

DOI: 10.13382/j.jemi.B2205773

基于增量能量法和 BiGRU-Dropout 的 锂电池健康状态估计*

张朝龙^{1,2} 罗来劲² 刘惠汉² 赵筛筛²

(1. 金陵科技学院智能科学与控制工程学院 南京 211169; 2. 安庆师范大学电子工程与智能制造学院 安庆 246011)

摘要: 锂离子电池健康状态(SOH)的精确估计是电池管理系统面临的核心问题之一。针对实际的电池容量很难直接测量和容量再生导致的SOH估计误差问题,提出了一种基于增量能量法和双向门控循环网络(BiGRU)-Dropout的锂离子电池健康状态估计方法。首先分析增量能量曲线随电池老化的衰退规律,提取出最大峰值高度作为电池SOH的新健康因子。通过翻转层和门控循环网络层所搭建的BiGRU网络得出健康因子与SOH的映射关系,同时添加Dropout机制网络层防止出现过拟合现象,建立SOH估计模型用于电池SOH精确估计。实验结果表明,在不同充电倍率条件下,该方法均可快速、准确地估计电池SOH。

关键词: 锂离子电池;健康状态;增量能量法;双向门控循环网络;Dropout机制

中图分类号: TM912 **文献标识码:** A **国家标准学科分类代码:** 120.30

State of health estimation of Lithium-ion batteries based on incremental energy analysis and BiGRU-Dropout

Zhang Chaolong^{1,2} Luo Laijin² Liu Huihan² Zhao Shaishai²

(1. College of Intelligent Science and Control Engineering, Jinling Institute of Technology, Nanjing 211169, China;

2. School of Electronic Engineering and Intelligent Manufacturing, Anqing Normal University, Anqing 246011, China)

Abstract: The accurate state of health (SOH) estimation of Lithium-ion battery is one of the core issues faced by battery management systems. Considering that it is difficult to directly measure the battery capacity in practice, and the capacity regeneration problem always cause SOH estimation errors, a SOH estimation method of Lithium-ion battery is proposed based on incremental energy analysis and bidirectional gate recurrent unit (BiGRU)-Dropout. The incremental energy curve is used to analyze the battery's degeneration characteristic, and the maximum peak height is extracted as a new health factor of battery SOH. Through the BiGRU network built by flip layer and gate recurrent unit layer, the mapping relationship between health factor and SOH is obtained. At the same time, Dropout mechanism network layer is added to prevent overfitting, and a SOH estimation model is established to accurately estimate the battery SOH. The results indicate that the proposed method can estimate battery SOH quickly and accurately under different charging rates.

Keywords: Lithium-ion battery; state of health; incremental energy analysis; bidirectional gated recurrent unit; Dropout mechanism

0 引言

在“双碳”目标下,锂离子电池具备高能量密度、循环寿命长、自放电率低、成本较低、环境污染小等突出优势,被广泛地应用于电网储能、航空、航天和电动汽车等众多领域^[1-2]。而锂电池在不断的循环使用过程中,健康状态(state of health, SOH)成为评价电池老化程度的关

键指标。由于电池老化因素复杂多变,与电池内外部条件都有很大的关系,故准确地估计锂电池SOH是至关重要^[3]。近年来,许多估计锂电池SOH的方法被提出,大致分为基于模型的方法^[4-8]和数据驱动的方法^[9-11]。

基于模型的方法是指建立锂离子电池的等效模型,通过模型仿真电池内部结构和材料以及内部所发生的化学反应。近年来,锂离子电池模型研究主要有电化学机理模型、等效电路模型和经验退化模型等^[4-8]。例如,

收稿日期: 2022-08-23 Received Date: 2022-08-23

* 基金项目: 国家重点研发计划(2020YFB0905905, 2016YFF0102200)、国家自然科学基金重点资助项目(51637004)、金陵科技学院高层次人才科研启动基金(jit-rcyj-202202)、安庆师范大学研究生创新创业项目(2022cxcsj161)资助

Xiong 等^[5]通过有限分析方法提出了一种简化的伪二维模型。Mevawalla 等^[6]提出了一种简化的电化学热模型,涉及大量的偏微分方程计算。Yang 等^[7]提出了一种基于电阻、电感的等效电路模型,采用并行连接的方式提高模型的精度。Zheng 等^[8]提出了一种前馈经验模型和反馈神经网络相融合的电池容量预测方法,通过两种模型的估计差异对前馈经验模型的参数进行修正。由于基于模型的方法原理和计算过程复杂,不利于电池管理系统的实时监测。

数据驱动法只需对实验测量的历史数据进行分析,不需要分析锂电池内部电化学反应,可直接根据提取的电流、电压等特征建立估计模型,因而被广泛的使用。常用的数据驱动方法包括极限学习机(extreme learning machine, ELM)^[9]、支持向量机(support vector machine, SVM)^[10]、长短期记忆网络(long short-term memory, LSTM)^[11]等。其中 ELM 算法的输入权值是随机的,无法对数据特征的变化进行微调,可控性较差,模型的输出结果不稳定。SVM 对大规模的数据样本难以进行划分且计算成本会极大增加,需要选择正则化参数,核函数以及核函数参数。LSTM 模型不仅复杂度较高,而且收敛速度慢,训练过程中更加耗时,计算量大不利于处理长时序。门控循环单元(gate recurrent unit, GRU)作为 LSTM 的变体,利用较少的参数和低的网络复杂度,在计算成本和收敛速度上具有很大的优势。双向门循环单元(bidirectional gate recurrent unit, BiGRU)模型能很好地学习历史和未来信息,可进一步克服锂电池在实际应用的再生现象^[12]。另外,为避免出现模型的过拟合以及更加合理的解释老化过程,在 BiGRU 网络模型上添加 Dropout 机制再进行建模,可有效地提升网络模型的泛化性和鲁棒性。

虽然数据驱动的方法能够很好地处理非线性问题,但是其估计精度的关键在于特征的分析与提取。Lin 等^[13]提取恒流充电阶段的充电时长作为的电池老化特征,达到快速估计 SOH 的效果。Chen 等^[14]对随机的短期充电数据预测恒流充电过程的整个温度变化,并利用卡尔曼滤波得到平滑的温差曲线提取电池老化特征进行 SOH 估计。Liu 等^[15]提取恒流充电阶段和恒压充电阶段的固定时差内的电压差值作为健康特征进行 SOH 估计。以上方法均从电压、电流和温度等充电曲线中提取特征,所提取的特征无法表明电池内部剧烈反应过程^[16-17]。近些年增量容量分析法(incremental capacity analysis, ICA)被广泛地用来分析电池老化特性和提取特征,ICA 将传统的充放电曲线转化为具有更加明显特征的 IC 曲线。IC 曲线所包含的特征不仅可有效反应锂电池的衰退过程,还可以描述锂电池内部老化的反应机理^[18]。Li 等^[19]利用高斯滤波的方法对静态充电曲线进行平滑处

理后提取 IC 曲线的特征,进而得出特征与 SOH 的映射关系,但并未对不同充放电倍率充电曲线进行讨论。Liu 等^[20]使用改进的增量容量分析和 LSTM 神经网络来估计锂电池 SOH,该方法增加了采样范围,但存在较大的测量误差噪声干扰导致 SOH 估计效果一般。

本文针对上述方法的缺点,提出一种基于增量能量法(incremental energy analysis, IEA)和 BiGRU 的锂离子健康状态估计方法,该方法将传统的能量充电曲线转换为增量能量曲线,采用等压升内的能量变化量与等压差比值,可以获取更为丰富有效的特征,减少了测量误差和缩小了计算成本,有利于特征的快速提取。随后采用 BiGRU 估计的基础上添加 Dropout 层解决网络训练时出现过拟合问题,进而建立锂离子电池的 SOH 估计模型。本文提出的方法在 4 种不同充放电倍率的循环老化数据和 4 种不同比例的训练样本数量上进行验证,实验结果表明该方法具有较强的泛化能力和稳定性。

1 增量能量分析

传统的 ICA 通常应用于恒流充放电模式下的电池老化机理分析,将原始的充放电数据的容量-端电压($Q-V$)曲线采用一阶微分求导转换成容量增量-端电压($dQ/dV-V$)曲线,变换后的曲线有利于分析和提取出更加有效的特征来表征电池的老化过程。本文参考 ICA 提出 IEA 方法用于电池老化机理分析,并采用更为简便的等压差所对应的能量变化值 ΔE 与固定的等压差 ΔV 的比值,来代替函数拟合充电曲线后微分求导的 dE/dV ,有效减少了拟合误差,代替过程为:

$$E = f(V) \quad (1)$$

$$\frac{dE}{dV} \approx \frac{\Delta E}{\Delta V} \quad (2)$$

式中: E 为充电能量; V 为充电电压; f 为 $E-V$ 的函数关系。

不同充电倍率的能量-端电压($E-V$)曲线如图 1 所示,经转换后的能量增量-端电压($dE/dV-V$)曲线,即 IE 曲线如图 2 所示。从图 1 中可以看出,随着充电倍率的减小,能量曲线向左上方移动(能量增大和电压减小的方向偏移),可以表明在小电流情况下,能充入的能量更多并且充电时长会明显增加。从图 2 中可以看出,随着充电倍率的减小,IE 曲线向左上方移动(dQ/dV 峰增大和电压减小的方向偏移),且在 0.5 C 倍率时的 3 号和 4 号峰值被 2 号峰吸收,峰宽明显增加,IE 曲线将图 1 中充电曲线上电压增加缓慢但内部发生复杂和剧烈的电化学反应的区间,通过 dE/dV 峰值更加明显地展现出来,因此有利于特征提取。




图 1 不同充电倍率下的 E-V 曲线

Fig. 1 The E-V curves under different charging rates




图 2 不同充电倍率下的 IE 曲线

Fig. 2 The IE curves under different charging rates

2 SOH 估计方法

2.1 BiGRU

LSTM 存在单元内部结构复杂、参数多而导致的计算量过大等问题。因此,为保留 LSTM 能长期记忆的同时减少参数、优化结构,GRU 将传统 LSTM 的输入门和遗忘门替换成更新门,减少了结构的复杂度和参数的数量,因此,GRU 能快速有效地处理长时间的信息更新与存储。

GRU 对输入数据的处理过程可以描述为:

1) 更新门 z_t 衡量前一时刻的信息被保留在当前时刻的程度,值越大表明前一时刻的信息被保留的越多。

$$z_t = \sigma(w_z \cdot [h_{t-1}, x_t] + b_z) \quad (3)$$

2) 重置门 r_t 用来控制前一时刻的信息被保留在当前时刻候选隐藏信息 \tilde{h}_t 上的多少,值越大,说明前一时刻的信息被保留在候选隐藏状态的越多。

$$r_t = \sigma(w_r \cdot [h_{t-1}, x_t] + b_r) \quad (4)$$

3) 隐藏状态信息 \tilde{h}_t 的更新如下:

$$\tilde{h}_t = \tanh(w_h \cdot [r_t \odot h_{t-1}, x_t] + b_h) \quad (5)$$

4) 根据 \tilde{h}_t 和 h_{t-1} 计算出输出门 h_t :

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (6)$$

式中: w 和 b 分别表示对应门的权值和偏置; σ 和 \tanh 分别为 sigmoid 型激活函数和双曲正切型激活函数。

本文利用 Flip 层构建出反向 GRU 来获取未来信息,搭建出基本的 BiGRU 模型结构如图 3 所示。




图 3 Bi-GRU 模型结构

Fig. 3 Structure of Bi-GRU model

图 3 中 BiGRU 网络层由前向和反向传播的 GRU 层组成,分别计算前向 GRU 层当前时刻的值与反向 GRU 层当前时刻的值后,二者共同决定最终的输出值。网络输出过程如下:

$$\vec{h}_t = f(x_t, \vec{h}_{t-1}) \quad (7)$$

$$\overleftarrow{h}_t = f(x_t, \overleftarrow{h}_{t-1}) \quad (8)$$

$$h_t = \vec{w}_t \vec{h}_t + \overleftarrow{w}_t \overleftarrow{h}_t + b_t \quad (9)$$

式中: \vec{w}_t 和 \overleftarrow{w}_t 分别表示前向 GRU 隐藏层输出和反向 GRU 隐藏层输出的权重; h_t 为前向隐藏层状态和反向隐藏层状态的线性叠加。

2.2 Dropout 机制

Dropout 机制对神经元的状态信息取平均和减少神经元之间共同作用的复杂关系,让部分神经元以一定的概率停止工作,Dropout 主要结构如图 4 所示。

2.3 BiGRU-Dropout 网络模型的结构

本文采用 Flip 层、Dropout 层、GRU 层、全连接层、级联层、Softmax 层、输入层、输出层构建 BiGRU-Dropout 的网络模型,如图 5 所示。

模型每层功能分别如下:

1) Input (输入层), 读取从锂电池 IE 曲线中获取的峰值特征序列和健康状态序列,归一化预处理,划分为训练集和测试集。




图 4 Dropout 结构
Fig. 4 Structure of Dropout

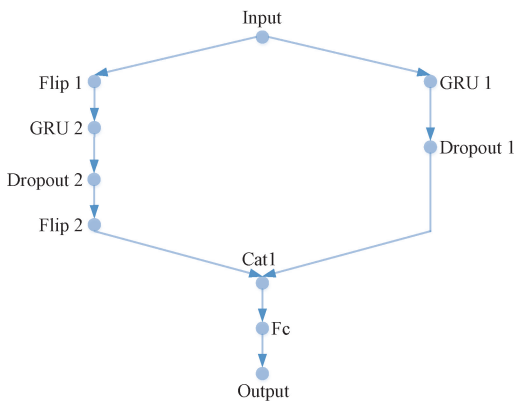


图 5 网络模型的结构
Fig. 5 Structure of network model

2) Flip(翻转层),采用数据翻转的形式放在 GRU 层前面,让 GRU 层反向学习未来信息。

3) GRU 层,利用 GRU 单元存储关键的信息,遗忘无用的信息。

4) Dropout 层,随机(备份)删除网络神经元数量的隐藏状态。

5) Cat1(级联层),将前向 GRU 和反向 GRU 学习后存储的信息进行串联连接。

6) Fc(全连接层),将 BiGRU-Dropout 层的输出非线性变化映射至输出空间。

7) Output(输出层),采用 Softmax 型激活函数对输入的信息进行计算,得出估计结果。

2.4 SOH 估计框架

本文提出的锂电池 SOH 估计方法流程如图 6 所示,可分为数据预处理、SOH 估计模型训练以及 SOH 估计共 3 个部分。首先对电池的充电能量数据绘制 IE 曲线提取最大峰值特征,并将归一化处理后的特征数据作为网络输入。然后按照 1 : 1 划分为训练集和测试集,并基于训练集构建 BiGRU-Dropout 的电池 SOH 估计模型。最后通过测试集和建立的 BiGRU-Dropout 模型对电池 SOH 进行估计。

3 实验数据、结果和分析

3.1 实验数据和步骤

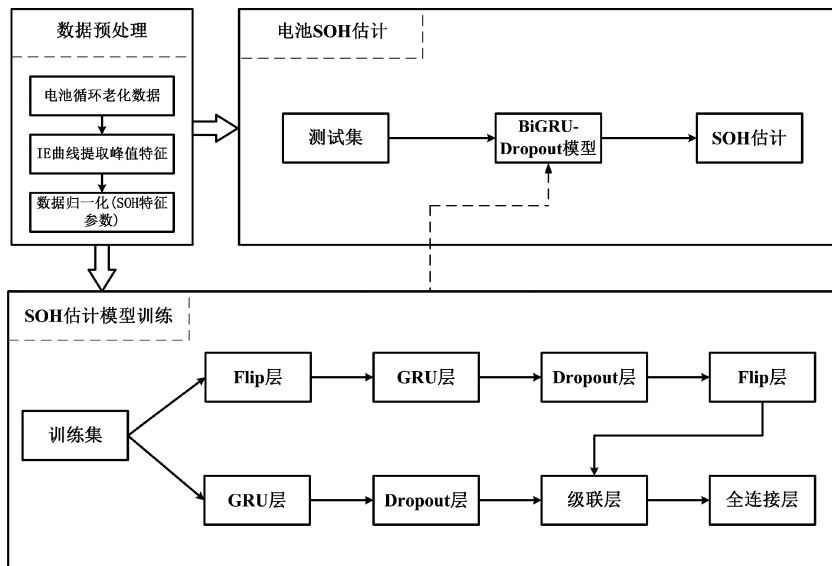


图 6 SOH 估计方法的整体框架
Fig. 6 Flowchart of SOH estimation

采用 4 节规格相同的圆柱形 18650 锂离子电池在常 温下进行充放电循环,其电池参数如表 1 所示。4 节电

池通过如图 7 所示的电池测试系统进行循环充放电试验,测量锂电池老化数据。其中电池测试系统包括上位机、单体电池测量设备以及恒温箱。上位机用于记录和保存电池试验数据。单体电池测量设备采用新威 BTS-4000,具有恒流、恒压、恒流恒压等多种充放电模式。

表 1 电池参数

Table 1 Battery parameters

参数	数值
额定容量/(A·h)	2.4
标称电压/V	3.6
电压工作范围/V	3~4.2
充电截止电流/mA	48

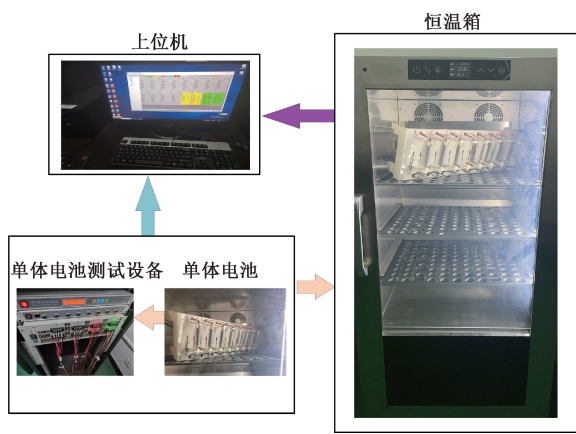


图 7 电池测试系统

Fig. 7 Battery testing system

该实验首先在恒流恒压充电模式下分别进行 0.5 C、0.3 C、0.2 C、0.1 C 恒流充电,直至电池端电压达到上截止电压,然后保持电压恒定不变,进行恒压充电,直至电流降低为截止电流,静置一段时间后进行 1 C 恒流放电,直至电池端电压下降为截止电压。在不同倍率电流进行循环老化实验时,用容量比来定义锂电池健康状态:

$$SOH = \frac{Q_{\max \text{ capacity}}}{Q_{\text{rated capacity}}} \times 100\% \quad (10)$$

式中: $Q_{\max \text{ capacity}}$ 为锂电池当前最大放电容量, $Q_{\text{rated capacity}}$ 为锂电池出厂时规定的额定容量。

图 8 为不同充电倍率的 4 节锂离子电池,在相同 SOH 时充电的电压曲线,可以看出充电时长会随着充电倍率的减小而明显增加。图 9 为各电池健康状态数据,可以看出电池健康状态随充放电循环而不断地下降,并伴随着局部再生现象。由于这 4 节电池的初始健康状态和下降趋势截然不同,单体之间的差异性会对电池健康状态的估计带来一定的困难。

对 4 个不同充电倍率的电池进行循环实验,在进行 750 次充放电循环后,0.5 C 倍率充电的电池可用能量从




图 8 充电时电压曲线

Fig. 8 Voltage curves when charging




图 9 电池 SOH 数据

Fig. 9 Battery SOH data

8.618 0 W·h 下降至 6.478 1 W·h; 0.3 C 倍率充电的电池可用能量从 8.551 4 W·h 下降至 7.318 4 W·h; 0.2 C 倍率充电的电池可用能量从 8.481 3 W·h 下降至 7.240 0 W·h; 0.24 A 倍率充电的电池,进行 600 次充放电循环后,电池可用能量从 8.398 2 W·h 下降至 7.239 2 W·h。老化参数如表 2 所示。

表 2 电池老化参数


Table 2 Battery aging parameters

充电倍率	循环次数	初始能量/(W·h)	结束能量/(W·h)
0.5 C(1.2 A)	750	8.618 0	6.478 1
0.3 C(0.72 A)	750	8.551 4	7.318 4
0.2 C(0.48 A)	750	8.481 3	7.240 0
0.1 C(0.24 A)	600	8.398 2	7.239 2


3.2 实验数据和步骤

根据 IE 曲线生成方法,计算得出如图 10(a)、(b)、(c)和(d)所示的不同充电倍率的 IE 老化曲线。可以看到,0.5 C 的 IE 曲线中出现了两个较为明显的峰值,并随


着循环老化,IE 曲线逐渐向右下方移动(电压增加和峰值降低方向偏移),且在最高峰降低的同时,其峰值对应的电压并未发生明显的变化。而 0.3 C、0.2 C 和 0.1 C 的 IE 曲线中均出现了较为明显的 4 个峰值,随着循环老化,这 3 个 IE 曲线的峰值,与 0.5 C 的 IE 曲线峰值出现类似的变化,即 4 个峰值在逐渐地降低,但峰值对应的电压几乎没有什么变化。为使利用不同倍率充电的电池快速有效地估计电池 SOH,本文将 IE 曲线最高峰值作为电池 SOH 衰退的特征。




(a) 0.5 C 充电下 IE 老化曲线
(a) IE aging curves at 0.5 charging rate



(b) 0.3 C 充电下 IE 老化曲线
(b) IE aging curves at 0.3 charging rate



(c) 0.2 C 充电下 IE 老化曲线
(c) IE aging curves at 0.2 charging rate



(d) 0.1 C 充电下 IE 老化曲线
(d) IE aging curves at 0.1 charging rate

图 10 不同充电倍率下的 IE 老化曲线

Fig. 10 IE aging curves under different charging rates

3.3 实验评判标准

本文采用平均绝对误差 (MAE)、均方根误差 (RMSE)、决定系数 (R^2) 和运行时间作为估计模型的性能指标。其计算公式分别如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

式中: \hat{y}_i 代表模型的 SOH 估计值, y_i 代表实际 SOH 测量值, \bar{y} 代表测量 SOH 的平均值, $i \in [1, n]$, n 为实验循环次数。对于 MAE、RMSE 来说,值越小,表明模型估计的准确度越高。 R^2 在 0~1 之间,值越接近 1 表明模型的拟合效果越好,估计误差的偏离程度小。

3.4 SOH 估计结果与分析


本实验运行环境为 Windows 10 操作系统、MATLAB 2020a 软件、英特尔酷睿 i5、内存 12 GB 等。按照 1 : 1 划分数数据集进行电池 SOH 估计,不同倍率的 SOH 估计结果如图 11(a)、(b)、(c) 和 (d) 所示,该网络的估计性能如表 3 所示。其中 BIGRU 的神经元数量各为 40,学习率由 Adam 算法自适应更新,最大训练次数为 100,Dropout 层的丢弃率为 0.5。

从图 11 可以看到,4 种不同的充放电倍率循环的实验中都取得了较为准确的 SOH 估计结果,并克服了电池的再生现象。在 0.5 C、0.3 C、0.2 C 倍率中,都具有相同的网络参数和充放电循环次数,而 0.3 C 中 MAE 为 0.206 5%,RMSE 为 0.246 0% 以及运行时间 14.03 s 与其


表 3 SOH 估计性能

Table 3 Performance of SOH estimation


充电倍率	MAE/%	RMSE/%	R^2 /%	时间/s
0.5 C	0.224 9	0.309 2	99.29	16.71
0.3 C	0.206 5	0.246 0	99.46	14.03
0.2 C	0.215 6	0.255 4	98.02	17.56
0.1 C	0.246 9	0.307 7	98.52	16.54



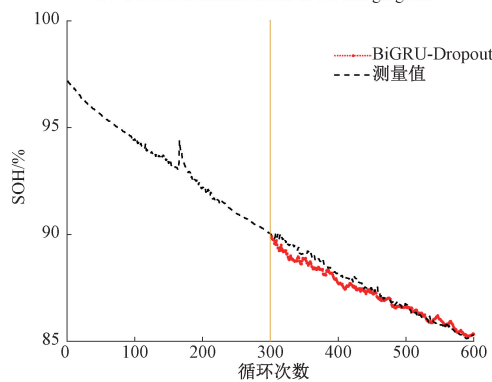
(a) 0.5 C 充电下 SOH 估计结果
(a) SOH estimation results at 0.5 charging rate



(b) 0.3 C 充电下 SOH 估计结果
(b) SOH estimation results at 0.3 charging rate



(c) 0.2 C 充电下 SOH 估计结果
(c) SOH estimation results at 0.2 charging rate




(d) 0.1 C 充电下 SOH 估计结果
(d) SOH estimation results at 0.1 charging rate

图 11 不同充电倍率下的 SOH 估计结果


Fig. 11 SOH estimation results under different charging rates

他倍率下实验相比,都是最小的,具有较高的准确度和较小的计算成本,同时 0.3 C 的 R^2 为 99.46% 具有很好的拟合度,拟合度越大表明网络模型输入特征与 SOH 具有越好的解释关系,说明本实验 0.3 C 的增量能量特征能更有效地追踪电池 SOH 的衰退过程。对 0.1 C 而言,虽然有相同的网络参数但循环次数少于 0.5 C、0.3 C、0.2 C 倍率,所以运行时间相对较短,导致其误差偏大,但从 0.1 C 的 R^2 为 98.52% 可知,该倍率下的增量能量特征对电池老化过程具有较好的解释程度。因此,本实验表明在不同倍率下充放电循环的能量增量特征均能有效地表征电池的老化过程。


在相同条件下,采用 LSTM、SVM 以及 ELM 对 4 种不同倍率的电池 SOH 进行估计,对比其估计性能。实验结果如图 12(a)、(b)、(c) 和 (d) 所示。从 4 种估计结果来看,虽然 LSTM 具有较好的记忆时间序列数据之间的依赖性,在一定程度上缓解梯度消失以及爆炸问题,但 LSTM 无法准确地估计序列之间的长期依赖性,并且在训练过程中误差梯度不断累加,导致模型的权重更新较大,估计精度降低。而 SVM 核函数的惩罚系数和宽度因子需要进行不断调节,无法准确地跟踪电池 SOH 的真实衰退规律,导致估计结果出现多个跳变点。而 ELM 隐含层输入的权值是随机初始化的,不可以人为赋值,无法进行反馈,虽然 ELM 计算速度快,但是 SOH 估计结果波动较大。本文提出的 BiGRU-Dropout 网络添加了非线性数据相关的控制单元,使 SOH 估计值相关的目标函数梯度不会消失,很好地学习历史 SOH 和未来 SOH,有效克服了电池 SOH 的再生现象,捕捉了电池 SOH 的老化规律;同时 Dropout 机制对神经元的状态信息取平均和减少神经元之间共同作用的复杂关系,提升模型的估计性能,达到最佳的估计效果。表 4、5、6 和 7 中记录本文提出的方法和 LSTM、SVM、ELM 方法的对比结果。可以看出,本文所提 BiGRU 方法的 MAE 和 RMSE 误差都是最小,表明 BiGRU-Dropout 网络能准确地估计不同倍率下电池 SOH,精确地追踪电池 SOH 的老化规律。本文提出的方法在 4 种不同充电倍率下循环老化的 SOH 估计模型的拟合度均达到 98% 以上,都高于 LSTM、SVM 以及 ELM 的 SOH 估计模型的拟合度,表明提出的基于增量能量法和 BiGRU-Dropout 的锂离子健康状态估计方法具有更好的适用性与准确性。




(a) 0.5 C 充电下 SOH 估计结果
(a) SOH estimation results at 0.5 charging rate



(b) 0.3 C 充电下 SOH 估计结果
(b) SOH estimation results at 0.3 charging rate



(c) 0.2 C 充电下 SOH 估计结果
(c) SOH estimation results at 0.2 charging rate



(d) 0.1 C 充电下 SOH 估计结果
(d) SOH estimation results at 0.1 charging rate

图 12 对比实验的 SOH 结果

Fig. 12 SOH estimation results of comparison experiments

表 4 0.5 C 充电倍率下的性能评估

Table 4 Performance evaluation under 0.5 C charging rate

方法	MAE/%	RMSE/%	R^2 /%
BiGRU-Dropout	0.224 9	0.309 2	99.29
LSTM	0.322 4	0.376 2	98.52
SVM	0.336 4	0.456 2	97.85
ELM	0.374 8	0.493 4	97.62

表 5 0.3 C 充电倍率下的性能评估

Table 5 Performance evaluation under 0.3 C charging rate

方法	MAE/%	RMSE/%	R^2 /%
BiGRU-Dropout	0.206 5	0.246 0	99.46
LSTM	0.285 8	0.348 3	98.93
SVM	0.313 8	0.386 1	97.36
ELM	0.336 3	0.408 8	97.73

表 6 0.2 C 充电倍率下的性能评估

Table 6 Performance evaluation under 0.2 C charging rate

方法	MAE/%	RMSE/%	R^2 /%
BiGRU-Dropout	0.215 6	0.255 4	98.02
LSTM	0.334 1	0.409 6	97.64
SVM	0.360 4	0.472 4	94.06
ELM	0.418 3	0.526 7	93.79

表 7 0.1 C 充电倍率下的性能评估

Table 7 Performance evaluation under 0.1 C charging rate

方法	MAE/%	RMSE/%	R^2 /%
BiGRU-Dropout	0.246 9	0.307 7	98.52
LSTM	0.301 4	0.349 9	94.21
SVM	0.268 8	0.334 8	94.71
ELM	0.441 5	0.527 7	94.35

为了进一步证明所提方法的优越性,对 4 种不同倍率的电池分别采用 50%,40%,30%以及 20%共 4 种不同比例的训练样本对 SOH 估计进行测试,估计结果如表 8 所示。从表 8 可以看出,所提方法使用 20%~50%之间的训练样本比例均可以准确地估计电池 SOH,MAE 和 RMSE 值分别都在 2%和 2.5%以内, R^2 均在 75%以上,且 MAE 和 RMSE 值会随着样本比例的增加而大幅减小, R^2 会随着样本比例的增加而大幅提升。以 0.1 C 充电倍率的电池为例,样本比例从 20%增加到 30%时,MAE 和 RMSE 分别降低了 26.3%和 29.6%, R^2 增加了 8.4%;样本比例从 20%增加到 40%时,MAE 和 RMSE 分别降低了 57.1%和 59.6%, R^2 增加了 20.1%;样本比例从 20%增加到 50%时,MAE 和 RMSE 分别降低了 77.6%和

76.4%, R^2 增加了 29.7%。因此经过 SOH 估计结果分析,本文所提出的基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计方法具有较强的泛化能力和稳定性,在少量样本情况下仍具有较高的 SOH 估计精度。

表 8 4 种不同训练样本比例的估计性能对比

Table 8 Comparison of estimation performance of four different training sample proportions

充电倍率	训练样本比例/%	MAE/%	RMSE/%	R^2 /%
0.5 C	50	0.224 9	0.309 2	99.29
	40	0.454 3	0.551 7	97.44
	30	0.919 7	1.248 2	95.32
	20	1.782 5	2.253 6	88.71
0.3 C	50	0.206 5	0.246 0	99.46
	40	0.411 7	0.487 2	94.41
	30	0.739 4	0.853 4	87.61
	20	0.924 2	1.138 1	83.69
0.2 C	50	0.215 6	0.255 4	98.02
	40	0.373 9	0.447 4	93.92
	30	0.640 8	0.819 4	85.91
	20	0.934 3	1.081 7	82.47
0.1 C	50	0.246 9	0.307 7	98.52
	40	0.473 4	0.527 3	91.24
	30	0.814 2	0.920 3	82.41
	20	1.104 3	1.306 4	75.97

4 结 论

本文提出了一种新的增量能量法提取特征,该方法更加方便简单,避免了传统方法拟合充电曲线后微分求导带来的拟合误差。通过 BiGRU-Dropout 的网络模型有效地克服了电池的再生现象问题,提高了 SOH 估计模型的精度。通过 4 种不同倍率下的循环老化实验对所提方法的适用性进行了验证,得出所提方法在不同充电倍率下的增量能量特征均可以贴切地表征出电池老化过程,而 BiGRU-Dropout 可以准确地估计电池 SOH。为了进一步验证所提方法的泛化能力和稳定性,采用四种不同比例的训练样本进行 SOH 估计,即使在 20% 少量样本比例下,SOH 估计结果的性能指标 MAE 和 RMSE 分别在 2% 和 2.5% 以内, R^2 在 75% 以上。因此,本文提出的方法对锂电池 SOH 估计具有指导性和参考性。后续将开展不同温度条件、不同充电模式和放电模式下的锂离子电池充放电实验,并进而进行锂离子电池健康状态估计,从而进一步拓展本文方法的适用性。

参考文献

[1] LI X, ZHANG Q, YANG B W, et al. Research on capacity degradation and aging state estimation of lithium-ion battery [C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 2011(1): 012082.
 [2] 刘大同, 宋宇晨, 武巍, 等. 锂离子电池组健康状态

估计综述 [J]. 仪器仪表学报, 2020, 41(11): 1-18.
 LIU D T, SONG Y CH, WU W, et al. Review of state of health estimation for lithium-ion battery pack [J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 1-18.

- [3] WANG Y J, TIAN J Q, SUN ZH D, et al. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems [J]. Renewable and Sustainable Energy Reviews, 2020, 131: 110015.
 [4] OUYANG M G, FENG X N, HAN X B, et al. A dynamic capacity degradation model and its applications considering varying load for a large format Li-ion battery [J]. Applied Energy, 2016, 165: 48-59.
 [5] XIONG R, LI L L, LI Z R, et al. An electrochemical model based degradation state identification method of Lithium-ion battery for all-climate electric vehicles application [J]. Applied Energy, 2018, 219: 264-275.
 [6] MEVAVALLA A, PANCHAL S, TRAN M K, et al. One dimensional fast computational partial differential model for heat transfer in lithium-ion batteries [J]. Journal of Energy Storage, 2021, 37: 102471.
 [7] YANG J F, CAI Y F, PAN C F, et al. A novel resistor-inductor network-based equivalent circuit model of lithium-ion batteries under constant-voltage charging condition [J]. Applied Energy, 2019, 254: 113726.
 [8] ZHENG Y J, CUI Y F, HAN X B, et al. A capacity prediction framework for lithium-ion batteries using fusion prediction of empirical model and data-driven method [J]. Energy, 2021, 237: 121556.
 [9] JING Y, ZHEN P, WANG H M. The remaining useful life estimation of lithium-ion battery based on improved extreme learning machine algorithm [J]. International Journal of Electrochemical Science, 2018, 13(5): 4991-5004.
 [10] FENG X N, WENG C H, HE X M, et al. Online state-of-health estimation for Li-Ion battery using partial charging segment based on support vector machine [J]. IEEE Transactions on Vehicular Technology, 2019, 68(9): 8583-8592.
 [11] ZHANG CH B, ZHU Y Y, DONG G ZH, et al. Data-driven lithium-ion battery states estimation using neural networks and particle filtering [J]. International Journal of Energy Research, 2019, 43(8): 8230-8241.
 [12] LI X CH, MA X F, XIAO F CH, et al. Time-series production forecasting method based on the integration of bidirectional gated recurrent unit (Bi-GRU) network and sparrow search algorithm (SSA) [J]. Journal of

- Petroleum Science and Engineering, 2022, 208(1): 109309.
- [13] LIN CH P, XU J, SHI M J, et al. Constant current charging time based fast state-of-health estimation for lithium-ion batteries[J]. Energy, 2022, 247: 123556.
- [14] CHEN ZH, ZHAO H Q, ZHANG Y J, et al. State of health estimation for lithium-ion batteries based on temperature prediction and gated recurrent unit neural network [J]. Journal of Power Sources, 2022, 521: 230892.
- [15] LIU J, CHEN Z Q. Remaining useful life prediction of lithium-ion batteries based on health indicator and Gaussian process regression model [J]. IEEE Access, 2019, 7: 39474-39484.
- [16] 郑雪莹, 邓晓刚, 曹玉苹. 基于能量加权高斯过程回归的锂离子电池健康状态预测 [J]. 电子测量与仪器学报, 2020, 34(6): 63-69.
- ZHENG X Y, DENG X G, CAO Y P. State of health prediction of lithium-ion batteries based on energy-weighted Gaussian process regression [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(6): 63-69.
- [17] HARPER G, SOMMERVILLE R, KENDRICK E, et al. Recycling lithium-ion batteries from electric vehicles [J]. Nature, 2019, 575(7781): 75-86.
- [18] LI X Y, YUAN CH G, WANG ZH P. State of health estimation for Li-ion battery via partial incremental capacity analysis based on support vector regression [J]. Energy, 2020, 203: 117852.
- [19] LI Y, ABDEL-MONEM M, GOPALAKRISHNAN R, et al. A quick on-line state of health estimation method for li-ion battery with incremental capacity curves processed by Gaussian filter [J]. Journal of Power Sources, 2018, 373: 40-53.
- [20] LIU Q, KANG Y, QU S, et al. An online SOH estimation method based on the fusion of improved ICA and LSTM [C]. 2020 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia). IEEE, 2020: 1163-1167.


作者简介



张朝龙, 2018 年于合肥工业大学获得博士学位, 现为金陵科技学院教授, 主要研究方向为锂电池智能管控、故障诊断和预测。

E-mail: zhangchaolong@jit.edu.cn

Zhang Chaolong received the Ph. D. degree from Hefei University of Technology in 2018. He is currently a professor at Jinling Institute of Technology. His main research interests include intelligent control of lithium battery, fault diagnostics and prognostics.



罗来劲 (通信作者), 2021 年于武汉工程大学邮电与信息工程学院获得学士学位, 现为安庆师范大学研究生, 主要研究方向为锂电池测试技术。

E-mail: laijinluo@163.com

Luo Laijin (Corresponding author) received the B. Sc. degree from the College of Post and Telecommunication of Wuhan Institute of Technology in 2021. He is a M. Sc. candidate at Anqing Normal University. His current research interest includes lithium-ion battery testing technology.