

DOI: 10.13382/j.jemi.B2407368

一种精确估算电动汽车动力电池 SOC&SOH 的 循环门控模型*

彭自然 王顺豪 肖伸平 许怀顺 王思远

(湖南工业大学电气与信息工程学院 株洲 412007)

摘要:针对现有电动汽车动力电池 SOC 和 SOH 估计方法存在运算效率低、实时性差以及估算准确率低的问题,提出一种精确估算电动汽车动力电池 SOC&SOH 的循环门控模型。首先,改进门控循环单元 GRU 中更新门和重置门的计算方式并将候选隐藏状态激活函数替换为 ThLU 函数,缩短训练时间,有效缓解梯度消失。其次,优化序列数据输入方式,引入环形 GRU 计算模式,提升模型运算效率和估计精度。最后,基于卷积神经网络 CNN 和改进门控循环单元 IGRU,利用传感器采集到的电压 V、电流 I、温度 T 数据,实现全周期 SOH 和 SOC 同步估算,并将 SOH 估计值计入 SOC 估算,消除老化因素对 SOC 估算造成的不利影响。利用牛津大学电池数据集进行实验验证,结果表明,相比传统估计模型,循环门控模型 SOC 估计精确度有效提升,预测误差基本保持在 0.5% 以内。

关键词:电动汽车;动力电池;卷积神经网络;门控循环单元;ThLU

中图分类号: TN919.5; TP183

文献标识码: A

国家标准学科分类代码: 470.40

Cycle gating model for accurate estimation of SOC&SOH of power battery in electric vehicles

Peng Ziran Wang Shunhao Xiao Shenping Xu Huaishun Wang Siyuan

(School of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou 412007, China)

Abstract: Aiming at the problems of low computing efficiency, poor real-time performance and low estimation accuracy of the existing SOH and SOC estimation methods for electric vehicle power battery, a recurrent gated neural network model is proposed to accurately estimate the SOC & SOH of electric vehicle power battery. Firstly, the calculation methods of update gate and reset gate in the Gated Recurrent Unit are improved and the candidate hidden state activation function is replaced by the ThLU function to shorten the training time and effectively alleviate the gradient vanishing. Secondly, the sequence data input method is optimized, and the loop GRU calculation mode is introduced to improve the model computing efficiency and estimation accuracy. Lastly, the model is based on the convolutional neural network and the improved gate recurrent unit, the full-cycle SOH and SOC are simultaneously estimated using the voltage, current, and temperature data collected by the sensors, and the SOH estimation is included in the SOC estimation to eliminate the adverse effects of the aging factor on the SOC estimation. Experimental validation using the Oxford University battery dataset shows that compared with the traditional estimation model, the SOC estimation accuracy of the model proposed in this paper is effectively improved, and the prediction error basically stays within 0.5%.

Keywords: electric vehicle; power battery; convolutional neural network; gate recurrent unit; ThLU

0 引言

动力电池是电动汽车核心部件之一,通常由上百个

单体电池以串联或并联排列构成,最终实现电池组所需的电压和容量^[1-2]。受到环境温度、成组方式、充放电倍率、放电深度等其他因素的影响,动力电池内部容易出现 SEI 膜生长、电解液分解、锂离子电池自放电、电极活性

收稿日期: 2024-03-24 Received Date: 2024-03-24

* 基金项目: 国家重点研发计划基金资助项目(2019YFE0122600)、湖南省教育厅重点科研项目(22A0423)、湖南省自然科学基金项目(2023JJ60267, 2022JJ50073)资助

材料损失、集流体腐蚀等现象最终导致容量衰退^[3-5]。动力电池容量可衰退至额定容量的 70%~80%，严重影响电动汽车的电能补给和使用环境，形成一定的安全隐患。更重要的是，容量衰退会导致荷电状态 SOC 估计误差逐步增大，使得用户错误估计电动汽车续航里程，影响日常出行。因此，为了提高电动汽车安全性和改善用户的驾驶体验，电池管理系统 BMS 必须精确估计电动汽车动力电池的老化程度 SOH 以及荷电状态 SOC^[6-8]。

目前针对动力电池 SOH 与 SOC 估计方法主要分为基于模型的估算方法^[9-10]和基于数据驱动的估算方法^[11-12]。基于模型的估算方法通常是建立反映电池内部物理机制的电路模型，一般分为一阶 RC 和二阶 RC 等效电路模型。对于不同老化程度的电池，依据提取到的电压等数据得到模型参数的变化进而完成 SOH 和 SOC 估算。但这种估计方法高度依赖所建等效电路的精度，一旦电路模型的精度不够，将会严重影响 SOH 和 SOC 估计。基于数据驱动的估算方法主要通过从充放电循环过程获取的大量电压、电流、温度数据中提取与电池 SOH 和 SOC 相关的特征，利用神经网络模型最终完成 SOH 与 SOC 估计。其无需考虑电池内部复杂的化学反应和结构的变化，估计精确度高从而得到广泛的使用。

近年来，机器学习^[13-14]、深度学习^[15-16]由于具有能够处理复杂数据并自动提取复杂特征、泛化能力强的优势逐步应用于 SOH 和 SOC 的估计。文献[17]介绍了一种基于双层集成极限学习机 ELM 的 SOH 和 SOC 估计方法，通过提取电池健康状态 HI 映射与 SOH 的关系，然后采用安时积分法修正 SOC，实现 SOH 和 SOC 联合估计，但这种方法需要人工手动提取特征，造成大量人力物力的浪费，且不能完全反映采集数据与 SOH 和 SOC 的关系。文献[18]提出了一种基于深度学习的动力电池 SOH 和 SOC 联合估算的方法，采用卷积神经网络 CNN 将动力电池满充过程中的电压、温度、电流值映射到当前循环的 SOH 值，然后将 SOH 作为特征值利用门控循环单元 GRU 实现 SOC 估计，获得较高的精度。

但采用 GRU 估计 SOC 过程中仍然存在计算效率低、梯度消失、储存数据占据空间问题。用长序列数据训练一个有效的 GRU 依旧很耗时，为减少参数量，需要对 GRU 内部的计算方式做出一些改进。文献[19]提出一种轻量型门控循环单元，在一定程度上减少了模型参数量，但同时需要更长的执行时间和更大的学习率才能取得较好的效果，不利于实际应用。门控循环单元 GRU 尽管在一定程度上缓解传统循环神经网络梯度爆炸和梯度消失的问题，但在计算候选隐藏状态时饱和激活函数 Tanh 仍会带来梯度消失的问题。文献[20]提出将原始 GRU 的候选隐藏状态 Tanh 激活函数替换为非饱和激活函数 Relu 激活函数，缓解饱和函数引起的梯度消失。但

ReLU 激活函数在 x 小于 0 情况下存在硬饱和的现象，会出现权重无法更新，从而出现神经元死亡的现象。此外，长序列数据占据大量存储空间，导致可用空间不足进而引起系统性能下降造成系统崩溃和数据丢失。电动汽车电池管理系统 BMS 存储空间是有限资源，如果传感器采集到的所有数据均需要储存，则占据大量存储空间，需要额外的投资来扩展存储设备或采购更大容量的存储介质，增加电池管理系统 BMS 的运维成本和维护复杂性^[21]。

针对以上动力电池 SOC 和 SOH 的估计存在的问题，构建了基于门控循环单元的 CNN-IGRU 预测模型，以精确估计电动汽车在正常运行时动力电池的健康状态和荷电状态。具体贡献为：

1) 针对传统 GRU 模型存在计算效率低以及梯度消失的问题，通过优化 GRU 模型更新门和重置门的计算方式，并且将候选隐藏状态中的 Tanh 激活函数替换为线性修正单元 ThLU 激活函数，缩短了 GRU 模型的训练时间，有效缓解模型梯度消失现象。

2) 针对储存过多数据引发存储空间不足的问题，优化序列数据输入方式，引入环状 GRU 网络结构，减少数据存储空间，降低计算资源，提高运算效率。

3) 考虑到动力电池健康状态 SOH 对荷电状态估算的影响，将健康状态 SOH 作为特征量参与荷电状态 SOC 的估算，采用 CNN-IGRU 模型实现 SOH 和 SOC 的联合估算，提高电动汽车在实际运行过程中 SOC 估算准确率。

1 相关工作

1.1 SOH 和 SOC 关联性分析

电池健康状态^[22](state of health, SOH)，通常用于表征电池的老化衰退程度，具体定义为当前循环可用的最大电荷容量与电池生产出厂时的额定容量之比，如式(1)所示。电池荷电状态^[23](state of charge, SOC)，一般用于表征电池的剩余电量，具体定义为当前电池剩余可用的总电荷量与当前可用的最大电荷容量之比，如式(2)所示。

$$SOH(C) = \frac{Q(C)_{\text{MAX}}}{Q_N} \quad (1)$$

$$SOC(t) = \frac{Q(t)}{Q(t)_{\text{MAX}}} \quad (2)$$

其中， $Q(C)_{\text{MAX}}$ 代表当前循环可用的最大电荷容量， Q_N 表示为电池生产出厂时的额定容量， $SOC(t)$ 为不同时刻 t 的 SOC 值， $Q(t)$ 代表当前电池剩余可用的总电荷量， $SOH(t)$ 代表当前循环电池的健康状态。

在动力电池使用过程中，单次循环的 SOH 由于变化较小可以忽略不记，在估算过程中将每次循环 SOH 视为

为固定值, SOC 与 SOH 的关系如式(3)所示。

$$SOC(t) = \frac{Q(t)}{Q_N \times SOH(t)} \quad (3)$$

从重新推导的式(3)可以看出,健康状态 SOH 与荷电状态 SOC 具有非常强的线性关系。因此本文提出将电池 SOH 作为特征估算电池 SOC, 这样既可以考虑电池组在工作中受内部和外部因素影响老化的情况, 及时的更换电池组中的电池, 提高电池的利用率; 也可以利用 SOH 作为特征提升 SOC 估计的精度, 方便电动汽车用户能够根据电量做出合理的充电规划和出行计划。

1.2 门控循环单元 GRU

门控循环单元 (gate recurrent unit, GRU) 采用门控机制控制信息的流动, 能够更好的捕捉长序列数据的依赖关系。相比长短期记忆神经网络 (long short-term memory, LSTM) 引入的遗忘门、输入门、输出门 3 个门, 门控循环单元仅引入重置门和更新门, 参数量减少的同时, 在某些任务中运算速度和精确度的表现均优于 LSTM。GRU 结构图如图 1 所示。

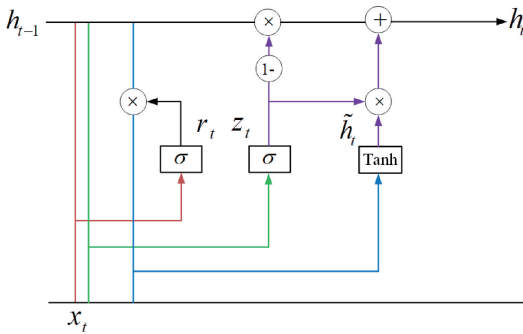


图 1 门控循环单元 GRU 结构图

Fig. 1 Structure of the gated recurrent unit

门控循环单元 GRU 中的重置门 r_t 、更新门 z_t 、候选隐

藏状态 \tilde{h}_t 、最终隐藏状态 h_t 的计算方式分别如式(4)~(7)所示。

$$r_t = \sigma(x_t W_{xr} + h_{t-1} U_{hr} + b_r) \quad (4)$$

$$z_t = \sigma(x_t W_{xz} + h_{t-1} U_{hc} + b_z) \quad (5)$$

$$\tilde{h}_t = \text{Tanh}(x_t W_{xh} + (r_t \odot h_{t-1}) U_{hh} + b_h) \quad (6)$$

$$h_t = z_t \odot \tilde{h}_t + (1 - z_t) \odot h_{t-1} \quad (7)$$


其中, \odot 为逐元素乘积, W_{xr} 、 W_{xz} 、 W_{xh} 、 U_{hr} 、 U_{hc} 、 U_{hh} 为权重参数, b_r 、 b_z 、 b_h 为偏置函数, σ 为 Sigmoid 激活函数, Tanh 为双曲正切激活函数。

1.3 SOH 和 SOC 估计

在动力电池充放电过程中选取与 SOH 相关性较高的特征对于 SOH 估计至关重要。文献[24]介绍充电阶段相比放电阶段更加可控、相对温和、稳定的特性, 更易


探索与电池 SOH 的相关性。以美国航空航天局卓越测试中心 (PCoE) 的 B005 电池为例, 观察电池在不同循环充电过程中的电流、温度、电压的变化曲线的差异以及不同循环次数下电池容量的变化情况, 分别如图 2(a)~(d) 所示。

从图 2 中可以看出, 不同循环次数下的电压曲线、温度曲线、电流曲线存在明显的差异, 不同循环次数下的容量曲线总体呈现下降的趋势。电动汽车用户充电习惯通常为: 在 SOC 为 40%~75% 的区间内开始充电, 直至 SOC 为 100% 结束充电, 各次充电的 SOC 变化量为 25%~




(a) 不同循环次数电压曲线

(a) Voltage curves for different number of cycles




(b) 不同循环次数的电流曲线

(b) Current curves for different number of cycles



(c) 不同循环次数的温度曲线

(c) Temperature profiles for different number of cycles



(d) 不同循环次数的容量曲线
(d) Capacity curves for different number of cycles

图 2 充电过程不同循环电压、电流、温度及容量变化曲线

Fig. 2 Voltage, current, temperature and capacity change curves for different cycles of charging process
数据采集




图 3 SOH 估计流程图

Fig. 3 Flowchart of SOH estimation

同老化状态下的荷电状态 SOC 也会存在明显的差异性。不同 SOH 值下充电阶段 SOC 变化曲线如图 4 所示,不同 SOH 值下放电阶段 SOC 变化曲线如图 5 所示。




图 4 不同 SOH 值下充电阶段 SOC 变化曲线

Fig. 4 SOC change curve of charging stage under different SOH




图 5 不同 SOH 值下放电阶段 SOC 变化曲线

Fig. 5 SOC curves in the discharge stage at different SOH

由图 4 和 5 可以看出,电池在不同的健康状态 SOH 下 SOC 的变化不同。SOH 值越小,老化程度越严重,其对应充电阶段 SOC 由 0% 达到 100% 时间提前,放电阶段

60%。因此,考虑到电动用户实际充电习惯,本文选择部分充电过程中的电压 V 、电流 I 、温度 T 值 $[V_1, I_1, T_1, V_2, I_2, T_2, \dots, V_n, I_n, T_n]$ 作为 SOH 估计模型的特征。基于充电阶段的电池容量更能反映电池 SOH 变化的特性,SOH 估计采用充电阶段的电池容量。选取卷积神经网络 (convolutional neural network, CNN) 作为预测 SOH 模型,既避免了人工手动提取特征的过程,又能够自适应的从充电阶段采集到的电压、电流、温度数据中提取与 SOH 相关的特征,最终实现 SOH 估计。SOH 估计具体流程如图 3 所示。

电动汽车在充电阶段依据 SOC 估计电池的实际电量,在放电行驶过程依据 SOC 估计剩余行驶里程,整个充放电循环的 SOC 至关重要。因此主要估计充电过程和放电过程中的 SOC 变化情况,实现全使用周期 SOC 估计。动力电池 SOH 和 SOC 之间存在最大容量的关系,不

SOC 由 100% 达到 0% 的时间同样提前,因此为了准确估计 SOC 值就必须考虑 SOH 的影响。将电池充放电过程当前时刻的电压 V_t 、电流 I_t 、温度 T_t 、前一时刻 SOC 值 SOC_{t-1} 以及当前循环 SOH 值 $[V_t, I_t, T_t, SOC_{t-1}, SOH]$ 作为 SOC 估计的特征。SOC 估算流程如图 6 所示。

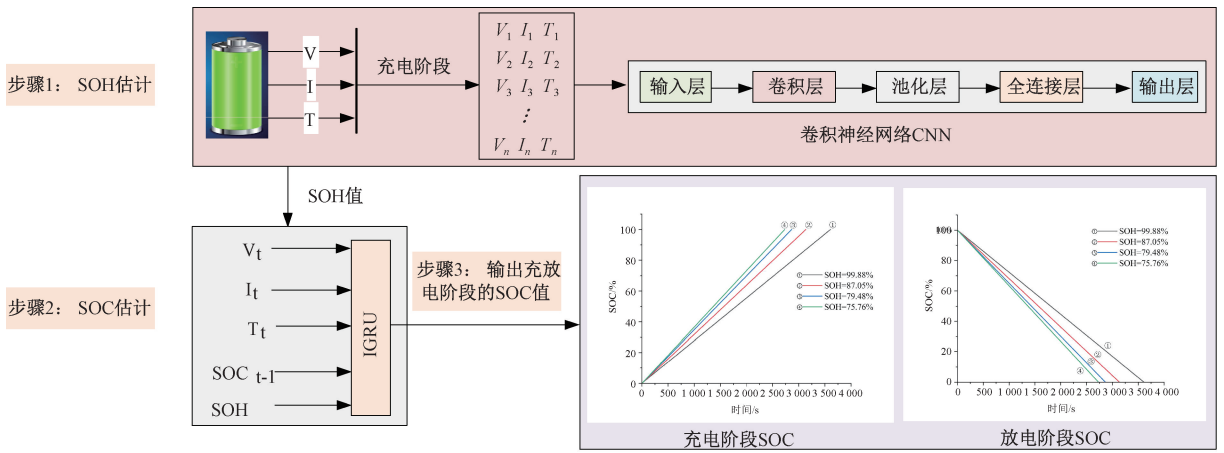


图 6 SOC 估计流程图

Fig. 6 Flowchart of SOC estimation

2 构建环状门控循环网络模型

2.1 构造变体更新门和重置门

电动汽车电池管理系统 BMS 内部传感器采集的电压, 电流和温度数据属于长序列数据。用长序列数据训练一个有效的 GRU-RNN 是非常耗时的, 因此迫切需要进行进一步研究减少 GRU 模型参数, 提高训练效率。针对上述问题, 改进了传统门控循环单元 GRU 更新门和重置门的计算方式, 构造变体更新门和重置门。具体来讲, 重置门和更新门仅使用先前的隐藏状态 h_{t-1} 和偏置量 b 来计算。计算方法如式(8)、(9)所示。

$$r_t = \sigma(h_{t-1}U_{hr} + b_r) \quad (8)$$

$$z_t = \sigma(h_{t-1}U_{hc} + b_z) \quad (9)$$

改进后的变体门控与传统门控对比如图 7 所示。




图 7 传统门控与变体门控对比

Fig. 7 Traditional gating compared to variant gating

图 7 中左半部分传统门控中更新门 z_t 决定保留来自先前隐藏状态的信息以及应该接受多少来自当前输入的新信息, 重置门 r_t 决定忽略多少先前隐藏状态的信息以及重置当前时刻输入的影响。提出的变体门控如图 7 中右半部分所示, 变体门控中更新门 z_t 仅决定保留来自先

前隐藏状态的信息, 重置门 r_t 仅忽略来自先前隐藏状态的信息。相比传统门控的优势为: 一方面在于减轻了更新门和重置门对当前时刻输入 x_t 的依赖程度, 同时延续更新候选隐藏状态和隐藏状态的功能; 另一方面, 当前时刻输入 x_t 只参与到候选隐藏状态的计算, 能够在参与度较少的情况下, 最终实现隐藏状态的输出。

当权重参数 W 为 $N \times M$ 矩阵, U 为 $N \times N$ 矩阵, 偏置项 b 为 $N \times 1$ 矩阵, 当前时刻输入为 M 维时, 传统门控循环单元的总参数量等于 $3 \times (N^2 + NM + N)$, 而本节提出的变体门控相比传统门控循环单元总参数量减少 $2 \times NM$, 即最终的总参数量为 $3(N^2 + N) + NM$ 。由此看来, 提出的变体更新门和重置门不仅减少了总参数量, 提高了运算效率, 而且能够实现传统门控循环单元输出隐藏状态的功能。

2.2 线性修正单元 ThLU 激活函数

门控循环单元隐藏候选状态计算中采用了 Tanh 激活函数, 存在一定的梯度消失现象, 不适用于深度神经网络的训练。ReLU 激活函数可以保证信息传输更加直接, 相比饱和的 Tanh 激活函数, ReLU 不存在饱和激活函数带来的梯度消失问题, 且能更好地配合残差信息的传递。更改后隐藏候选状态计算方法如式(10)所示。

$$\tilde{h}_t = ReLU(x_t W_{sh} + (r_t \odot h_{t-1}) U_{hh} + b_h) \quad (10)$$

但 ReLU 激活函数在 $x < 0$ 情况下存在硬饱和的现象, 会出现权重无法更新, 从而出现神经元死亡的现象。为了解决这种现象, 基于双曲正切 Tanh 函数负半轴可以减少神经元细胞死亡的优势以及 ReLU 激活函数在正半轴不存在梯度消失的优势, 采用一种基于 Tanh 函数的线性整流函数 (tangent based on rectified linear unit, ThLU) 作为门控循环单元 GRU 候选隐藏状态计算的激活函数。ThLU 函数公式如式(11)所示。

$$ThLU(x) = \begin{cases} x, x \geq 0 \\ \frac{e^x - e^{-x}}{e^x + e^{-x}}, x < 0 \end{cases} \quad (11)$$

为了更直观的分析 ThLU 函数,对 Tanh 函数、ReLU 函数、ThLU 函数进行对比分析,如图 8 所示。




图 8 Tanh 函数、ReLU 函数、ThLU 函数曲线

Fig. 8 Tanh function, ReLU function, ThLU function curve

从图 8 中可以看出,当 $x \geq 0$ 时, ThLU 激活函数的输出与 ReLU 激活函数的输出相同,大于 Tanh 激活函数的输出;当 $x < 0$ 时, ThLU 激活函数的输出与 Tanh 激活函数的输出相同,小于 ReLU 激活函数的输出。从整体输出可以分析出, ThLU 激活函数融合了 Tanh 激活函数和 ReLU 激活函数两种函数的优点,更接近 0 均值。

最终候选隐藏状态的计算方式如式(12)所示。

$$\tilde{h}_t = ThLU(x_t W_{sh} + (r_t \odot h_{t-1}) U_{hh} + b_h) \quad (12)$$

改进后的门控循环单元 GRU 的计算公式如式(13)所示。

$$\begin{cases} r_t = \sigma(h_{t-1} U_{hr} + b_r) \\ z_t = \sigma(h_{t-1} U_{hc} + b_z) \\ \tilde{h}_t = ThLU(x_t W_{sh} + (r_t \odot h_{t-1}) U_{hh} + b_h) \\ h_t = z_t \odot \tilde{h}_t + (1 - z_t) \odot h_{t-1} \end{cases} \quad (13)$$

改进后的 GRU 结构如图 9 所示。

序列数据输入多个 GRU 模块的计算过程,如图 10 所示。

2.3 优化数据输入方式,引入环状 GRU 计算模式

门控循环单元 GRU 的计算效率与数据输入方式密切相关,传统计算方式为序列数据 $[x_1, x_2, x_3, x_4, \dots, x_n]$ 按照时间顺序依次输入 N 个门控循环单元 GRU,最终在末尾 GRU 中获取输出,计算流程如图 11 所示。由于 GRU 的数量与输入数据量成正比,大量序列数据参与计算会造成运算复杂并且占据大量存储空间影响模型的运算效率。

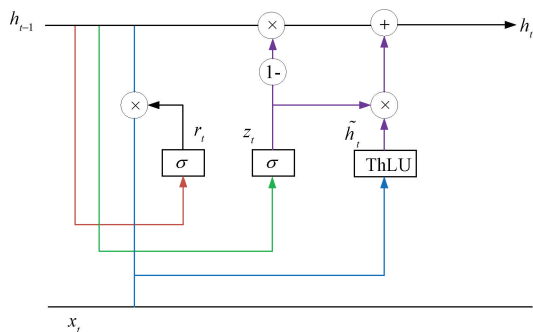


图 9 改进后的 GRU 结构图

Fig. 9 Diagram of the improved GRU structure




图 10 GRU 循环结构

Fig. 10 GRU cycle structure




图 11 传统门控循环单元 GRU 计算流程

Fig. 11 Conventional calculation process

传统的 GRU 计算方式如式(14)所示。

$$h_t = GRU_n(x_1, x_2, x_3, x_4, x_n, h_{t-1}) \quad (14)$$

提出优化序列数据的输入方式,引入环形 GRU 计算模式,从而实现减少数据存储空间,提高运算效率目的。环形 GRU 计算方式如图 12 所示,计算方法如式(15)所示。

$$\begin{cases}
 h_t = GRU_n(x_1, x_2, x_3, x_4, \dots, x_n, h_{t-1}) \\
 h_t = GRU_1(x_{n+1}, x_2, x_3, x_4, \dots, x_n, h_{t-1}) \\
 h_t = GRU_2(x_{n+1}, x_{n+2}, x_3, x_4, \dots, x_n, h_{t-1}) \\
 h_t = GRU_3(x_{n+1}, x_{n+2}, x_{n+3}, x_4, \dots, x_n, h_{t-1}) \\
 h_t = GRU_4(x_{n+1}, x_{n+2}, x_{n+3}, x_{n+4}, \dots, x_n, h_{t-1}) \\
 \vdots \\
 h_t = GRU_n(x_{n+1}, x_{n+2}, x_{n+3}, x_{n+4}, \dots, x_{2n-3}, x_{2n-2}, x_{2n-1}, x_{2n}, h_{t-1})
 \end{cases}
 \quad (15)$$

其中, GRU_x 代表第 x 个 GRU 单元, h_t 是隐藏状态, h_{t-1} 是前一时刻的隐藏状态。优化序列数据输入方式具

体流程为:首先,采用 N 个固定数量的 GRU, 基于数据结构队列中数据先进先出的原理, 调动 front 和 rear 指针, 将后续采集到的 $[x_{n+1}, x_{n+2}, x_{n+3}, x_{n+4}, \dots, x_{2n-1}, x_{2n}]$ 依次从队尾入队, 原先采集的数据 $[x_1, x_2, x_3, x_4, \dots, x_n]$ 依次从队头出队, 从而实现数据之间的替换。优化序列数据输入方式后, 采用环形 GRU 模式计算, 具体步骤为: 实现一个数据出队操作时, 输出结果在数据替换对应的门控循环单元 GRU 中输出, N 个固定数量门控循环单元 GRU 依次按顺序首尾连接, 构成一个环形的 GRU 计算模型, 当所有数据循环替代时, 最终结果也循环输出。

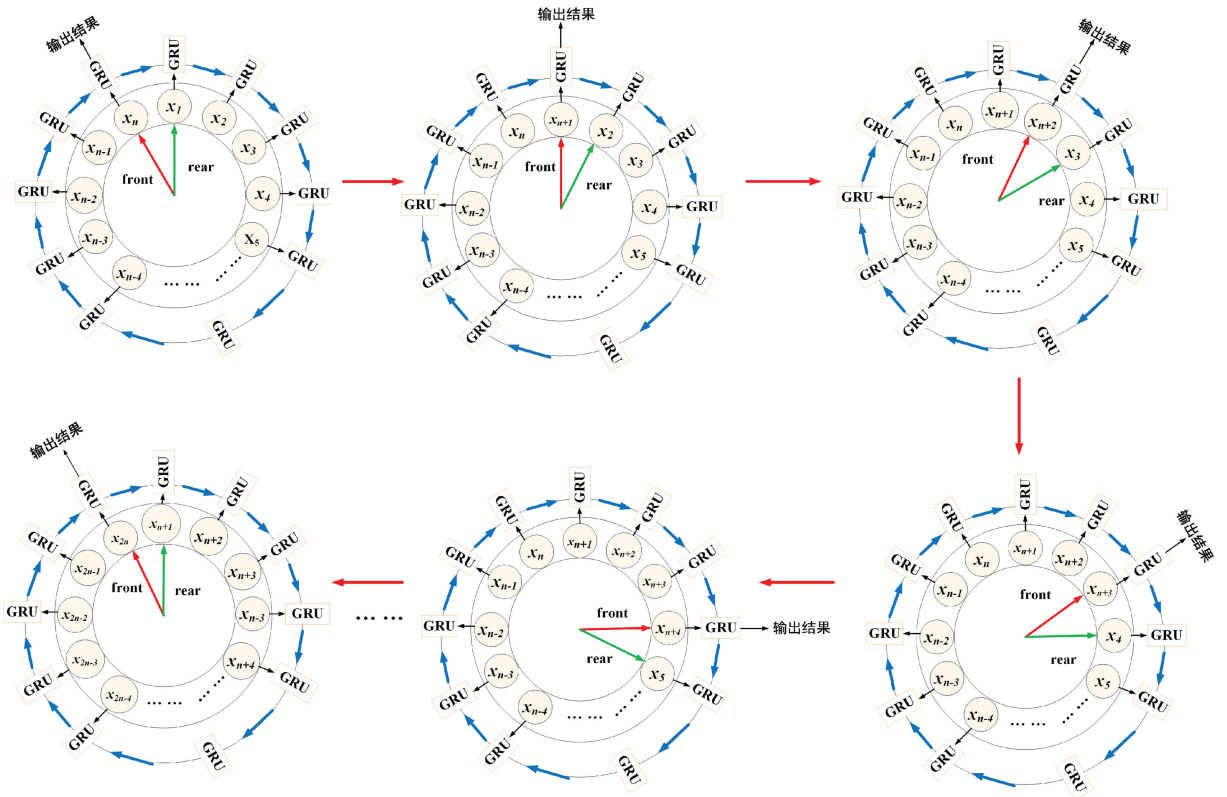


图 12 环形 GRU 计算流程图

Fig. 12 Flowchart of the circular GRU calculation

优化数据输入方式, 环形 GRU 计算模式的优势在于减少计算量, 提高运算效率以及提高 SOC 估算精度。首先对减少运算量, 提高运算效率机理进行分析, 环形 GRU 简易结构图如图 13 所示。

从图 13 中可以看出, GRU 内部的计算方式简化为 H、X、Z 3 个模块。分析 1: 插入数据 x_{t-1} 操作, 将 x_{t-1} 插入到 Rear 的 GRU 根节点的输入端, 如图 13 所示替换 x_{t+N} , 通过 X 网络模块计算产生中间结果 \hat{x} 。分析 2: $Front = (Front + 1) \% N$, $Rear = (Rear + 1) \% N$ 。分析 3: 从 Front 的根节点 h_{k-1} 开始, 执行如下操作。1) 计算 H 模块, 得到中间结果 $\widehat{h_{k-1}}$ 。2) 将缓存的中间结果 \widehat{x} 取出, 与




图 13 环形 GRU 简易结构图

Fig. 13 Ring GRU simple structure diagram

$\widehat{h_{k-1}}$ 结合起来共同计算 Z 模块, 得到输出 h_k 。

从以上计算进程分析, 每轮计算过程利用了 X 模块

计算的中间结果,只需执行 H 模块与 Z 模块的运算。H、X、Z 模块计算量近似相等,即 $O(H) = O(X) = O(Z) = C$, 则环形 GRU 一轮运算的总计算量为 $O(n) = n(O(H) + O(Z)) = 2Cn$ 。相比传统流水线型 GRU 结构,环形 GRU 模式要节约 1/3 的计算量。

其次,对环形 GRU 提高 SOC 估算精度进行分析。传统 GRU 和环形 GRU 估计 SOC 模式对比如图 14 所示。




图 14 SOC 估计模式图

Fig. 14 SOC estimation model diagram

从图 14 可以看出,环形 GRU 估计 SOC 模式摒弃传统 GRU 采用全部域估计 SOC 的做法,根据阶段性域实时更新 SOC。这种方法的优势在于能够充分利用实时采集的数据,以区域性的数据变化趋势作为衡量 SOC 值的标准,减弱强输入数据之间过分依赖,可以提高 SOC 估计的精确度。

综上所述,提出一种针对 SOH 和 SOC 估计的方法,构建了基于门控循环单元的 CNN-IGRU 预测模型。该模型能够利用电动汽车在充电阶段和放电阶段由传感器采集到的电压、电流、温度数据实现全使用周期内动力电池的健康状态 SOH 和荷电状态 SOC 的估算,并最终反馈到电动汽车电池管理系统 BMS。总体流程如图 15 所示。

3 实验与分析

为了验证所提模型对电动汽车动力电池 SOH 和

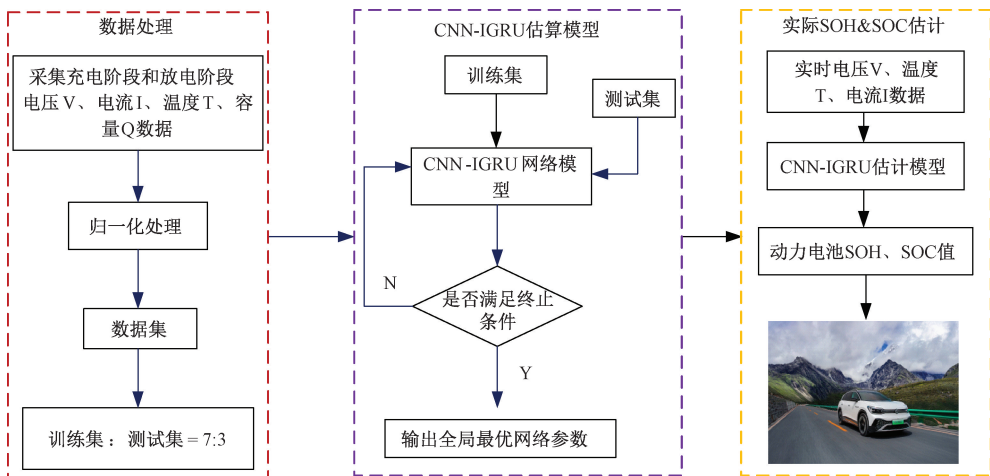


图 15 总体流程图

Fig. 15 Flowchart of overall

SOC 估计的有效性,基于牛津大学退化电池数据集进行实验。对比实验分为未考虑老化影响仅基于 GRU 的 SOC 估计、考虑 SOH 影响基于 CNN 和 GRU 的 SOC 估计 CNN-GRU 两组实验。为了评估更改 GRU 更新门和重置门计算方式、候选隐藏状态计算过程中 Tanh 激活函数改为 Thlu 激活函数、优化序列数据输入方式,引入环形 GRU 计算模式 3 种改进对 GRU 估计 SOC 的影响,设计了消融实验。

3.1 BMS 数据采集分析流程

电动汽车动力电池包通常由数十个电池模组构成,电池模组由上百电芯以并联或串联形式构成。电池管理系统 BMS^[25-27] 由采集模块、通信模块和数据分析模块组成,保障着电池的安全性、性能和寿命。经传感器采集到

的电压,电流,温度信息通过 CAN 通信或菊花链通信由从板 CSC 传递到主板 BCU,由主板 BCU 完成健康状态 SOH 和荷电状态 SOC 的估计工作。动力电池数据采集分析流程如图 16 所示。



图 16 动力电池数据采集分析

Fig. 16 Power battery data acquisition and analysis

3.2 动力电池数据集

牛津大学电池数据集是牛津大学发布的公共数据集,主要用于电池的健康状态和和荷电状态估计。测试

对象为 8 块额定容量 740 mA · h, 额定电压 4.2 V 的锂电池, 它们的编号记为 Cell1, Cell2, …, Cell8。这些电池在环境温度 40 °C 下进行了循环充放电测试, 具体测试步骤为: 首先使用 1.48 A 的恒流对电池进行充电, 直至电池达到 4.2 V, 然后在模拟电动汽车动态工况环境下对电池以 0.74 A 的恒流对电池进行放电直至电池电压达到截止电压 2.7 V, 重复进行充放电并每隔 100 次循环记录当前循环充电阶段和放电阶段的电压 V、电流 I、温度 T、容量值, 最终能够对大约 15 万个数据点进行采样。本实验将 Cell4 和 Cell8 用作测试样本, 其余 6 个电池用作训练样本训练 SOH 和 SOC 估计模型。

3.3 实验设置

实验平台为 CPU (Intel Core i7-8550U 1.8 GHz)、GPU (NVIDIA GeForce MX130), 编译平台为 Pycharm, 编译器为 Pytorch。动力电池 SOH 和 SOC 联合估计模型中卷积神经网络 CNN 由 1 个输入层、4 个卷积层和池化层构成的卷积块、1 个 Flatten 层、1 个全连接层、1 个输出层构成。其中输入层的结构为 256×3, 256 代表序列的长度, 即采样点的个数, 3 代表电压、电流、温度 3 个类别。卷积块内的卷积层包含 3 个滤波器, 每个滤波器包含 64 个卷积核, 卷积核的大小为 32×1, 卷积块内的池化层包含 3 个最大池化层滤波器, 每个最大池化层的大小为 2×1, Flatten 层、全连接层、输出层的节点分别设置为 1 024、256、1。门控循环单元 GRU 由输入层、1 个隐藏层, 全连接层和输出层构成, 节点数分别设置为 5、50、50、1。卷积神经网络 CNN 和门控循环单元 GRU 将均方误差 MSE

作为目标函数, 采用 Adam 优化算法, 迭代次数分别为 500 次和 200 次。

训练样本和测试样本用于 SOH 和 SOC 估算模型之前需要经过归一化处理, 本文采用最大最小归一化, 将数值映射到 [0, 1] 范围内, 如式 (16) 所示。

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (16)$$

其中, x' 代表归一化后的数据, x 为原始数据, $\min(x)$ 为原始数据中的最小值, $\max(x)$ 为原始数据中的最大值。

采用平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean square error, RMSE) 作为评价指标, 如式 (17)、(18) 所示。

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (17)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (18)$$

3.4 对比试验

为了验证所提算法的有效性, 以牛津大学电池数据集为基础, 将提出的 CNN-IGRU 算法与 GRU、CNN-GRU 两组模型设置为对比试验。将牛津大学电池退化数据集的 Cell4 和 Cell8 电池作为测试集, 将剩余的 6 个电池作为训练集训练 SOH 和 SOC 估计模型。在 Cell4 和 Cell8 电池上 CNN-IGRU 模型、GRU 模型、CNN-GRU 模型的估算结果如表 1 所示。

表 1 不同电池不同模型估计 SOH 和 SOC 的 MAE 和 RMSE 值

Table 1 MAE and RMSE values of SOH and SOC estimated by different models for different batteries

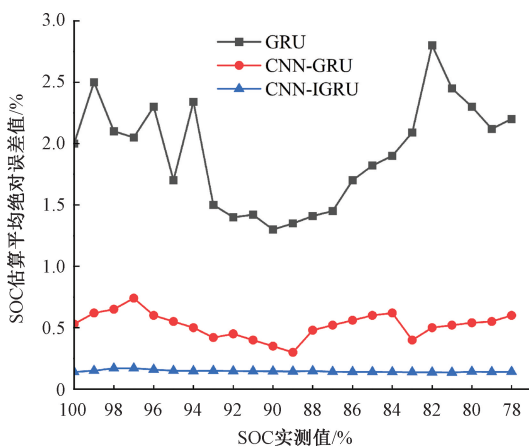
电池编号	估计模型	SOH 估算 MAE 平均值/%	SOH 估算 RMSE 平均值/%	SOC 估算 MAE 平均值/%	SOC 估算 RMSE 平均值/%
Cell4	GRU			2.07	2.78
	CNN-GRU	1.18	1.57	0.53	0.78
	CNN-IGRU	1.18	1.57	0.14	0.25
Cell8	GRU			2.35	2.97
	CNN-GRU	0.74	0.93	0.75	1.02
	CNN-IGRU	0.74	0.93	0.24	0.38

为了更直观的体现算法的优越性, 接下来以 Cell4 电池为例, 对不同模型下 SOC 估计效果进行讨论。SOC 估算平均绝对误差如图 17(a) 所示, SOC 估算均方根误差如图 17(b) 所示。

从图 17(a)、(b) 中可以看出未考虑电池健康状态 SOH 情况下直接采用 GRU 模型实现 SOC 估计与考虑电池健康状态 SOH 情况下采用 CNN-GRU 模型实现 SOC 估计相比, 平均绝对误差 MAE 和均方根误差 RMSE 都比较大并且稳定性较差。提出的 CNN-IGRU 算法充分考虑了电池老化对 SOH 估计的影响, 简化 GRU 的网络结构, 优化数据输入方式, 采用环形 GRU 计算方法提高了 SOC

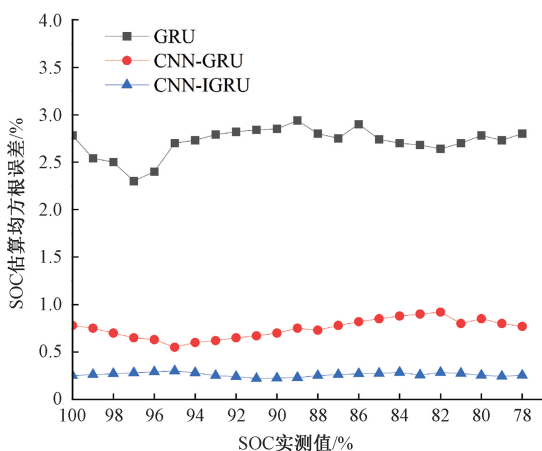
的估算精度, 稳定性非常好。相比 GRU 模型, SOC 估算平均绝对误差 MAE 平均值下降了 94.6%, 均方根误差 RMSE 平均值下降了 91%; 相比 CNN-GRU 模型 SOC 估算平均绝对误差 MAE 平均值下降了 73.6%, 均方根误差 RMSE 平均值下降了 67.9%。

由于实际应用中难以完全准确地获取电池的初始 SOC, 导致初始 SOC 通常存在误差, 因此算法在存在初始 SOC 误差下的校正能力和估计精度显得尤为重要。初始 SOC 的误差与电池的容量和电化学特性密切相关, 即与电池健康状态 SOH 密切相关。因此为了评估算法在存在初始 SOC 误差下的校正能力和估计精度, 以 Cell4 电



(a) SOC 估算平均绝对误差

(a) Mean absolute error of SOC estimation



(b) SOC 估算均方根误差

(b) Root mean square error of SOC estimation

图 17 Cell4 电池在不同 SOH 下 SOC 估算结果

Fig. 17 SOC estimation results for cell 4 at different SOH


池为例,分别展示其健康状态 SOH=98% (初始 SOC 误差为 2%)、SOH=91% (初始 SOC 误差为 9%)、SOH=78% (初始 SOC 误差为 22%) 时的 SOC 变化曲线,如图 18(a)~(c) 所示。

在不同初始 SOC 误差下,CNN-IGRU 算法的校正能力与估计精度如表 2 所示。

表 2 不同初始 SOC 误差条件下算法估算 SOC 结果


Table 2 Algorithmic estimation of SOC results under different initial SOC error conditions

初始 SOC 误差	SOC 估算	
	MAE/%	RMSE/%
2%	0.17	0.27
5%	0.182	0.29
9%	0.15	0.22
14%	0.167	0.27
17%	0.175	0.278
21%	0.142	0.253




(a) SOH=98%, SOC 误差 MAE=0.17%, RMSE=0.27%

(a) SOH=98%, MAE=0.17%, RMSE=0.27%



(b) SOH=91%, SOC 误差 MAE=0.15%, RMSE=0.22%

(b) SOH=91%, MAE=0.15%, RMSE=0.22%



(c) SOH=78%, SOC 误差 MAE=0.142%, RMSE=0.253%

(c) SOH=78%, MAE=0.142%, RMSE=0.253%

图 18 不同 SOH 下 SOC 估算曲线

Fig. 18 SOC estimation curves at different SOH

由图 18 和表 2 可得,CNN-IGRU 算法对不同初始 SOC 误差条件下 SOC 估算的校正能力和估计精度有很好的效果,能够有效的跟踪 SOC 实际变化情况。

3.5 消融实验

循环门控单元对初始 GRU 估算 SOC 算法做出了 3 点改进:1)更改门控循环单元 GRU 中更新门和重置门的

计算方式 (GRU- r_t-z_t)。2) 将门控循环单元 GRU 中候选隐藏状态的 Tanh 激活函数替换为 ThLU 激活函数 (GRU-ThLU)。3) 优化序列数据输入方式, 引入环形 GRU 计算模式 (GRU-circle)。为了验证以上改进方法的有效性, 设置两种消融实验:

1) 为了验证单独改进模块的优化效果, 以原始 CNN-GRU 模型为基础, 分别只增加一种改进算法。2) 为了验证两种改进模块相结合的优化效果, 以原始 CNN-GRU 模型为基础, 每次只允许增加两种算法。实验结果如表 3 所示, 其中“√”表示加入该改进算法。

表 3 消融实验结果

Table 3 Results of ablation experiments

算法模型	r_t-z_t	ThLU	circle	4 号电池 SOC 估算	4 号电池 SOC 估算	8 号电池 SOC 估算	8 号电池 SOC 估算
				MAE 平均值/%	RMSE 平均值/%	MAE 平均值/%	RMSE 平均值/%
CNN-GRU				0.53	0.78	0.75	1.02
CNN-GRU- r_t-z_t	√			0.49	0.73	0.69	0.97
CNN-GRU-ThLU		√		0.36	0.42	0.46	0.68
CNN-GRU-circle			√	0.28	0.37	0.38	0.52
CNN-GRU- r_t-z_t -ThLU	√	√		0.34	0.4	0.62	0.91
CNN-GRU- r_t-z_t -circle	√		√	0.25	0.3	0.35	0.49
CNN-GRU-ThLU-circle		√	√	0.17	0.26	0.31	0.42
CNN-IGRU(本文)	√	√	√	0.14	0.25	0.24	0.38

表 3 中消融实验表明, 相比第 1 组实验, 第 2 组实验采用了更改更新门和重置门的计算方式, 在参数量减少的情况下, 4 号电池的 SOC 估算 MAE 平均值降低了 7.5%, RMSE 平均值降低了 6.4%, 8 号电池的 SOC 估算 MAE 平均值降低了 8%, RMSE 平均值降低了 5.9%。第 3 组实验将 Tanh 激活函数改为 ThLU 激活函数, 4 号电池的 SOC 估算 MAE 平均值降低了 32%, RMSE 平均值降低了 46%, 8 号电池的 SOC 估算 MAE 平均值降低了 39%, RMSE 平均值降低了 33%。第 4 组实验优化序列数据输入方式, 引入环形 GRU 模式, 4 号电池的 SOC 估算 MAE 平均值降低了 47%, RMSE 平均值降低了 53%, 8 号电池的 SOC 估算 MAE 平均值降低了 50%, RMSE 平均值降低了 49%。第 4 组、第 5 组、第 6 组实验两个模块结合相比单独模块 SOC 估算精度进一步提高。

方面也更为优秀。在后续的研究中, 可以对如何提高电池老化预测精度从而提升荷电状态精度进行更深入的内部机理分析, 同时需要对如何保证优质数据采集、数据高效利用率进行研究, 形成智能检测数据, 高效估计 SOC&SOH 一体化的电池管理系统 BMS。

参考文献

4 结 论

本文提出一种精确估算电动汽车动力电池 SOC&SOH 的循环门控模型。该模型充分考虑电动汽车用户驾驶习惯、SOH 与 SOC 的关联性、BMS 存储空间的影响, 在动力电池荷电状态和健康状态估计准确度, 模型参数量以及模型运算效率等方面具有优势。循环门控模型首先对 GRU 模型中更新门和重置门的计算方式以及激活函数进行改进优化, 解决模型训练时间长、梯度消失的问题。其次, 提出优化数据输入方式并引入环形 GRU 计算模式, 可以减少电池管理系统 BMS 数据存储空间的消耗, 降低计算资源, 提高模型运算效率和估计能力。实验结果表明循环门控模型在开源牛津大学电池数据集上, 不仅预测 SOC 和 SOH 速度表现出色, 在估计准确度

[1] 杨续来, 袁帅帅, 杨文静, 等. 锂离子动力电池能量密度特性研究进展 [J]. 机械工程学报, 2023, 59(6): 239-254.
 YANG X L, YUAN SH SH, YANG W J, et al. Research progress on energy density of li-ion batteries for EVs [J]. Journal of Mechanical Engineering, 2023, 59(6): 239-254.

[2] 兰凤崇, 刘金, 陈吉清, 等. 电动汽车电池包箱体及内部结构碰撞变形与响应分析 [J]. 华南理工大学学报 (自然科学版), 2017, 45(2): 1-8.
 LAN F CH, LIU J, CHEN J Q, et al. Deformation and response analysis of pack and internal structure of electrical vehicle battery in collision [J]. Journal of South China University of Technology (Natural Science Edition), 2017, 45(2): 1-8.

[3] 闫啸宇, 周思达, 卢宇, 等. 锂离子电池容量衰退机理与影响因素 [J]. 北京航空航天大学学报, 2023, 49(6): 1402-1413.
 YAN X Y, ZHOU S D, LU Y, et al. Degradation mechanism and influencing factors on lithium-ion batteries [J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(6): 1402-1413.


[4] 张青松, 赵启臣. 过充循环对锂离子电池老化及安全性影响 [J]. 高电压技术, 2020, 46(10): 3390-3397.

- ZHANG Q S, ZHAO Q CH. Effects of overcharge cycling on the aging and safety of lithium ion batteries[J]. High Voltage Engineering, 2020, 46(10): 3390-3397.
- [5] HARAM M H S M, SARKER M T, RAMASAMY G, et al. Second life EV batteries: Technical evaluation, design framework, and case analysis[J]. IEEE Access, 2023, 11: 138799-138812.
- [6] KUMAR R R, BHARATIRAJA C, UDHAYAKUMAR K, et al. Advances in batteries, battery modeling, battery management system, battery thermal management, SOC, SOH, and charge/discharge characteristics in EV applications[J]. IEEE Access, 2023, 11: 105761-105809.
- [7] SYLVESTRIN G R, SCHERER H F, JUNIOR O H A. Hardware and software development of an open source battery management system [J]. IEEE Latin America Transactions, 2021, 19(7): 1153-1163.
- [8] THANGAVEL S, MOHANRAJ D, GIRIJAPRASANNA T, et al. A comprehensive review on electric vehicle: battery management system, charging station, traction motors[J]. IEEE Access, 2023, 11: 20994-21019.
- [9] HUANG Z, BEST M, KNOWLES J, et al. Adaptive piecewise equivalent circuit model with SOC/SOH estimation based on extended kalman filter [J]. IEEE Transactions on Energy Conversion, 2022, 38 (2): 959-970.
- [10] OBEID H, PETRONE R, CHAOUI H, et al. Higher order sliding-mode observers for state-of-charge and state-of-health estimation of lithium-ion batteries [J]. IEEE Transactions on Vehicular Technology, 2022, 72 (4): 4482-4492.
- [11] 朱丽群, 张建秋. 一种联合锂电池健康和荷电状态的新模型 [J]. 中国电机工程学报, 2018, 38 (12): 3613-3621.
- ZHU L Q, ZHANG J Q. A new model of jointed states of charge and health for lithium batteries[J]. Proceedings of the CSEE, 2018, 38(12): 3613-3621.
- [12] SHEN P, OUYANG M, LU L, 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, 2017, 67 (1): 92-103.
- [13] 蔡涛, 张钊诚, 袁奥特, 等. 锂离子电池储能安全管理中的机器学习方法综述[J]. 电力系统保护与控制, 2022, 50(24): 178-187.
- CAI T, ZHANG ZH CH, YUAN A T, et al. Review of machine learning for safety management of li-ion battery energy storage[J]. Power System Protection and Control, 2022, 50(24): 178-187.
- [14] 谢奕展, 程夕明. 锂离子电池状态估计机器学习方法综述[J]. 汽车工程, 2021, 43(11): 1720-1729.
- XIE Y ZH, CHENG X M. Review of state estimation of lithium-ion battery with machine learning[J]. Automotive Engineering, 2021, 43(11): 1720-1729.
- [15] 张朝龙, 罗来劲, 刘惠汉, 等. 基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计[J]. 电子测量与仪器学报, 2023, 37(1): 167-176.
- ZHANG CH L, LUO L J, LIU H H, et al. State of health estimation of lithium-ion batteries based on incremental energy analysis and BiGRU-Dropout [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 167-176.
- [16] 张振强, 马思乐, 姜向远, 等. 基于局部模型网络的锂电池 SOC 估计方法[J]. 仪器仪表学报, 2023, 44(7): 161-171.
- ZHANG ZH Q, MA S L, JIANG X Y, et al. State of charge estimation of lithium-ion battery using local model network [J]. Chinese Journal of Scientific Instrument, 2023, 44(7): 161-171.
- [17] 毛玲, 温佳林, 赵晋斌, 等. 基于集成 ELM 的锂离子电池充电截止电压下的 SOC 和 SOH 联合估计[J]. 电力系统保护与控制, 2023, 51(11): 86-95.
- MAO L, WEN J L, ZHAO J B, et al. Joint estimation of SOC and SOH at lithium-ion battery charging cut-off voltage based on an ensemble extreme learning machine[J]. Power System Protection and Control, 2023, 51(11): 86-95.
- [18] 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 CH R, XIAO F, FAN Y X, 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.
- [19] SALEM F M, SALEM F M. Gated RNN: The gated recurrent unit (GRU) RNN [J]. Recurrent Neural Networks: From Simple to Gated Architectures, 2022: 85-100, DOI:10.1007/978-3-030-89929-5_5.
- [20] 张忠豪, 董方敏, 胡枫, 等. 基于残差的门控循环单元[J]. 自动化学报, 2022, 48(12): 3067-3074.
- ZHANG ZH H, DONG F M, HU F, et al. Residual based gated recurrent unit [J]. Acta Automatica Sinica, 2022, 48(12): 3067-3074.
- [21] 崔建伟, 赵哲, 杜小勇. 支撑机器学习的数据管理技术综述[J]. 软件学报, 2021, 32(3): 604-621.
- CUI J W, ZHAO ZH, DU X Y. Survey on data management technology for machine learning [J]. Journal Of Software, 2021, 32(3): 604-621.

- [22] 李强龙,孙建瑞,赵坤,等. 基于 IALO-SVR 的锂电池健康状态预测[J]. 电子测量与仪器学报,2022,36(1): 204-211.
LI Q L, SUN J R, ZHAO K, et al. Prediction for the state of health of lithium-ion batteries based on IALO-SVR [J]. Journal of Electronic Measurement and Instrumentation,2022,36(1):204-211.
- [23] 王义军,左雪. 锂离子电池荷电状态估算方法及其应用场景综述[J]. 电力系统自动化,2022,46(14): 193-207.
WANG Y J, ZUO X. Review on estimation methods for state of charge of lithium-ion battery and their application scenarios [J]. Automation of Electric Power Systems, 2022,46(14):193-207.
- [24] CAI L, LIN J. A charging-feature-based estimation model for state of health of lithium-ion batteries [J]. Expert Systems with Applications,2024, 238: 122034.
- [25] 胡杰,高志文. 基于数据驱动的电动汽车动力电池 SOC 预测[J]. 汽车工程,2021,43(1):1-9.
HU J, GAO ZH W. A data-driven SOC prediction scheme for traction battery in electric vehicles [J]. Automotive Engineering,2021,43(1):1-9.
- [26] 蒋玮,王晓东,杨永标,等. 电动汽车电池组智能管理及其无线传感器网络路由协议[J]. 电力系统自动化,2015,39(18):62-68.
JIANG W, WANG X D, YANG Y B, et al. Electric vehicle smart battery management and its wireless sensor network protocol [J]. Automation of Electric Power Systems,2015,39(18):62-68.

- [27] WEI Z, LIU K, LIU X, et al. Multilevel data-driven battery management: From internal sensing to big data utilization [J]. IEEE Transactions on Transportation Electrification, 2023, 9(4): 4805-4823.

作者简介



彭自然 (通信作者), 2004 年于中南大学获得学士学位, 2008 年于中南大学获得硕士学位, 2017 年于中南大学获得博士学位, 现为湖南工业大学副教授, 主要研究方向为人工智能、信号处理、智能检测仪表等。
E-mail: pengziran@hut.edu.cn

Peng Ziran (Corresponding author), received his B. Sc. degree from Central South University, China, in 2004, the M. Sc. degree from Central South University, China, in 2008, and the Ph. D. degree from Central South University, China, in 2017, respectively. Now he is now an Associate Professor at Hunan University of Technology. His main research interests include Artificial Intelligence, Signal Processing, and Intelligent Detection Instrumentation.



王顺豪, 2022 年于山东航空学院获得学士学位, 现为湖南工业大学硕士研究生, 主要研究方向为电动汽车动力电池健康状态、荷电状态估算。
E-mail: 3130669501@qq.com

Wang Shunhao received his B. Sc. degree from Shandong Institute of Aeronautics in 2022. Now he is a M. Sc. candidate at Hunan University of Technology. His main research interests include electric vehicle power battery health state and charge state estimation.