

DOI: 10.19783/j.cnki.pspc.236010

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

毛玲, 温佳林, 赵晋斌, 董浩

(上海电力大学电气工程学院, 上海 200090)

摘要: 充电截止电压是大多数电动汽车用户充电都会经历的电压点。针对传统安时积分法忽略初始容量误差和电池老化等一系列待优化的问题, 提出了双层集成极限学习机(extreme learning machine, ELM)算法, 实现锂离子电池充电截止电压下的荷电状态(state of charge, SOC)和健康状态(state of health, SOH)联合估计。首先, 提取易测的电池健康特征(health indicator, HI), 采用集成极限学习机映射 HI 及充电所需时间与 SOH 之间的关系。其次, 用测得的 HI 估计难以在线测量的充电所需时间, 对充电截止电压下安时积分法的 SOC 进行在线修正。该方法充分考虑了电动汽车用户初始充电状态的不确定性, 指导电动汽车用户合理充电。此外, 通过选择合适的集成 ELM 模型集成度, 解决了单个 ELM 模型输出不稳定的问题。最后, 选用 NASA 和 CALCE 数据集进行实验验证。验证结果表明, 锂离子电池充电截止电压下 SOC 的估计均方根误差均小于 1.5%, 集成 ELM 相比于其他常见算法具有较高的训练、测试精度和较短的预测时间。

关键词: 锂离子电池; 荷电状态; 健康状态; 健康特征; 集成极限学习机

Joint estimation of SOC and SOH at lithium-ion battery charging cut-off voltage based on an ensemble extreme learning machine

MAO Ling, WEN Jialin, ZHAO Jinbin, DONG Hao

(College of Electrical Power Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: The charging cut-off voltage is the voltage point that most electric vehicles (EVs) will experience during charging. There is a series of problems to be optimized such as ignoring the initial capacity error and battery aging by the traditional ampere-hour integration method. A two-layer ensemble extreme learning machine (Ensemble ELM) algorithm is proposed to realize the joint estimation of SOC and SOH under the charging cut-off voltage of lithium-ion batteries. First, this study extracts the health indicator (HI), which is easily measured, and establishes the model between HI, charging time and SOH based on an Ensemble ELM. Second, the easily measured HI is used to estimate the charging time, something that is difficult to measure online. The online SOC correction based on the ampere-hour integration method is realized at the charging cut-off voltage. This method fully considers the uncertainty of the initial charging state of EVs, and can guide EV users to charge reasonably. In addition, the problem of output instability of a single ELM model is solved by selecting appropriate integration degree of the ensemble ELM model. Finally, the proposed method is tested on NASA and CALCE datasets. The results show that the root-mean-square-error (RMSE) of SOC estimation is less than 1.5% for a lithium-ion battery at charging cut-off voltage. Compared with other common algorithms, the ensemble ELM shows a higher training and test accuracy with short estimation time.

This work is supported by the National Natural Science Foundation of China (No. 52177184).

Key words: lithium-ion battery; state of charge; state of health; health indicator; ensemble extreme learning machine

0 引言

锂离子动力电池由于其能效高、能量密度高、

寿命长等优点被广泛应用在电动汽车及电力系统领域^[1-2]。对锂离子电池的荷电状态(state of charge, SOC)和健康状态(state of health, SOH)进行估计和实时修正具有十分重要的意义^[3-7]。SOC 被认为是电池目前的电荷容量和最大可用容量的比值, 具有

基金项目: 国家自然科学基金项目资助(52177184)

较短的时间尺度; SOH 被定义为当前最大可用容量与标称容量比值, 具有较长的时间尺度^[8]。由于 SOC 和 SOH 在时间尺度上的耦合, 所以对两者的进行联合估计具有十分重要的意义。表 1 是常见的 SOC 和 SOH 估计方法及其优缺点。

表 1 SOC 和 SOH 常见估计方法比较

Table 1 Comparison of common estimation methods for SOC and SOH

SOC 估计方法	优点	缺点
安时积分法 ^[9]	简单快速	有累计误差, 对初值要求较高
开路电压法 ^[10]	电路关系明确, 方法直接, 映射关系较好	SOC 较高或较低时预测效果较差, 开路电压测试所需静置时间长
智能算法类 ^[11-12]	基于历史数据学习, 具有无模型优势	计算量较大, 参数调节较为苛刻
滤波算法类 ^[13-17]	能够及时更正, 适合在线应用	受模型精度影响较大, 参数辨识要求较高
SOH 估计方法	优点	缺点
直接测量法	预测过程简单易行	对初值要求较高或时间较长, 不适合在线应用
基于模型方法	电路关系明确, 预测准确度较高, 适应于在线预测	受模型精度影响较大, 参数辨识要求较高
基于数据驱动 ^[18-20]	基于历史数据学习, 具有无模型优势	计算量较大, 参数调节较为苛刻

从 SOC 和 SOH 的定义中可以看出, 两者存在的共同参量是当前最大可用容量, 该物理量会随着锂离子电池的老化而不断衰减, 所以 SOC 估计势必会受到 SOH 估计的影响^[21]。面对锂离子电池较长生命周期的估计, SOC 和 SOH 的联合估计是不可避免的。文献[22]构建二阶 RC 等效电路模型, 并利用平方根无迹卡尔曼滤波算法和扩展卡尔曼滤波实现联合估计。文献[23]在二阶分数阶模型的基础上采用多创新无迹卡尔曼滤波(multi-innovations unscented kalman filter, MIUKF)预测 SOH, 以更新 SOC 预测的容量。文献[24]采用自适应等效电路模型, 为 SOC 和 SOH 的精确联合估计奠定了基础。文献[25]利用库伦计数法与电压差分法结合实现无模型的数据驱动的 SOC 和 SOH 联合估计。另外, 经过平移优化的 SOC-OCV 曲线并结合扩展卡尔曼滤波(extended kalman filter, EKF)的电池参数辨识能够提高 SOC 的全局估计精度^[26]。文献[27]提出一种抑制粒子退化的改进闪烁粒子滤波算法(improved firefly algorithm-particle filter, IFA-PF), 利用带有遗忘因子的递归最小二乘法进行参数辨识, 将内阻作为健康特征实现 SOC 和 SOH 的联合估计。文献[28-29]分别采用多个循环神经网络和加以改进的基于门控循环单元

循环神经网络(recurrent neural network with gated recurrent unit, GRU-RNN), 并利用数据驱动完成联合估计。文献[30]利用灰狼算法优化的长短期记忆神经网络和基于最小二乘的支持向量机融合模型提高了联合估计的精确度和鲁棒性。

上述联合估计方法中, 基于等效电路模型的方法参数辨识往往难度较大, 在线估计适应性低; 而神经网络、SVM 等机器学习方法的约束条件较为苛刻、参数调优等计算量较大。现有数据驱动方法的 SOC 和 SOH 大多是独立估计, 并最终随着电池老化在一定时间后实现 SOH 的更新迭代, 少有研究将 SOC 和 SOH 放置于同一模型中同时完成快速更新。因此, 本文采用集成极限学习机(extreme learning machine, ELM)模型, 利用集成 ELM 模型具有较强的学习和泛化能力, 构建电池健康特征(health indicator, HI)与 SOH 和 SOC 的模型实现不同充电状态下同时迭代估计。

充电截止电压是恒流和恒压充电的分界点, 恒压充电阶段电池的 SOC 已经处于较高位, 受电压应力的影响, 恒压充电时间越长, 电池的老化影响越明显^[31], 所以本文在充电截止电压下进行 SOC 和 SOH 联合估计, 实现充电截止电压时对传统安时积分法 SOC 的在线修正。

基于安时积分法的 SOC 进行修正需要在线解决 SOH 不断迭代更新的问题。对 SOC 和 SOH 的联合估计的意义在于考虑到两者时间尺度上的耦合, 能够给出更符合 SOC 定义的估计结果。综上所述, 在充电截止电压下的联合估计和在线修正具有较大的工程意义。本文的具体贡献体现在以下四个方面:

- 1) 采用集成 ELM 算法融合离线部分和在线部分, 构建起健康特征与对应电池 SOC 和 SOH 的相关性, 形成双层架构的模型训练与在线估计;
- 2) 能够在每次在线估计的充电过程中实现最大可用容量 Q_{\max} 的更新迭代, 迭代频率有所提高且能够实现更加适合在线的实时估计;
- 3) 对集成 ELM 的模型的集成度对估计结果的影响进行考察, 并选出合适的集成度;
- 4) 考虑用户充电起点的不确定性, 保障模型构建和在线估计的可行性, 并对多个数据集进行分别验证, 适应性较高。

1 方法与框架

电池管理系统(battery management system, BMS)能够实时监测锂离子电池的外特性, 包括电流、端电压、电池温度等。而 SOC 与 SOH 均属于无法直接测量的量, 因此本文基于数据驱动方法选

用集成 ELM 模型进行离线训练和在线测试, 具体步骤的框架流程如图 1 所示。

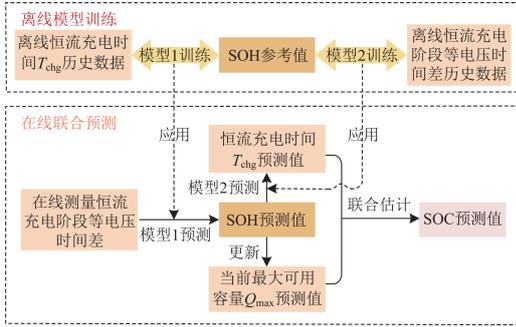


图 1 框架流程图

Fig. 1 Framework flow chart

离线部分的主要工作是训练模型。易测健康特征(记作 HI1), 在线测试难度较大的充电所需时间 T_{chg} (记作 HI2)。两个模型都由集成 ELM 建立, 模型 1 主要构建起易测健康特征与实测 SOH 之间的关系, 模型 2 建立起恒流充电时间与 SOH 的映射关系。在训练过程中, ELM 模型 1 和模型 2 的训练集分别为 HI1 和 HI2, 两种训练得到的映射关系在线预测阶段作为已知模型。

在线过程主要是快速实现用户充电过程中不同终止电压对应的 SOC 估计, 并在线实时修正及老化的 SOC 估计值, 将在线测得的 HI1 送入到模型 1 中获得锂离子电池的 SOH 估计值, 再将 SOH 估计值送入到模型 2 获得 T_{chg} 的预测值, 并同时在 SOC 估计中实现 SOH 更新。

2 算法模型

2.1 集成 ELM 模型

极限学习机是由单隐层前馈神经网络发展而来的, 随机性是该模型的主要特点, 因为隐含层的权值和偏差是随机给定的^[32]。该模型被广泛用于电力系统安全评估的回归预测。结构由输入层、隐含层、输出层组成, 如图 2 所示。每层都通过映射函数进行信息传递, 中间隐含层完成信息转换, 再到输出层通过映射函数计算出输出值。

假设输入层有 n 个神经元输入, 输出层有 m 个神经元输出, 隐含层有 l 个神经元。输入层和隐含层之间的连接权值矩阵为 ω , 它是一个 $l \times n$ 维的矩阵, 其元素是绝对值小于 1 的随机数。

$$\omega = \begin{pmatrix} \omega_{11} & \omega_{12} & \cdots & \omega_{1n} \\ \omega_{21} & \omega_{22} & \cdots & \omega_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \omega_{l1} & \omega_{l2} & \cdots & \omega_{ln} \end{pmatrix} \quad (1)$$

向量 b 是隐含层对应的偏置矩阵, 向量的维数是隐含层的神经元个数 l , 其元素是随机生成的, 元素值一般介于 0~1 之间。

$$b = (b_1, b_2, \dots, b_l)^T \quad (2)$$

β 是隐含层和输出层之间的连接矩阵, 矩阵中的值通过随机矩阵 ω 和偏置向量 b 计算得到。

$$\beta = \begin{pmatrix} \beta_{11} & \beta_{12} & \cdots & \beta_{1m} \\ \beta_{21} & \beta_{22} & \cdots & \beta_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \beta_{l1} & \beta_{l2} & \cdots & \beta_{lm} \end{pmatrix} \quad (3)$$

模型的输出值 $F_L(x)$ 可以通过 n 维的输入向量 x_i 和模型的激活函数获得, 如式(4)所示。

$$F_L(x) = \sum_{i=1}^L \beta_i \cdot h(x_i) \quad (4)$$

式中, L 表示样本总体数。激活函数实际是隐含层中对应样本的特征映射值, 本文选取的激活函数 $h(\cdot)$ 是标准正弦函数 ($\varphi(z) = \sin(z)$)。

假设模型的目标向量是 T , 随机学习的过程就是寻找合适的隐含层和输出层之间的连接矩阵 β 来满足二范数 $\|H\beta - T\|$ 的平方最小或者尽量接近于 0, 其中 H 是网络的隐含层输出矩阵。

由于单个 ELM 模型权值输入的随机性, 直接导致输出结果的不稳定性^[33], 所以采用多个单个 ELM 组成的集成模型的本质就是对极限学习机随机过程的拓展, 并建立决策机制式(5), 过滤掉集成 ELM 模型输出的与目标差别较大的异常值, 最终获得较好的估计效果。将个体输出值 $f_j(x_i)$ 与集成模型的期望值 $\hat{f}_j(x_i)$ 之间的差值绝对值作为潜在误差, 如式(6)所示。

$$\begin{cases} E_{\text{error}_j} > thr \rightarrow \text{舍去该单一ELM输出值} \\ E_{\text{error}_j} \leq thr \rightarrow \text{保留该单一ELM输出值} \end{cases} \quad (5)$$

$$E_{\text{error}_j} = |f_j(x_i) - \hat{f}_j(x_i)| \quad (6)$$

式中, thr 表示可信度阈值, 一般默认为 3σ 。

模型算法结构及联合估计过程如图 2 所示。模型 1 和模型 2 都在离线阶段采用集成 ELM 构建, 而模型的输出值是经过异常值处理得到的, 在线阶段将测量的易测 HI1 输入到模型中实现 SOC 和 SOH 联合估计和实时修正。具体的集成 ELM 模型算法流程图如图 3 所示。

2.2 相关系数

本文选用 Spearman 相关系数, 如式(7)所示, 其数值的绝对值越接近 1, 表示两个向量的相关性越高, 映射关系越理想, 机器学习效果也越好。

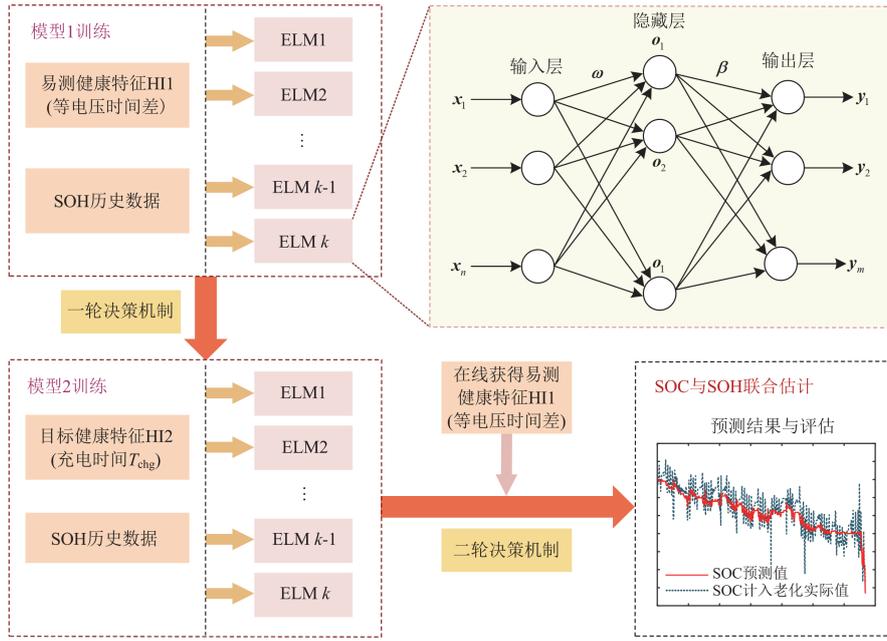


图 2 算法与模型示意图

Fig. 2 Schematic diagram of the algorithm and model

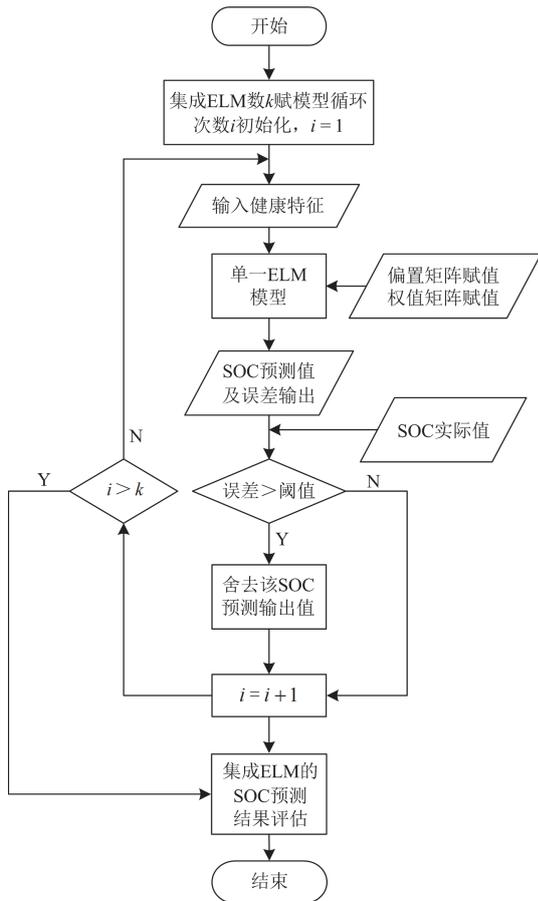


图 3 集成 ELM 算法流程图

Fig. 3 Flow chart of the ensemble ELM algorithm

$$S_{pearman} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (7)$$

式中: x_i 、 y_i 是两个相关性比较的 n 维向量; \bar{x} 、 \bar{y} 分别是向量的平均数据等级。

2.3 误差评判指标

本文选取均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)进行误差评价。

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (8)$$

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (9)$$

$$M_{APE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (10)$$

式中: y_i 代表向量的真实值; \hat{y}_i 代表向量的估计值。RMSE、MAE、MAPE 的值均为正数, 其值越小, 代表估计的精确度越高。

3 数据分析与模型构建

本文选用两种锂离子电池循环老化数据集作为实验的验证对象: 1) NASA 数据集^[34]来自于美国宇航局艾姆斯预测中心, 选用其中的 B0005、B0007 电池; 2) CALCE 数据集^[35]来自马里兰大学高级生

命周期工程中心, 选用其中 CS2-35、CS2-37 电池。电池数据集的基本信息见表 2。

表 2 锂离子电池数据集基本信息

Table 2 Basic information of lithium battery dataset

	额定容量/ mAh	充电 模式	起始充电 电压/V	充电截止 电压/V
NASA	2100	CC + CV	3.0	4.2
CALCE	1100	CC + CV	3.0	4.2

电池在离线测试阶段均完成 100% 放电深度 (depth of discharge, DOD) 的循环老化测试, 因此认为充电开始过程的荷电 $S_{oc}(t_0)$ 为 0, 以 NASA 的 B0005 电池在充电截止电压 (4.2 V) 下的 SOC 为例, 计及老化和不计及老化的 SOC 参考值如图 4 所示, 两种情形下的 SOC 参考值差距较大, 所以电池 SOC 估计时的老化因素不能忽略。

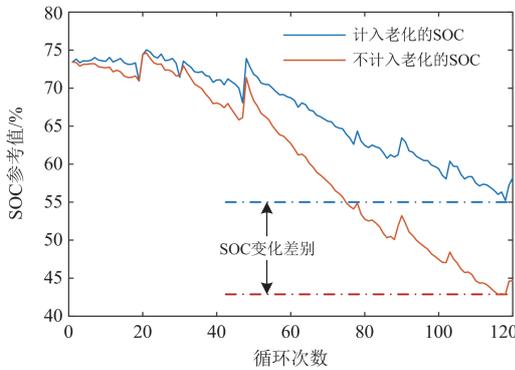


图 4 电池充电截止电压下 SOC 参考值

Fig. 4 SOC reference value for battery at charge cut-off voltage

从图 5 反映出的易测 HI 和 SOH 较高的相关性可以反映出模型 1 构建的整体可行性, NASA 在 3.9~4.0 V 和 CALCE 在 3.8~4.0 V 的 HI 与 SOH 相关性最高, 映射效果最好。该电压范围位于电动汽车用户 SOC 常用范围之内, 符合大众用户对电池的使用模式, 同时也降低了电池出现过充或过放等不安全状态的概率。

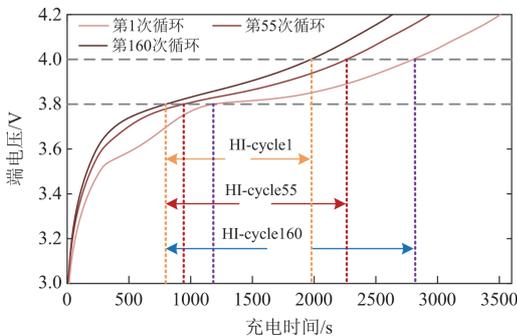


图 5 易测健康特征示意图

Fig. 5 Schematic diagram of easily measurable health indicator

表 3 易测健康特征 Spearman 相关系数

Table 3 Spearman correlation coefficients of easily measurable health indicators

NASA	等电压时间差健康特征的电压区间		
	3.9~4.0 V	4.0~4.1 V	4.1~4.2 V
B0005	0.9855	0.9738	0.9413
B0007	0.9785	0.9694	0.8819
CALCE	等电压时间差健康特征的电压区间		
	3.8~4.0 V	3.9~4.1 V	4.0~4.2 V
CS2-35	0.9913	0.8267	0.5792
CS2-37	0.9944	0.9000	0.7442

理论上从充电开始到充电截止电压下的恒流时间 T_{chg} 是能够在线测量获得的, 但是由于电动汽车用户在起始充电阶段的随机性, 因此对应的充电至截止电压的时间就会受到用户行为变化而波动较大, 如图 6 所示。所以尝试进一步建立实际 SOH 与充电至某一终止电压时间 T_{chg} 的模型 2。本文忽略 DOD 对电池老化的影响。在此基础上, 模型 2 的构建可以解决低 SOC 区域用户起始充电行为不确定导致的无法在线准确获得为全恒流充电时间的问题。

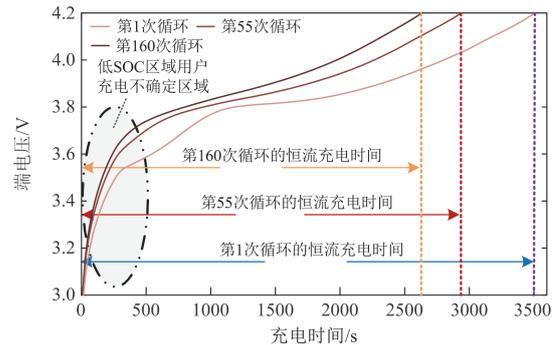


图 6 目标健康特征示意图

Fig. 6 Schematic diagram of target health indicator

此外, NASA 和 CALCE 电池充电至不同终止电压所需时间 T_{chg} 与电池实际 SOH 的 Spearman 相关性系数信息见表 4。相关性均高于 95%, 反映出表 4 不同充电终止电压所需时间 Spearman 相关性系数

Table 4 Spearman correlation coefficient of time required for different end-of-charge voltages

NASA	锂离子电池恒流充电终止时刻端电压				
	4.0 V	4.1 V	4.2 V		
B0005	0.9861	0.9916	0.9944		
B0007	0.9837	0.9917	0.9946		
CALCE	锂离子电池恒流充电终止时刻端电压				
	3.8 V	3.9 V	4.0 V	4.1 V	4.2 V
CS2-35	0.9505	0.9687	0.9872	0.9905	0.9910
CS2-37	0.9612	0.9757	0.9904	0.9936	0.9934

模型 2 构建的可行性。充电的终止电压也取决于电动汽车用户的实际使用需要, 任何充电电压下的 SOC 均可以与 SOH 联合估计, 而本文选用恒流恒压充电分界的充电截止电压进行 SOC 估计。

综上所述, 模型 1 和模型 2 的构建能够实现从健康特征到充电终止电压 SOC 估计值的多步映射, 实现 SOC 和 SOH 联合估计。

4 测试结果与评价

4.1 模型集成度分析

由于集成 ELM 模型受随机权值的影响, 因此模型的集成度会影响输出估计误差的准确性和稳定性, 定义集成度为 k , 表示集成 ELM 是由 k 个单个 ELM 构成的。图 7 为在线估计阶段模型集成度从 1 到 200 的 4.2 V 充电电压对应 SOC 的估计误差。图中表明, 模型集成度越高, 出现估计较大异常误差的可能性越小。在集成 ELM 模型集成度 $k > 100$ 后, 估计精度较高且可以认为位于稳定区域。

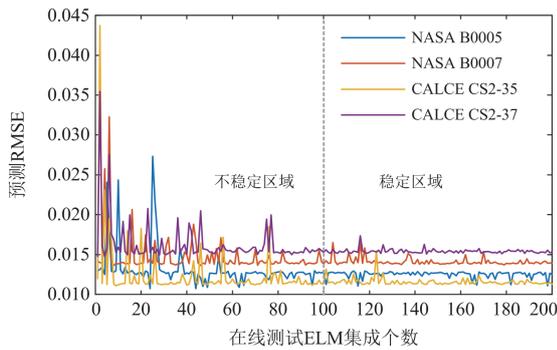


图 7 ELM 集成个数对估计误差的影响

Fig. 7 Effect of the number of ELM ensembles on the prediction error

因此模型的集成度可以选为 $k = 100$ 进行实验验证, 在保证估计精度的情况下尽可能地降低运算量。图 9 和图 11 分别给出 NASA(B0005 和 B0007) 和 CALCE(CS2-35 和 CS2-37) 锂离子电池充电终止电压为 4.2 V 的 SOC 估计结果和误差图。

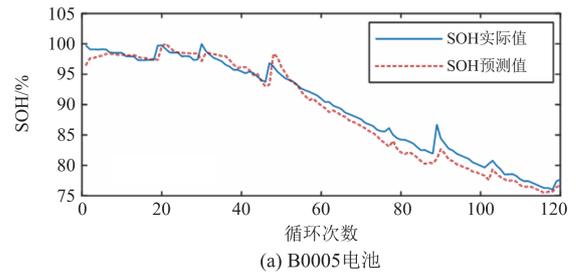
4.2 NASA 数据集的估计结果

NASA 数据集的 B0005 和 B0007 电池利用等充电电压片段时间差作为健康特征的 SOH 预测结果, 如图 8 所示。

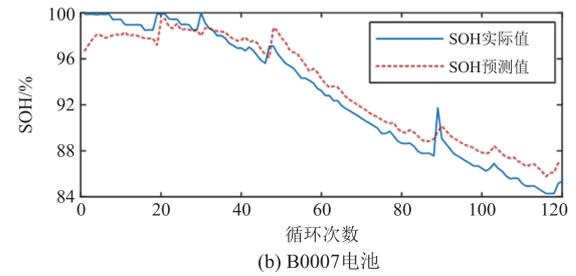
NASA 数据集电池(B0005、B0007)经过 SOH 预测后更新最大可用容量的 SOC 估计效果如图 9 所示。

4.3 CALCE 数据集的估计结果

CALCE 数据集的 CS2-35 和 CS2-37 电池利用等充电电压片段时间差作为健康特征的 SOH 预测结果, 如图 10 所示。



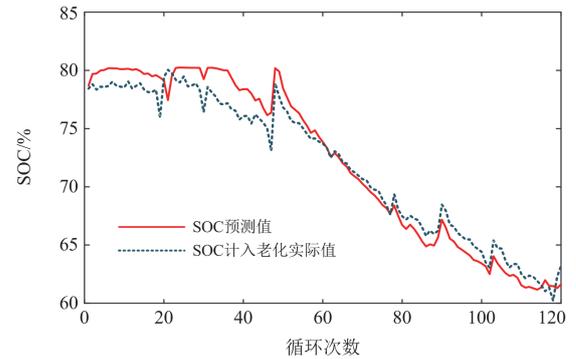
(a) B0005 电池



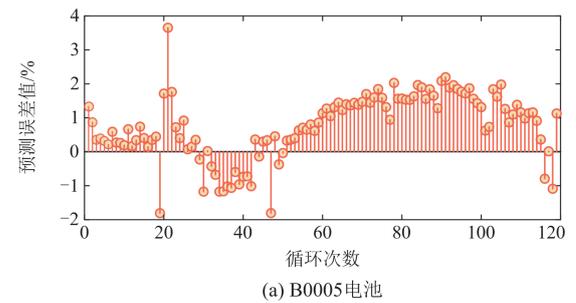
(b) B0007 电池

图 8 NASA 电池 SOH 估计结果

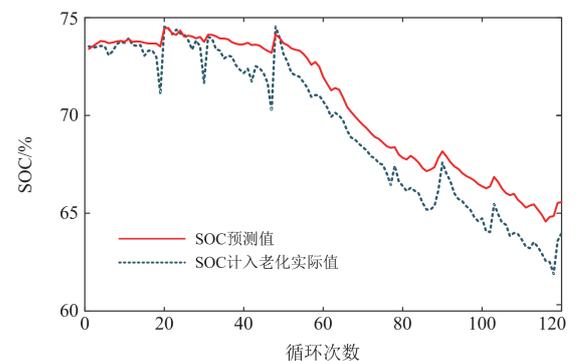
Fig. 8 SOH estimation results for NASA battery



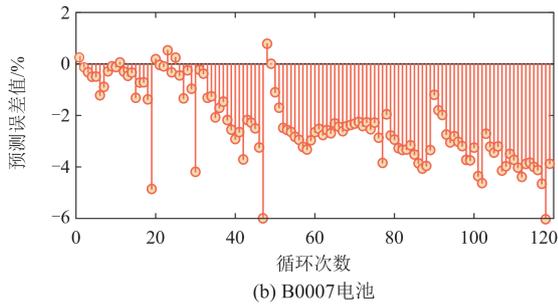
(a) B0005 电池



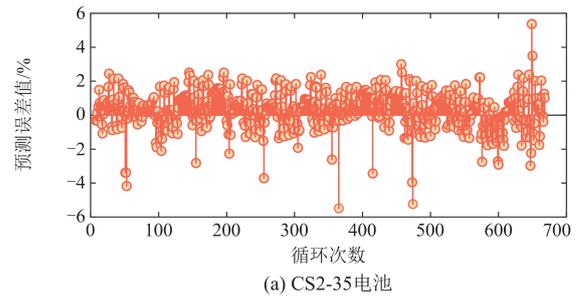
(a) B0005 电池



(a) B0005 电池



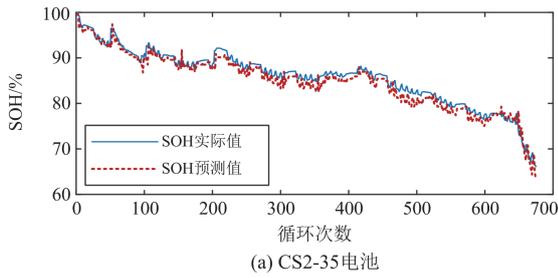
(b) B0007电池



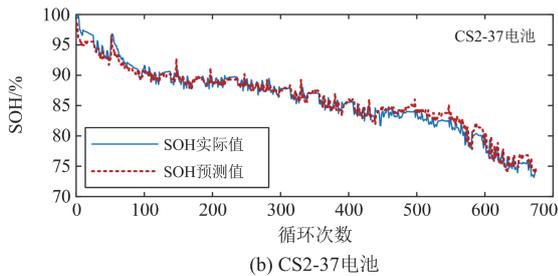
(a) CS2-35电池

图9 NASA 电池估计结果

Fig. 9 NASA battery estimation results



(a) CS2-35电池



(b) CS2-37电池

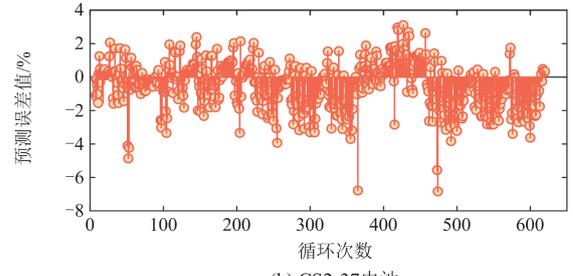
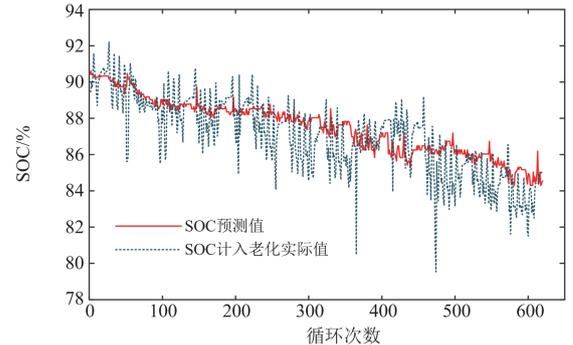
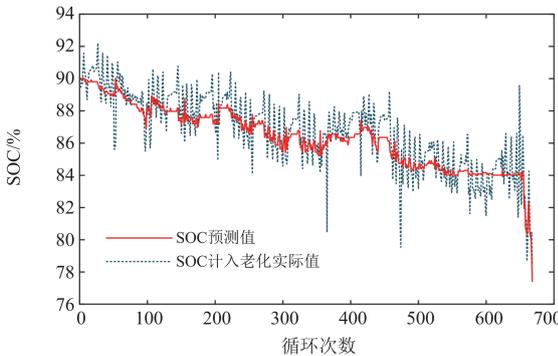
图10 CALCE 电池 SOH 估计结果

Fig. 10 SOH estimation results for CALCE battery

CALCE 数据集电池(CS2-35、CS2-37)经过 SOH 预测后更新最大可用容量的 SOC 估计效果如图 11 所示。

从表 5 可以看出, 经过等电压区间时间差健康特征进行双层集成 ELM 模型估计的 4.2 V 端电压下的 SOC 与计及老化的 SOC 参考值的所有估计均方根误差都小于 1.5%。

从图 9 和图 11 可知, NASA 和 CALCE 数据集



(b) CS2-37电池

图11 CALCE 电池估计结果

Fig. 11 CALCE battery estimation results

表5 充电终止电压为 4.2 V 的 SOC 估计结果

Table 5 Estimation results of SOC with end-of-charge voltage of 4.2 V

	RMSE	MAE	MAPE
NASA B0005	0.0115	0.0099	0.0153
NASA B0007	0.0137	0.0118	0.0171
CALCE CS2-35	0.0116	0.0090	0.0104
CALCE CS2-37	0.0148	0.0113	0.0130

的 SOH 预测误差值基本介于 ±5% 以内, 其预测误差值指 SOH 估计的相对误差, 满足式(11)。

$$\text{相对误差} = \frac{\text{预测值} - \text{实际值}}{\text{实际值}} \times 100\% \quad (11)$$

估计结果说明集成 ELM 模型具有较高的估计精确性和广泛适应性。因此锂离子电池能够实现对应充电电压下 SOC 的在线修正, 优化传统安时积分法因为初始容量不确定和不考虑电池老化带来的不

精确估计的影响。

4.4 算法比较

为了体现出所提出的集成度为 $k=100$ 的集成 ELM 算法的预测优势, 将该算法与常见算法的预测精度和预测所需时间进行比较, 如表 6 所示, 所有模型的超参数都进行了优化, 进行性能比较的算法有长短记忆神经网络(long short-term memory, LSTM)、随机森林(random forest, RF)、支持向量机(support vector machine, SVM)、单个 ELM、集成 ELM。算法比较时选用 NASA 和 CALCE 电池数据集, 保证训练数据和测试数据一致。

表 6 不同算法 SOC 预测精度(均方根误差)比较

Table 6 Comparison of estimation accuracy (RMSE) for SOC in different algorithms

算法	NASA	NASA	CALCE	CALCE
	B005	B007	CS2-35	CS2-37
LSTM	0.0216	0.0201	0.0243	0.0284
RF	0.0168	0.0188	0.0203	0.0189
SVM	0.0150	0.0161	0.0183	0.0174
单个 ELM	0.0189	0.0144	0.0289	0.0155
集成 ELM	0.0115	0.0137	0.0116	0.0148

基于机器学习算法的训练时间、训练准确率、测试时间、测试准确率也是考察算法性能的重要指标, 表 7 为进一步比较 CALCE(CS2-35、CS2-37 电池)两款电池的平均所需时间和预测准确率指标。

表 7 不同算法训练/测试的时间/准确率(均方根误差)比较

Table 7 Comparison of training/testing time/accuracy (RMSE) for different algorithms

算法	平均训练	平均测试	平均训练	平均测试
	时间/s	时间/s	RMSE/%	RMSE/%
LSTM	2.3894	2.0780	2.18	2.45
RF	0.3219	0.1215	1.82	1.67
SVM	0.4132	0.3988	1.93	2.01
单个 ELM	0.0275	0.0173	1.65	1.58
集成 ELM	0.5610	0.5070	1.59	1.44

对表 6 和表 7 中最优的结果进行了加粗处理, 可以看出, 集成 ELM 具有最高的预测精度、训练精度和测试精度。而从训练和测试时间角度考虑, 单个 ELM 模型的时间最短。由于单个 ELM 预测结果的不稳定性, 所以同样具有较短时间的集成 ELM 模型有更好的应用前景。

5 结论

为了对充电截止电压下的锂离子电池进行 SOC 精确预测, 本文考虑了电动汽车用户充电起始电压的随机性对在线获取充电时间难度较大的问题。基

于数据驱动构建了双层集成 ELM 模型, 完成了从 HI 对 SOH 和对应充电电压下 SOC 的多步联合估计。选用 NASA 和 CALCE 数据集分别进行验证。从验证结果可以看出, 对于两个数据集充电截止电压(4.2 V)下对应的 SOC 估计, 其均方根误差都小于 1.5%, 并从预测、训练和测试的精度以及测试时间等角度比较分析了集成 ELM 与其他常用算法, 结果表明, 集成 ELM 相比于其他算法对 SOC 和 SOH 联合估计具有较高的预测精度和较短的预测所需时间。

此外, 为了合理选择模型集成度来保证运算资源不被过度浪费, 本文进一步分析了 ELM 模型集成个数对估计精度的影响。测试结果表明, 集成 ELM 的集成度越高, SOC 估计误差出现较大异常值的概率越低, 在模型由大于 100 个单个 ELM 模型组成时, 既有较高的估计精度, 也能够使得估计结果趋于稳定。

参考文献

- [1] RAHIMI-EICHI H, OJHA U, BARONTI F, et al. Battery management system: an overview of its application in the smart grid and electric vehicles[J]. IEEE Industrial Electronics Magazine, 2013, 7(2): 4-16.
- [2] HU X, ZOU C, ZHANG C, LI Y. Technological developments in batteries: a survey of principal roles, types, and management needs[J]. IEEE Power and Energy Magazine, 2017, 15(5): 20-31.
- [3] DU Changqing, SHAO Jianbo, WU Dongmei, et al. Research on co-estimation algorithm of SOC and SOH for lithium-ion batteries in electric vehicles[J]. Electronics, 2022, 11(2): 181.
- [4] 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 Yijun, ZUO Xue. 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.
- [5] 李沂涸, 李慷, 余渐. 锂离子电池荷电状态与健康状态估计方法[J]. 发电技术, 2021, 42(5): 537-546.
LI Yihuan, LI Kang, YU Jian. Estimation approaches for states of charge and health of lithium-ion battery[J]. Power Generation Technology, 2021, 42(5): 537-546.
- [6] 夏向阳, 邓子豪, 张嘉诚, 等. 基于动力锂离子电池健康状态的全寿命周期优化充电策略[J]. 电力科学与技术学报, 2022, 37(6): 17-24.
XIA Xiangyang, DENG Zihao, ZHANG Jiacheng, et al. Life cycle optimal charging strategy based on the SOH of power

- lithium ion battery[J]. Journal of Electric Power Science and Technology, 2022, 37(6): 17-24.
- [7] 黎冲, 王成辉, 王高, 等. 基于数据驱动的锂离子电池健康状态估计技术[J]. 中国电力, 2022, 55(8): 73-86, 95.
LI Chong, WANG Chenghui, WANG Gao, et al. Technology of lithium-ion battery state-of-health assessment based on data-driven[J]. Electric Power, 2022, 55(8): 73-86, 95.
- [8] SHEN Ping, OUYANG Minggao, LU Languang, et al. The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles[J]. IEEE Transactions on Vehicular Technology, 2018, 67(1): 92-103.
- [9] 朱小平, 张涛. 基于自适应理论的锂离子电池 SOC 估计[J]. 电气技术, 2013, 14(7): 48-51.
ZHU Xiaoping, ZHANG Tao. New method of SOC estimation for lithium-ion batteries based on self-adaptive system[J]. Electrical Engineering, 2013, 14(7): 48-51.
- [10] ZHANG Caiping, JIANG Jiuchun, ZHANG Linjing, et al. A generalized SOC-OCV model for lithium-ion batteries and the SOC estimation for LNMCO battery[J]. Energies, 2016, 9(11).
- [11] 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.
- [12] 党选举, 言理, 姜辉, 等. 基于在线 LS-SVM 的动力电池 SOC 估算方法研究[J]. 电源技术, 2017, 41(5): 752-756.
DANG Xuanju, YAN Li, JIANG Hui, et al. Study on estimation based on online LS-SVM for state of charge of power battery[J]. Chinese Journal of Power Sources, 2017, 41(5): 752-756.
- [13] 孙金磊, 邹鑫, 顾浩天, 等. 基于 FFRLS-EKF 联合算法的锂离子电池荷电状态估计方法[J]. 汽车工程, 2022, 44(4): 505-513.
SUN Jinlei, ZOU Xin, GU Haotian, et al. State of charge estimation for lithium-ion battery based on FFRLS-EKF joint algorithm[J]. Automotive Engineering, 2022, 44(4): 505-513.
- [14] 唐传雨, 韩华春, 史明明, 等. 基于 DEKF 的储能电池系统 SOC 估计方法研究[J]. 电力工程技术, 2021, 40(3): 7-14.
TANG Chuanyu, HAN Huachun, SHI Mingming, et al. SOC estimation method of battery energy storage system for BMS test platform[J]. Electric Power Engineering Technology, 2021, 40(3): 7-14.
- [15] DUAN Jiandong, WANG Peng, MA Wentao. State of charge estimation of lithium battery based on improved correntropy extended Kalman filter[J]. Energies, 2020, 13(16): 4197.
- [16] 潘海鸿, 吕治强, 李君子, 等. 基于灰色扩展卡尔曼滤波的锂离子电池荷电状态估算[J]. 电工技术学报, 2017, 32(21): 1-8.
PAN Haihong, LÜ Zhiqiang, LI Junzi, et al. Estimation of lithium-ion battery state of charge based on grey prediction model-extended Kalman filter[J]. Transactions of China Electrotechnical Society, 2017, 32(21): 1-8.
- [17] 寇发荣, 王甜甜, 王思俊, 等. 基于 ABC-RFEKF 算法的锂电池 SOC 估计[J]. 电力系统保护与控制, 2022, 50(4): 163-171.
KOU Farong, WANG Tiantian, WANG Sijun, et al. Lithium battery SOC estimation based on an ABC-RFEKF algorithm[J]. Power System Protection and Control, 2022, 50(4): 163-171.
- [18] 黄健, 李建林, 李征. 退役锂离子电池健康状态快速评估方法[J]. 电力系统保护与控制, 2021, 49(12): 25-32.
HUANG Jian, LI Jianlin, LI Zheng. A state of health rapid assessment method for decommissioned lithium-ion batteries[J]. Power System Protection and Control, 2021, 49(12): 25-32.
- [19] 王萍, 范凌峰, 程泽. 基于健康特征参数的锂离子电池 SOH 和 RUL 联合估计方法[J]. 中国电机工程学报, 2022, 42(4): 1523-1534.
WANG Ping, FAN Lingfeng, CHENG Ze. A joint state of health and remaining useful life estimation approach for lithium-ion batteries based on health factor parameter[J]. Proceedings of the CSEE, 2022, 42(4): 1523-1534.
- [20] GUO Yu, YANG Dongfang, ZHANG Yang, et al. Online estimation of SOH for lithium-ion battery based on SSA-Elman neural network[J]. Protection and Control of Modern Power Systems, 2022, 7(3): 602-618.
- [21] XIAO Dianxun, FANG Gaoliang, LIU Sheng, et al. Reduced-coupling co-estimation of SOC and SOH for lithium-ion batteries based on convex optimization[J]. IEEE Transactions on Power Electronics, 2020, 35(11): 12332-12346.
- [22] 程泽, 杨磊, 孙幸勉. 基于自适应平方根无迹卡尔曼滤波算法的锂离子电池 SOC 和 SOH 估计[J]. 中国电机工程学报, 2018, 38(8): 2384-2393.
CHENG Ze, YANG Lei, SUN Xingmian. State of charge and state of health estimation of li-ion batteries based on

- adaptive square-root unscented Kalman filters[J]. Proceedings of the CSEE, 2018, 38(8): 2384-2393.
- [23] MA Lili, XU Yonghong, ZHANG Hongguang, et al. Co-estimation of state of charge and state of health for lithium-ion batteries based on fractional-order model with multi-innovations unscented Kalman filter method[J]. Journal of Energy Storage, 2022, 52.
- [24] WEI Zhongbao, ZHAO Jiyun, JI Dongxu, et al. A multi-timescale estimator for battery state of charge and capacity dual estimation based on an online identified model[J]. Applied Energy, 2017, 204(1): 1264-1274.
- [25] ZHANG Shuzhi, GUO Xu, DOU Xiaoxin, et al. A rapid online calculation method for state of health of lithium-ion battery based on coulomb counting method and differential voltage analysis[J]. Journal of Power Sources, 2020, 479(11).
- [26] 来鑫, 李云飞, 郑岳久, 等. 基于 SOC-OCV 优化曲线与 EKF 的锂离子电池荷电状态全局估计[J]. 汽车工程, 2021, 43(1): 19-26.
- LAI Xin, LI Yunfei, ZHENG Yuejiu, et al. An overall estimation of state-of-charge based on SOC-OCV optimization curve and EKF for lithium-ion battery[J]. Automotive Engineering, 2021, 43(1): 19-26.
- [27] WU Tiezhou, LIU Sizhe, WANG Zhikun, et al. SOC and SOH joint estimation of lithium-ion battery based on improved particle filter algorithm[J]. Journal of Electrical Engineering & Technology, 2022, 17(1): 307-317.
- [28] CHAOUI H, IBE-EKEOCHA C C. State of charge and state of health estimation for lithium batteries using recurrent neural networks[J]. IEEE Transactions on Vehicular Technology, 2017, 66(10): 8773-8783.
- [29] 李超然, 肖飞, 樊亚翔, 等. 基于深度学习的锂离子电池 SOC 和 SOH 联合估算[J]. 中国电机工程学报, 2021, 41(2): 681-692.
- LI Chaoran, XIAO Fei, FAN Yaxiang, et al. Joint estimation of the state of charge and the state of health based on deep learning for lithium-ion batteries[J]. Proceedings of the CSEE, 2021, 41(2): 681-692.
- [30] 王桥, 魏孟, 叶敏, 等. 基于 GWO-LSTM 与 LSSVM 的锂离子电池荷电状态与容量联合估计[J]. 汽车安全与节能学报, 2022, 13(3): 571-579.
- WANG Qiao, WEI Meng, YE Min, et al. Co-estimation of state of charge and capacity of lithium-ion battery based on GWO optimized LSTM and LSSVM[J]. Automotive Safety and Energy, 2022, 13(3): 571-579.
- [31] 孙丙香, 任鹏博, 陈育哲, 等. 锂离子电池在不同区间下的衰退影响因素分析及任意区间的老化趋势预测[J]. 电工技术学报, 2021, 36(3): 666-674.
- SUN Bingxiang, REN Pengbo, CHEN Yuzhe, et al. Analysis of influencing factors of degradation under different interval stress and prediction of aging trend in any interval for lithium-ion battery[J]. Transactions of China Electrotechnical Society, 2021, 36(3): 666-674.
- [32] MIENYE I D, SUN Yanxia. A survey of ensemble learning: concepts, algorithms, applications, and prospects[J]. IEEE Access, 2022, 10(1): 99129-99149.
- [33] GOU Bin, XU Yan, FENG Xue. An ensemble learning-based data-driven method for online state-of-health estimation of lithium-ion batteries[J]. IEEE Transactions on Transportation Electrification, 2021, 7(2): 422-436.
- [34] SAHA, GOEBEL K. Battery data set NASA ames prognostics data repository[EB/OL]. NASA Ames Research Center, Moffett Field, CA, 2007. <http://ti.arc.nasa.gov/project/prognostic-data-repository/#battery>.
- [35] Calce battery research group[EB/OL]. <https://web.calce.umd.edu/batteries/data.htm>.
-
- 收稿日期: 2022-08-15; 修回日期: 2023-01-21
- 作者简介:
- 毛玲(1981—), 女, 博士, 讲师, 研究方向为电动汽车有序充电、动力电池建模、状态估计及梯次利用、电动汽车与电网的互动等; E-mail: maoling2290@shiep.edu.cn
- 温佳林(1999—), 男, 硕士研究生, 研究方向为动力电池建模与状态估计; E-mail: wen914905850@126.com
- 赵晋斌(1972—), 男, 通信作者, 博士, 教授, 研究方向为电力电子装备研制、交直流系统稳定性分析与控制、新能源并网稳定分析与控制、无线电能传输技术等。E-mail: zhaojinbin@shiep.edu.cn
- (编辑 姜新丽)