, LSTM 和 GRU 在初始的误差波动后, 仍表现出很高的误差波动. 在两种混合工况下, LSTM 的初始误差均超过 80%, 但之后的误差范围保持在 10% 以内, 优于 GRU 模型. 相反, GRU 的初始误差为 20%, 但之后的误差波动超过 10%. 综上, 所提出的闭环估计方法, 无论是在初值存在误差的情况下, 或是在高环境噪声干扰的情况下, 均保证了其良好的估计精度. 因此, 所提方法具有较好的鲁棒性能与应用价值.

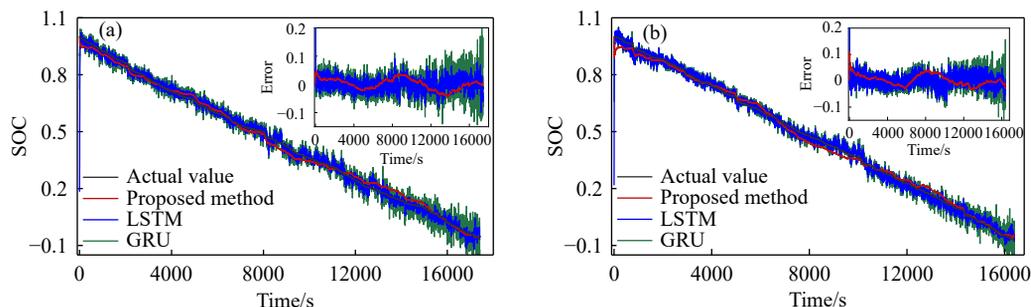


图7 随机噪声鲁棒性测试结果. (a) 混合工况-1 测试结果; (b) 混合工况-2 测试结果

Fig.7 SOC estimation in the case of random noises: (a) results under mix-1 cycle; (b) results under mix-2 cycle

5 结论

本文提出了一种基于 ELM 和 MCCKF 的锂离子电池 SOC 估计方法. 并通过一系列实验予以验证. 主要结论如下:

(1) 利用泛化性好、训练速度快的 ELM 建立卡尔曼滤波的测量方程, 并基于灰狼优化算法简化了 ELM 繁琐的调参过程且提高了锂离子电池 SOC 的估计精度.

(2) 基于 MCCKF 实现了锂离子电池 SOC 的闭环估计, 可有效减少 ELM 的 SOC 估计误差, 且在存在初始误差与干扰噪声的情况下, 显示出了优越的鲁棒性.

(3) 利用 LSTM、GRU 等序列处理能力强的神经网络与所提方法进行比较. 结果表明, 所提方法在运行时间与精度上都明显优于前两种方法.

(4) 进行了一系列的锂离子电池测试实验, 所提方法的优越性在多工况循环、宽温度范围内取得了验证, 显示出了良好的精确性、泛化性和鲁棒性.

参 考 文 献

- [1] Gao H N, Xu J, Pu X H, et al. An online control method for energy recovery of suspension vibration of new energy vehicles. *J Xi'an Jiaotong Univ*, 2020, 54(4): 19
(郜浩楠, 徐俊, 蒲晓晖, 等. 面向新能源汽车的悬架振动能量回收在线控制方法. *西安交通大学学报*, 2020, 54(4): 19)
- [2] Shrivastava P, Soon T K, Idris M Y I B, et al. Overview of model-based online state-of-charge estimation using Kalman filter family for lithium-ion batteries. *Renew Sustain Energy Rev*, 2019, 113: 109233
- [3] Wang Y J, Tian J Q, Sun Z D, et al. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems. *Renew Sustain Energy Rev*, 2020, 131: 110015
- [4] Xiong R, Cao J Y, Yu Q Q, et al. Critical review on the battery state of charge estimation methods for electric vehicles. *IEEE Access*, 2017, 6: 1832
- [5] Zhang S Z, Guo X, Dou X X, et al. A data-driven coulomb counting method for state of charge calibration and estimation of lithium-ion battery. *Sustain Energy Technol Assess*, 2020, 40: 100752
- [6] Xiong R, Yu Q Q, Wang L Y, et al. A novel method to obtain the open circuit voltage for the state of charge of lithium ion batteries in electric vehicles by using H infinity filter. *Appl Energy*, 2017, 207: 346
- [7] Wang X L, Jin H Q, Liu X Y. Online estimation of the state of charge of a lithium-ion battery based on the fusion model. *Chin J Eng*, 2020, 42(9): 1200
(王晓兰, 靳皓晴, 刘祥远. 基于融合模型的锂离子电池荷电状态在线估计. *工程科学学报*, 2020, 42(9): 1200)
- [8] Zhang Q, Cui N X, Li Y, et al. Fractional calculus based modeling of open circuit voltage of lithium-ion batteries for electric vehicles. *J Energy Storage*, 2020, 27: 100945
- [9] Feng F, Teng S L, Liu K L, 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 Power Sources*, 2020, 455: 227935
- [10] Zhu R, Duan B, Zhang J M, et al. Co-estimation of model parameters and state-of-charge for lithium-ion batteries with recursive restricted total least squares and unscented Kalman filter. *Appl Energy*, 2020, 277: 115494
- [11] Liu X, Qu H, Zhao J H, et al. Maximum correntropy square-root cubature Kalman filter with application to SINS/GPS integrated systems. *ISA Trans*, 2018, 80: 195
- [12] Almeida G C S, Souza A C Z, Ribeiro P F. A neural network application for a lithium-ion battery pack state-of-charge estimator with enhanced accuracy. *Proceedings*, 2020, 58(1): 33
- [13] Wang J, Yang Y Q, Wang T, et al. Big data service architecture: a survey. *J Internet Technol*, 2020, 21(2): 393
- [14] Reddy G T, Reddy M P K, Lakshmana K, et al. Analysis of dimensionality reduction techniques on big data. *IEEE Access*, 2020, 8: 54776
- [15] Gozde O S, Milutin P, Zafer S, et al. Battery state-of-charge estimation based on regular/recurrent Gaussian process regression. *IEEE Trans. Ind. Electron.*, 2018, 65(5): 4311
- [16] Li X Y, Yuan C G, Li X H, et al. State of health estimation for Li-

- Ion battery using incremental capacity analysis and Gaussian process regression. *Energy*, 2020, 190: 116467
- [17] Ren X Q, Liu S L, Yu X D, et al. A method for state-of-charge estimation of lithium-ion batteries based on PSO-LSTM. *Energy*, 2021, 234: 121236
- [18] Jiao M, Wang D Q, Qiu J L. A GRU-RNN based momentum optimized algorithm for SOC estimation. *J Power Sources*, 2020, 459: 228051
- [19] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications. *Neurocomputing*, 2006, 70(1-3): 489
- [20] Jiao M, Wang D Q, Yang Y, et al. More intelligent and robust estimation of battery state-of-charge with an improved regularized extreme learning machine. *Eng Appl Artif Intell*, 2021, 104: 104407
- [21] Hossain Lipu M S, Hannan M A, Hussain A, et al. Extreme learning machine model for state-of-charge estimation of lithium-ion battery using gravitational search algorithm. *IEEE Trans Ind Appl*, 2019, 55(4): 4225
- [22] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer. *Adv Eng Softw*, 2014, 69: 46
- [23] Deng Z W, Hu X S, Lin X K, et al. Data-driven state of charge estimation for lithium-ion battery packs based on Gaussian process regression. *Energy*, 2020, 205: 118000
- [24] Wei Z B, Hu J, Li Y, et al. Hierarchical soft measurement of load current and state of charge for future smart lithium-ion batteries. *Appl Energy*, 2022, 307: 118246
- [25] Wei Z B, Zhao D F, He H W, et al. A noise-tolerant model parameterization method for lithium-ion battery management system. *Appl Energy*, 2020, 268: 114932
- [26] Wei Z B, Dong G Z, Zhang X N, et al. Noise-immune model identification and state-of-charge estimation for lithium-ion battery using bilinear parameterization. *IEEE Trans Ind Electron*, 2021, 68(1): 312