

采用全局健康因子和残差模型的 锂离子电池健康状态估计

胡循泉¹, 耿莉敏¹, 舒俊豪², 张文博³, 巫春玲², 尉小龙⁴, 黄东¹, 陈昊¹

(1. 长安大学陕西省交通新能源开发、应用与汽车节能重点实验室, 710064, 西安; 2. 长安大学
西安市交通先进动力重点实验室, 710064, 西安; 3. 陕西重型汽车有限公司汽车工程研究院,
710200, 西安; 4. 核工业二〇三研究所, 712099, 陕西咸阳)

摘要: 为准确估计锂离子电池的健康状态(SOH),提出了一种卷积神经网络-残差网络-双向门控循环单元-注意力机制(CNN-Residual-BiGRU-Attention)模型和微调估计方法。首先,采用分段近似聚合算法对电池容量增量和恒流充电曲线进行降维,构建全局健康因子;接着,利用卷积神经网络提取全局健康因子时序特征,通过注意力机制突出强相关特征,并引入残差网络保持信息完整性;最后,通过改进人工蜂群算法对模型超参数寻优,提升模型 SOH 估计精度。采用美国国家航空航天局和牛津大学锂离子电池数据集进行精度验证,结果表明:利用提出的微调估计方法,即使精度较差的卷积神经-长短期记忆模型,SOH 估计结果的平均绝对误差 e_{MAE} 、平均绝对百分比误差 e_{MAPE} 和均方根误差 e_{RMSE} 也均在 2% 以内;相较于卷积神经网络-双向门控循环单元-注意力机制模型,采用 CNN-Residual-BiGRU-Attention 模型对训练集比例为 30% 的同一电池 SOH 进行估计,得到的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 分别降低了 41.86%、44.35%、42.11%;对训练集比例为 40% 的同类电池 SOH 进行估计,得到的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 分别降低了 45.51%、45.93%、40.10%。该研究结果可为低比例训练集条件下准确估计锂离子电池的 SOH 提供理论参考。

关键词: 锂离子电池;健康状态估计;全局健康因子;改进人工蜂群算法;残差;双向门控循环单元

中图分类号: TM912.8 **文献标志码:** A

DOI: 10.7652/xjtuxb202504010 **文章编号:** 0253-987X(2025)04-0105-13

Estimation of Lithium-Ion Battery State of Health Using Global Health Factor and Residual Model

HU Xunquan¹, GENG Limin¹, SHU Junhao², ZHANG Wenbo³, WU Chunling²,
WEI Xiaolong⁴, HUANG Dong¹, CHEN Hao¹

(1. Shaanxi Key Laboratory of New Transportation Energy and Automotive Energy Saving, Chang'an University,
Xi'an 710064, China; 2. Xi'an Key Laboratory of Advanced Transport Power Machinery, Chang'an University,
Xi'an 710064, China; 3. Automotive Engineering Research Institute, Shaanxi Heavy Vehicle Co., Ltd.,
Xi'an 710200, China; 4. Nuclear Industry 203 Research Institute, Xianyang, Shaanxi 712099, China)

Abstract: To accurately estimate the state of health (SOH) of lithium-ion batteries, a convolutional neural network-residual-BiGRU-attention (CNN-Residual-BiGRU-Attention) model and fine-

收稿日期: 2024-11-29。 作者简介: 胡循泉(2000—),男,硕士生;耿莉敏(通信作者),女,教授,博士生导师。
基金项目: 陕西省自然科学基金基础研究计划资助项目(2023-JC-QN-0417);西安市科技计划资助项目(24ZDCYJSGG0048);
咸阳市重点研发计划资助项目(L2023-ZDYF-SF-077)。

网络出版时间: 2025-01-02

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20241231.0955.009>

tuning estimation method are proposed. Firstly, a piecewise approximate aggregation algorithm is used to reduce the dimensionality of battery capacity increment and constant current charging curves to construct a global health factor. Secondly, the CNN is used to extract the temporal features of the global health factor, highlighting strong correlations through an attention mechanism, and the residual network is introduced to maintain information integrity. Finally, by improving the artificial bee colony algorithm for model hyperparameter optimization, the accuracy of SOH estimation is enhanced. The accuracy is validated using lithium-ion battery datasets from NASA and the University of Oxford. The results show that, even with a less accurate convolutional neural network-long short-term memory model, the proposed fine-tuning estimation method keeps the mean absolute error e_{MAE} , mean absolute percentage error e_{MAPE} , and root mean square error e_{RMSE} of the SOH estimation results within 2%. Compared with the CNN-BiGRU-Attention model, when the CNN-Residual-BiGRU-Attention model is employed to estimate the SOH of the same battery with a training set ratio of 30%, the e_{MAE} 、 e_{MAPE} and e_{RMSE} of the estimated results are reduced by 41.86%, 44.35% and 42.11%, respectively. For estimating the SOH of the same type of batteries with a training set ratio of 40%, the e_{MAE} 、 e_{MAPE} and e_{RMSE} of the estimated results are reduced by 45.51%, 45.93%, and 40.10%, respectively. These research findings provide a theoretical reference for accurately estimating the SOH of lithium-ion batteries under low training set conditions.

Keywords: lithium-ion batteries; the state of health estimation; global health factor; improved artificial bee colony algorithm; residual; bidirectional gated recurrent unit

锂离子电池因使用寿命长、能量密度高等优点,被广泛应用于新能源汽车与储能领域^[1-2]。电池健康状态(SOH)是电池管理的重要组成部分,随着电池充放电循环次数增加,电池性能和寿命不断衰减,甚至会造成安全隐患^[3-5]。因此,准确评估电池 SOH 对延长电池寿命、确保电池安全可靠运行具有重要意义^[6]。

目前,锂离子电池 SOH 估计方法可分为基于模型的估计方法和基于数据驱动的估计方法^[7]。基于模型的估计方法主要是采用电化学模型、等效电路模型或分数阶模型等描述电池内部化学反应机理,并结合先进的滤波算法实现 SOH 估计。赵月荷等^[8]将二阶 RC 等效电路模型与无迹卡尔曼滤波算法相结合,实现了锂离子电池内阻估计,并通过电池内阻与 SOH 的关系间接估计电池 SOH,可将误差控制在 1% 以内。Chen 等^[9]将温度相关的二阶 RC 等效电路模型与双自适应扩展卡尔曼滤波算法相结合,实现了不同温度下的 SOH 估计,结果表明:在-5、15、35℃环境温度下,不同工况的 SOH 估计误差均小于 1%。虽然基于模型的 SOH 估计方法的准确性和可靠性良好,但估计精度依赖于模型和参数辨识的准确性^[10]。其中,电化学模型可准确描述电池内部机理,但涉及参数过多,计算复杂,参数辨识难度高^[11];等效电路模型计算虽然相对简单但泛化性差,难以直接应用于不同电池。

基于数据驱动的 SOH 估计方法忽略电池内部复杂的电化学反应,通过建立电池健康因子与 SOH 的映射关系,实现准确 SOH 估计^[12-13]。吴青峰等^[14]提取锂离子电池输出电压、输出电流、容量和等压降放电时间 4 个局部特征,作为电池健康因子输入反向传输(BP)神经网络,实现了 SOH 估计,并联合模拟退火算法和遗传算法对 BP 神经网络进行优化,结果表明:该方法对单一电池 SOH 的估计精度较高,且在部分数据缺失情况下,依然有较高的 SOH 估计精度。方斯顿等^[15]提取最小放电电压、放电峰值温度、充电饱和电压、恒流充电电流、充电峰值温度、放电负载电压和充电峰值 7 个局部健康因子,输入双向长短期记忆(BiLSTM)模型,采用鲸鱼捕食算法优化模型超参数,并通过美国国家航空航天局(NASA)数据集验证,结果表明:利用电池可直接测量的参数作为模型输入开展 SOH 估计,结果的均方根误差基本在 7% 以内。Ding 等^[16]以恒流充电时间、恒流充电容量、放电时间和放电容量 4 个特征作为电池健康因子,输入到麻雀搜索算法优化的卷积神经-长短期记忆(CNN-LSTM)模型中开展 SOH 估计,最佳估计结果的均方误差和平均绝对误差分别为 0.67%、0.53%。

综上所述,基于数据驱动的 SOH 估计方法可避免复杂的电池建模过程,通过挖掘历史数据的老化规律实现 SOH 的准确估计。已有研究大多以电

池局部特征作为健康因子,然而锂离子电池 SOH 衰退的影响因素复杂,仅考虑局部特征无法完全描述电池的老化细节。为了全面反映锂离子电池的老化规律,本文提出了一种新的 SOH 估计方法,主要创新点如下:提出全局健康因子,以低维数据替代原高维数据,既保留了数据原有特征,又提高了模型计算效率;构建卷积神经网络-残差网络-双向门控循环单元-注意力机制(CNN-Residual-BiGRU-Attention)模型,引入残差连接确保模型训练过程信息的完整性,降低了模型梯度消失的风险。

本文的主要研究内容包括:(1)通过分段近似聚合算法对电池容量增量(IC)曲线和恒流充电曲线进行数据降维,将降维后的 IC 曲线与恒流充电曲线融合,作为全局健康因子输入模型;(2)引入残差连接构建 CNN-Residual-BiGRU-Attention 模型,实现 SOH 的准确估计;引入 Tent 混沌映射改进人工蜂群算法(ABC),采用改进人工蜂群算法(IABC)对 CNN-Residual-BiGRU-Attention 模型超参数进行寻优,提升模型的估计精度;(3)基于全局健康因子和 CNN-Residual-BiGRU-Attention 模型,采用单一电池进行预训练,以低比例训练集微调模型,实现同类电池 SOH 的准确估计。

1 实验数据集与全局健康因子提取


1.1 数据集介绍

从电池容量角度定义 SOH,计算式如下


$$S = \frac{Q}{Q_r} \times 100\% \quad (1)$$

式中: S 为电池 SOH; Q 为电池最大可用容量; Q_r 为电池额定容量。

选用 NASA 老化数据集中的 B0005、B0006 和 B0007 电池,以及牛津大学老化数据集中的 Cell1、Cell3 和 Cell8 电池进行分析研究,各电池 SOH 的变化曲线如图 1 所示。



(a) NASA 数据集



(b) 牛津大学数据集

图 1 不同数据集中电池 SOH 的变化曲线

Fig. 1 Battery SOH change curve with different data sets

NASA 锂离子电池老化实验在室温(24℃)下进行,对标称容量为 2 A·h 的商用 18650 型锂离子电池进行充放电循环。实验采用恒流-恒压充电模式,以 1.5 A 恒流充电至 4.2 V,再以恒压充电至电流降为 0.02 A;放电时,以 2 A 电流放电至 2.5 V。当电池最大可用容量降为额定容量的 30%时,实验结束。

牛津大学锂离子电池老化实验在 40℃ 环境下进行,对标称容量为 0.74 A·h 的软包电池进行充放电循环测试。采用 0.74 A 电流充电,恒流充电至 4.2 V;然后,采用动态工况放电至 2.7 V。老化实验中,每循环 100 次对电池进行一次容量测试。

1.2 全局健康因子的提取

已有研究大多使用的是局部特征因子,如恒流充电时间、恒流充电容量和放电时间等,本文定义的全局健康因子既保留了原始曲线特征,又包含了各局部特征随电池老化的变化规律。

分段近似聚合(PAA)是一种基于长时间序列数据、通过分段平均生成短时间序列的算法^[17]。PAA 将高维数据序列分段平均后重构为低维数据序列,实现了采用低维数据序列表征高维数据序列基本形态,同时减少了计算复杂度。用 n 维短时间序列 $\{O_1, O_2, O_3, \dots, O_i\} (i=1, 2, \dots, n)$ 替代原 m 维长时间序列 $\{Z_1, Z_2, Z_3, \dots, Z_j\} (j=1, 2, \dots, m)$, 定义压缩比 $k = m/n$, 则 O_i 可表示为

$$O_i = \frac{1}{k} \sum_{j=k(i-1)+1}^{ki} Z_j \quad (2)$$

有研究证明:电池容量增量曲线和充放电曲线包含众多与电池 SOH 相关性高的特征,如 IC 峰值、IC 峰下面积、恒流充电时间等^[18-21]。因此,本文选取容量增量曲线和恒流充电曲线进行 PAA 数据

降维。由于 IC 曲线和恒流充电曲线会随着电池充放电循环次数增加而变化,为了在数据降维过程中不丢失重要特征信息,将每次循环的 IC 曲线与恒流充电曲线均分为 60 段。为保证模型输入的一致性,若经过 PAA 计算后,IC 曲线与恒流充电曲线不足 60 段,则置空补齐。以 Cell1 电池为例,经过 PAA

数据降维后的 IC 曲线与恒流充电曲线如图 2 所示。定义容量变化率为单位电压下充入的电池电量,从图 2(a)~2(d)可以看出,采用 PAA 算法对数据降维,保留了原始曲线的变化特征,降维后的曲线随电池循环次数增加的变化规律与原曲线变化规律保持一致。




图 2 Cell1 电池原始曲线与经 PAA 降维后曲线的对比
Fig. 2 Comparison of Cell1 battery original curve and PAA dimension reduction curve

1.3 全局健康因子与 SOH 相关性分析

目前,许多研究采用皮尔逊相关系数评价电池健康因子与 SOH 的相关性^[22-25]。皮尔逊相关系数的具体表达式如下

$$P = \frac{\sum_{i=1}^N (f_i - \bar{f})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (f_i - \bar{f})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (3)$$

式中: f_i 、 y_i 分别为电池第 i 次循环的健康因子和真实 SOH; $\bar{f}$ 、 $\bar{y}$ 分别为健康因子和真实 SOH 的平均值; N 为电池总的循环次数。

由于提取的全局健康因子会随着循环次数增加而改变,因此无法利用皮尔逊相关系数直接评估全局健康因子与 SOH 的相关性。为了评价全局健康

因子的有效性,分别将全局健康因子和高相关性健康因子输入搭建的基础神经网络中,对比两者 SOH 的估计结果。采用决定系数 R^2 评价拟合效果的优劣, R^2 的取值范围为 $[0, 1]$, 越接近 0 表明拟合效果越差,越接近 1 表明拟合效果越好,其表达式可写为

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (4)$$

式中: $\hat{y}_i$ 为第 i 次循环时 SOH 的估计值。

以 B0006 电池为例,采用高斯滤波后,IC 峰值计算的皮尔逊相关系数为 0.991 9,表明高斯滤波后的 IC 峰值与电池 SOH 具有强相关性。以高斯滤波后的 IC 峰值作为局部健康因子,并与 IC 曲线和恒流充电曲线组

成的全局健康因子进行对比,对比过程中所用基础神经网络的神经元数为 128,其余参数均保持一致,划分 70%数据作为训练集,计算得到局部健康因子的决定系数为 0.512 4,全局健康因子的决定系数为 0.536 3,表明全局健康因子与 SOH 的相关性更强。

为进一步探究引入全局健康因子对 SOH 估计结果的影响,采用更为复杂的 CNN-LSTM 模型估计电池 SOH。设定 CNN 卷积核数为 32,LSTM 神经元数为 128,训练集比例为 60%。B0006 电池不同特征的 SOH 估计结果如图 3 所示。经过计算,得到局部健康因子的决定系数为 0.896 9,全局健康因子的决定系数为 0.943 5。从图 3 和计算得到的决定系数可以看出,CNN-LSTM 模型能有效学习电池特征与 SOH 老化规律的关联性,且在更复杂的模型中,全局健康因子对 SOH 估计精度的影响更显著。




图 3 B0006 电池不同特征的 SOH 估计结果

Fig.3 SOH estimates for B0006 battery with different characteristics

2 构建 CNN-Residual-BiGRU-Attention 模型

2.1 CNN-Residual-BiGRU-Attention 模型框架

为实现 SOH 的准确估计,本文提出了 CNN-Residual-BiGRU-Attention 模型,结构如图 4 所示。

在卷积层中,采用一维卷积层和一维最大池化层提取全局健康因子特征,一维卷积层与一维最大池化层相连,卷积核尺寸为 2,步长为 2,激活函数选择 Relu,最大池化层窗口尺寸和步长均为 2。

双向门控循环单元由一个处理正向信息的门控循环单元(GRU)和一个处理反向信息的 GRU 组成。双向门控循环单元(BiGRU)的正、反向 GRU 结构能够同时捕捉前向和后向信息,提高了对时序数据的理解能力。双向门控循环单元中, $\{x_1, x_2,$

$\dots, x_l\}$ 表示长度为 l 的输入序列, $\{h_1, h_2, \dots, h_l\}$ 表示 BiGRU 输出的隐藏状态,与输入序列相对应。




图 4 CNN-Residual-BiGRU-Attention 模型结构图

Fig.4 CNN-Residual-BiGRU-Attention model structure diagram

注意力机制层的原理与人脑注意力机制类似,聚焦于需重点关注的目标区域,通过对输入特征进行权重分配,达到突出强相关特征、忽略弱相关特征的目的。注意力机制层中, $\{q_1, q_2, \dots, q_w\}$ 为输入序列,长度为 w ; $\{G_1, G_2, \dots, G_w\}$ 为与输入序列相对应的隐藏状态; C 为各隐藏状态与对应权重乘积的和; a 为各隐藏状态的权重; G'_w 为最终输出的隐藏状态。

在 CNN-Residual-BiGRU-Attention 模型中,引入丢弃层避免模型在训练过程中产生过拟合;采用残差连接将 CNN 层与第 2 层丢弃层的输出融合,作为第 3 层 BiGRU 的输入。残差连接能够保护模型训练时特征信息的完整性,提高模型性能,同

时有效预防因模型过深造成的梯度消失。

2.2 改进人工蜂群算法

为避免因超参数设置不当造成模型的估计精度下降,本文采用 ABC 算法对提出的混合模型超参数

进行寻优。ABC 算法是一种基于蜂群觅食行为的群智能全局优化算法,通过引领蜂、跟随蜂和侦察蜂分工协作寻找最佳蜜源,即找到问题最优解^[26]。图 5 给出了 ABC 算法的流程示意图。





图 5 ABC 算法流程示意图


Fig. 5 Flowchart of ABC algorithm

在 ABC 算法中,引领蜂和跟随蜂在初始随机生成的蜜源邻域内探索新蜜源,当蜜源初始化均匀性较差时,局部搜索能力变弱,收敛速度变慢。本文通过加入帐篷混沌映射,改善了传统 ABC 算法随机生成初始蜜源的均匀性。帐篷混沌映射的数学表达式如下

$$T_{i+1} = \begin{cases} \frac{T_i}{b}, & T_i < b \\ \frac{1 - T_i}{1 - b}, & T_i \geq b \end{cases} \quad (5)$$



(a) 传统初始化效果



(b) 加入 Tent 混沌映射的初始化效果

图 6 不同初始化方法的效果对比

Fig. 6 Comparison of the effects of different initialization methods

3 实验方法及结果

3.1 实验方法

基于全局健康因子和 CNN-Residual-BiGRU-Attention 模型,本文提出了一种微调估计 SOH 方法,其具体过程如下。

(1)模型预训练。利用某一电池数据对 CNN-Residual-BiGRU-Attention 模型进行预训练,考虑到微调阶段的训练参数数量和训练时间,训练完成后冻结所有 BiGRU 层,保留其权重。

(2)微调估计电池的 SOH。将电池数据划分为训练集和测试集,使用低比例的训练集微调模型,微调训练过程中各 BiGRU 层被冻结,不改变权重,采用 CNN 和注意力机制提取并突出不同电池全局健康因子的时空特征,实现电池的 SOH 估计。

采用 B0006 和 Cell1 电池数据对模型进行预训练。训练时,设置迭代次数为 150,学习率为 0.001。预训练后,冻结所有的 BiGRU 层。微调训练时,设置迭代次数为 60,学习率为 0.001。

采用 IABC 算法,优化预训练和微调训练过程中模型的超参数。设置 IABC 算法的迭代次数为 50,引领蜂种群数为 75,跟随蜂种群数为 35,卷积核数搜索空间为[2,128],各层 BiGRU 神经元数搜索空间为[2,256],丢弃层取值搜索空间为[0,0.6],训练批次搜索空间为[2,30]。

3.2 评价指标

采用平均绝对误差 e_{MAE} 、均方根误差 e_{RMSE} 和平均绝对百分比误差 e_{MAPE} 评价 SOH 估计结果的准确性。其中, e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 越小,表明 SOH 的估计结果越准确。3 个指标的计算公式分别如下

$$e_{MAE} = \frac{1}{N} \sum_{i=1}^N (|y_i - \tilde{y}_i|) \tag{6}$$

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \tilde{y}_i)^2} \tag{7}$$

$$e_{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \tilde{y}_i|}{y_i} \times 100\% \tag{8}$$

为了评估 CNN-Residual-BiGRU-Attention 模型和微调估计 SOH 方法对锂离子电池 SOH 估计精度的影响,本文中,将 B0006 和 Cell 1 电池定义为同一电池,将 B0005 和 B0007、Cell 3 和 Cell 8 定义为同类电池。下面从同一电池的估计性能和同类电池的估计性能两个方面进行评价。

为了探究合适的训练集比例微调模型,使其达到既能保证 SOH 估计精度,又能尽量使用低比例

训练集的目的,以 B0006 和 B0007 电池为例,采用不同比例的训练集微调模型,得到的 SOH 估计结果如图 7 和图 8 所示。




图 7 采用不同比例训练集微调模型的 B0006 电池 SOH 估计结果

Fig. 7 SOH estimation results of B0006 battery with model fine-tuned using different proportions of training sets




图 8 采用不同比例训练集微调模型的 B0007 电池 SOH 估计结果

Fig. 8 SOH estimation results of B0007 battery with model fine-tuned using different proportions of training sets

表 1 和表 2 分别给出了采用不同比例训练集微调模型时,B0006 和 B0007 电池的 SOH 估计误差。从表 1 和表 2 可以看出,同一电池和同类电池的 SOH 估计精度随训练集比例的增加而提高,但当同一电池使用的训练集比例超过 30% 时,SOH 估计误差的下降幅度较小;当同类电池采用的训练集比例超过 40% 时,SOH 估计误差的下降幅度亦较小。因此,综合考虑到 SOH 估计精度和实际应用价值,对于同一电池,采用比例为 30% 的训练集微调模型;对于同类电池,采用比例为 40% 的训练集微调模型。

表 1 采用不同比例训练集微调模型的 B0006 电池 SOH 估计误差

Table 1 SOH estimation error of B0006 battery with model fine-tuned using different proportions of training sets

训练集比例	e_{MAE}	e_{MAPE}	e_{RMSE}
10%	0.010 0	0.013 3	0.011 5
20%	0.007 5	0.009 9	0.009 5
30%	0.003 1	0.004 5	0.004 0
40%	0.002 7	0.004 0	0.003 5
50%	0.002 3	0.003 4	0.003 4

表 2 采用不同比例训练集微调模型的 B0007 电池 SOH 估计误差


Table 2 SOH estimation error of B0007 battery with model fine-tuned using different proportions of training sets

训练集比例	e_{MAE}	e_{MAPE}	e_{RMSE}
20%	0.014 6	0.018 9	0.017 1
30%	0.010 2	0.013 1	0.012 2
40%	0.002 8	0.003 6	0.004 2
50%	0.002 5	0.003 3	0.003 5
60%	0.002 4	0.003 2	0.003 3


3.3 同一电池的估计性能

取 B0006 和 Cell1 电池数据集中前 30% 的数据作为训练集,微调模型并进行数据集中剩余 70% 数据的 SOH 估计。图 9(a)~9(d)展示了 B0006 和 Cell1 电池的估计结果与绝对误差。其中,绝对误差表示 SOH 估计值与真实值之差的绝对值。


从图 9(a)和 9(c)可以看出,在低比例训练集条件下,B0006 和 Cell1 电池的 SOH 估计曲线与真实曲线基本吻合;从图 9(b)和 9(d)可以看出,B0006 电池 SOH 估计的最大绝对误差为 2.14%,Cell1 电池 SOH 估计的最大绝对误差为 0.93%,表明模型的估计精度均较高。




(a)B0006 电池 SOH 估计结果



(b)B0006 电池 SOH 估计的绝对误差



(c)Cell1 电池 SOH 估计结果



(d)Cell1 电池 SOH 估计的绝对误差

图 9 B0006 和 Cell1 电池的 SOH 估计结果与绝对误差
Fig. 9 B0006 and Cell1 battery SOH estimated results and estimated absolute error

接着,将本文提出的 CNN-Residual-BiGRU-Attention 模型的 SOH 估计结果与已有模型的估计结果进行对比。所有模型训练方法保持一致,且均使用 IABC 算法进行超参数寻优,以降低超参数变化对估计结果的影响。所有模型的输入和数据集划分比例均保持一致,以排除除模型外其他因素的影响。表 3 和表 4 给出了采用不同模型时 B0006 和

Cell1 电池估计误差的对比。

表 3 不同模型下 B0006 电池的 SOH 估计误差
Table 3 B0006 battery estimation error of different models

模型	e_{MAE}	e_{MAPE}	e_{RMSE}
CNN-LSTM	0.013 6	0.019 5	0.015 2
CNN-GRU	0.008 4	0.012 5	0.010 6
CNN-BiGRU	0.007 2	0.010 4	0.008 7
CNN-GRU-Attention	0.007 3	0.010 6	0.008 5
CNN-BiGRU-Attention	0.005 9	0.009 0	0.007 8
CNN-Residual-BiGRU-Attention	0.003 1	0.004 5	0.004 0

表 4 不同模型下 Cell1 电池的 SOH 估计误差
Table 4 Cell1 battery estimation error of different models

模型	e_{MAE}	e_{MAPE}	e_{RMSE}
CNN-LSTM	0.006 1	0.007 6	0.006 5
CNN-GRU	0.004 9	0.006 2	0.006 0
CNN-BiGRU	0.004 7	0.005 8	0.005 2
CNN-GRU-Attention	0.004 1	0.005 1	0.004 6
CNN-BiGRU-Attention	0.002 7	0.003 4	0.003 6
CNN-Residual-BiGRU-Attention	0.001 9	0.002 4	0.002 6

从表 3 和表 4 可以看出,不管选取何种模型,采用本文微调估计方法得到的 SOH 估计结果均较好。即使是效果最差的 CNN-LSTM 模型,B0006 电池 SOH 估计结果的 e_{MAE} 、 e_{MAPE} 、 e_{RMSE} 分别为 1.36%、1.95%和 1.52%,Cell1 电池 SOH 估计结果的 e_{MAE} 、 e_{MAPE} 、 e_{RMSE} 分别为 0.61%、0.76%和 0.65%,两种电池的估计误差均不超过 2%。对比 CNN-GRU、CNN-GRU-Attention、CNN-BiGRU 和 CNN-BiGRU-Attention 模型的 SOH 估计误差发现,加入注意力机制有助于提高模型对电池 SOH 的估计精度。

从表 3 和表 4 中还可以看出,本文提出的 CNN-Residual-BiGRU-Attention 模型估计精度远高于其他对比模型,平均后同一电池 SOH 估计结果的 e_{MAE} 、 e_{MAPE} 、 e_{RMSE} 分别为 0.25%、0.345%和 0.33%。与 CNN-BiGRU-Attention 模型相比,平均后的 e_{MAE} 、 e_{MAPE} 、 e_{RMSE} 分别降低了 41.86%、44.35%和 42.11%。

3.4 同类电池的估计性能

将 B0005 和 B0007、Cell3 和 Cell8 电池数据集中前 40%数据作为训练集输入模型,微调模型后估计数据集中剩余 60%数据的 SOH。图 10 和图 11 给出了 4 种型号电池 SOH 的估计结果。可以看出,CNN-Residual-BiGRU-Attention 模型实现了同类电池 SOH 的准确估计,B0005 和 B0007 电池 SOH 估计的最大绝对误差分别为 1.16%、1.6%,

Cell3 和 Cell8 电池 SOH 估计的最大绝对误差分别为 0.61%、0.46%。




图 10 B0005 和 B0007 电池的 SOH 估计结果
Fig. 10 B0005 and B0007 battery SOH estimated results





图 11 Cell3 和 Cell8 电池的 SOH 估计结果
Fig. 11 Cell3 and Cell8 battery estimated results

图 12 和图 13 展示了不同模型对 B0005 和 B0007 电池,以及 Cell3 和 Cell8 电池的 SOH 估计结果。可以看出,本文 CNN-Residual-BiGRU-Attention 模型的估计精度相较其他模型有显著提升,与真实 SOH 曲线吻合更好。






图 12 不同模型下 B0005 和 B0007 电池的 SOH 估计结果
Fig. 12 SOH estimation results of B0005 and B0007 batteries
by different models





图 13 不同模型下 Cell3 和 Cell8 电池的估计结果
Fig. 13 SOH estimation results of Cell3 and Cell8 batteries
by different models

表 5、表 6 给出了不同模型下 B0005 和 B0007 电池,以及 Cell3 和 Cell8 电池的 SOH 估计误差。从表中各模型的 SOH 估计误差可以看出,即使是

估计效果最差的 CNN-LSTM 模型,对同类电池 SOH 估计结果的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 都控制在 2% 以内。对比 CNN-GRU 和 CNN-GRU-Attention、CNN-BiGRU 和 CNN-BiGRU-Attention 模型的 SOH 估计误差后发现,引入注意力机制后,模型对同类电池 SOH 的估计精度显著提升,经平均后得到的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 分别降低了 27.41%、28.39%、24.62%。

表 5 不同模型下 B0005 和 B0007 电池的 SOH 估计误差

Table 5 SOH estimation errors of B0005 and B0007 batteries by different models					
模型	电池	e_{MAE}	e_{MAPE}	e_{RMSE}	
CNN-LSTM	B0005	0.012 0	0.017 3	0.013 8	
	B0007	0.008 7	0.011 6	0.010 6	
CNN-GRU	B0005	0.009 9	0.014 2	0.011 3	
	B0007	0.008 5	0.011 3	0.010 3	
CNN-BiGRU	B0005	0.007 3	0.010 6	0.008 9	
	B0007	0.007 9	0.010 4	0.009 5	
CNN-GRU-Attention	B0005	0.006 8	0.009 7	0.007 9	
	B0007	0.006 4	0.008 5	0.007 9	
CNN-BiGRU-Attention	B0005	0.004 8	0.007 0	0.006 0	
	B0007	0.006 0	0.008 0	0.007 4	
CNN-Residual-BiGRU-Attention	B0005	0.003 2	0.004 5	0.004 0	
	B0007	0.002 8	0.003 6	0.004 2	

表 6 不同模型下 Cell3 和 Cell8 电池的 SOH 估计误差

Table 6 SOH estimation errors of Cell3 and Cell8 batteries by different models					
模型	电池	e_{MAE}	e_{MAPE}	e_{RMSE}	
CNN-LSTM	Cell3	0.004 8	0.005 9	0.005 3	
	Cell8	0.003 5	0.004 4	0.004 1	
CNN-GRU	Cell3	0.004 1	0.005 2	0.004 6	
	Cell8	0.003 4	0.004 2	0.003 8	
CNN-BiGRU	Cell3	0.003 3	0.004 2	0.004 3	
	Cell8	0.002 7	0.003 5	0.003 5	
CNN-GRU-Attention	Cell3	0.002 9	0.003 6	0.003 6	
	Cell8	0.002 2	0.002 7	0.003 0	
CNN-BiGRU-Attention	Cell3	0.002 7	0.003 3	0.003 1	
	Cell8	0.002 1	0.002 6	0.002 7	
CNN-Residual-BiGRU-Attention	Cell3	0.001 2	0.001 5	0.001 7	
	Cell8	0.001 3	0.001 7	0.001 6	

本文构建的 CNN-Residual-BiGRU-Attention 模型对同类电池 SOH 估计结果的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 均不超过 0.45%。经平均后,同类电池 SOH 估计结果的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 分别为 0.212 5%、0.282 5%、0.287 5%。相较于 CNN-BiGRU-Attention 模型,平均后的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 分别降低了 45.51%、45.93%、40.10%。

4 结 论

为准确估计锂离子电池的 SOH,提出了全局健康因子和 CNN-Residual-BiGRU-Attention 模型,并基于两者构建了一种新的微调估计 SOH 方法。采用 NASA 和牛津大学锂离子电池数据集进行验证,得到如下主要结论。

(1)将本文提出的 IC 曲线和恒流充电曲线组成的全局健康因子,与高斯滤波 IC 峰值构成的局部健康因子进行对比后发现,在基础神经网络模型中,计算得到局部健康因子的决定系数为 0.512 4,全局健康因子的决定系数为 0.536 3,表明全局健康因子与 SOH 具有更强的相关性;在较复杂的 CNN-LSTM 模型中,计算得到局部健康因子的决定系数为 0.896 9,全局健康因子的决定系数为 0.943 5,表明在复杂模型中,引入全局健康因子能明显提升电池 SOH 的估计精度。

(2)采用本文构建的 CNN-Residual-BiGRU-Attention 模型,对训练集比例为 30%的同一电池 SOH 进行估计,得到估计结果的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 分别为 0.25%、0.345%、0.33%,与 CNN-BiGRU-Attention 模型相比,分别降低了 41.86%、44.35% 和 42.11%。

(3)采用 CNN-Residual-BiGRU-Attention 模型,对训练集比例为 40%的同类电池 SOH 进行估计,得到估计结果的 e_{MAE} 、 e_{MAPE} 和 e_{RMSE} 分别为 0.212 5%、0.282 5%、0.287 5%,相较于 CNN-BiGRU-Attention 模型,分别降低了 45.51%、45.93% 和 40.10%。

虽然本文构建的 CNN-Residual-BiGRU-Attention 模型和微调估计 SOH 方法对 NASA 和牛津大学锂离子电池数据集中系列电池的估计精度较高,但锂离子电池循环寿命长,难以获取完整的 SOH 数据,本模型尚缺乏更多新型电池 SOH 数据的验证结果。在今后的研究中,应将其进一步拓展,用于更多不同类型电池数据集的估计精度和模型泛化性的实验验证。

参考文献:

[1] 尹杰, 刘博, 孙国兵, 等. 基于迁移学习和降噪自编码器-长短时间记忆的锂离子电池剩余寿命预测 [J]. 电工技术学报, 2024, 39(1): 289-302.
YIN Jie, LIU Bo, SUN Guobing, et al. Transfer learning denoising autoencoder-long short term memory for remaining useful life prediction of li-ion batteries [J]. Transactions of China Electrotechnical Society, 2024, 39(1): 289-302.

[2] 郭鹏旭, 赵理, 张丰硕. 基于随机充电片段的锂电池健康状态估计方法 [J/OL]. 电源学报. (2024-08-19) [2024-10-20]. <http://kns.cnki.net/kcms/detail/12.1420.tm.20240819.1312.002.html>.
GUO Pengxu, ZHAO Li, ZHANG Fengshuo. A method for estimating the health state of lithium batteries based on random charging segments [J/OL]. Journal of Power Supply. (2024-08-19)[2024-10-20]. <http://kns.cnki.net/kcms/detail/12.1420.tm.20240819.1312.002.html>.

[3] 李卓昊, 石琼林, 王康丽, 等. 锂离子电池健康状态估计方法研究现状与展望 [J]. 电力系统自动化, 2024, 48(20): 109-129.
LI Zhuohao, SHI Qionglin, WANG Kangli, et al. Research status and prospects of state of health estimation methods for lithium-ion batteries [J]. Automation of Electric Power Systems, 2024, 48(20): 109-129.

[4] 廖列法, 占玉敏, 刘映宝. 基于 IViT 的锂离子电池健康状态估计 [J]. 电子测量技术, 2024, 47(18): 63-70.
LIAO Liefu, ZHAN Yumin, LIU Yingbao. Lithium-ion battery state of health estimation based on IViT [J]. Electronic Measurement Technology, 2024, 47(18): 63-70.

[5] 李鹏, 葛儒哲, 董存, 等. 基于转置 Transformer 模型的电化学储能自适应 SOH 估计方法 [J/OL]. 高电压技术. (2024-08-12) [2024-10-30]. <https://doi.org/10.13336/j.1003-6520.hve.20240555>.
LI Peng, GE Ruzhe, DONG Cun, et al. Adaptive SOH estimation method based on the transpose transformer model for electrochemical energy storage [J/OL]. High Voltage Engineering. (2024-08-12)[2024-09-15]. <https://doi.org/10.13336/j.1003-6520.hve.20240555>.

[6] 李远茂, 刘桂雄. 动力锂离子电池关键参数估计方法研究进展 [J]. 中国测试, 2024, 50(6): 1-9.
LI Yuanmao, LIU Guixiong. Research progress of key parameter estimation methods for power lithium-ion batteries [J]. China Measurement & Test, 2024, 50

- (6): 1-9.
- [7] TANG Aihua, HUANG Yukun, XU Yuchen, et al. Data-physics-driven estimation of battery state of charge and capacity [J]. *Energy*, 2024, 294: 130776.
- [8] 赵月荷, 庞宗强. 基于无迹卡尔曼滤波的动力电池健康状态估计 [J]. *国外电子测量技术*, 2022, 41(10): 136-141.
- ZHAO Yuehe, PANG Zongqiang. State of health estimation of power batteries based on unscented Kalman filter [J]. *Foreign Electronic Measurement Technology*, 2022, 41(10): 136-141.
- [9] CHEN Lu, WANG Shunli, CHEN Lei, et al. An improved grey wolf optimization-double adaptive extended Kalman filtering algorithm for co-estimation of state of charge and state of health for lithium-ion batteries based on temperature-dependent second-order RC model [J]. *Ionics*, 2024, 30(8): 4631-4646.
- [10] 熊庆, 邸振国, 汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述 [J]. *高电压技术*, 2024, 50(3): 1182-1195.
- XIONG Qing, DI Zhenguo, JI Shengchang. Review on health state estimation and life prediction of lithium-ion batteries [J]. *High Voltage Engineering*, 2024, 50(3): 1182-1195.
- [11] 朱振宇, 高德欣. 基于混合网络的锂离子电池健康状态与剩余使用寿命联合估计方法 [J]. *信息与控制*, 2024, 53(1): 120-128.
- ZHU Zhenyu, GAO Dexin. Joint estimation method of state of health and remaining useful life for lithium-ion batteries based on hybrid networks [J]. *Information and Control*, 2024, 53(1): 120-128.
- [12] ZHANG Mei, YIN Jun, CHEN Wanli. SOH estimation and RUL prediction of lithium batteries based on multidomain feature fusion and CatBoost model [J]. *Energy Science & Engineering*, 2023, 11(9): 3082-3101.
- [13] 申江卫, 马文赛, 肖仁鑫, 等. 基于优化高斯过程回归算法的锂离子电池可用容量估算 [J]. *中国公路学报*, 2022, 35(8): 31-43.
- SHEN Jiangwei, MA Wensai, XIAO Renxin, et al. Available capacity estimation of lithium-ion batteries based on optimized Gaussian process regression [J]. *China Journal of Highway and Transport*, 2022, 35(8): 31-43.
- [14] 吴青峰, 杨艺涛, 刘立群, 等. 基于 GA-SA-BP 神经网络的锂电池健康状态估算方法 [J]. *电力系统保护与控制*, 2024, 52(19): 74-84.
- WU Qingfeng, YANG Yitao, LIU Liqun, et al. Lithium battery state of health estimation method based on a GA-SA-BP neural network [J]. *Power System Protection and Control*, 2024, 52(19): 74-84.
- [15] 方斯顿, 刘龙真, 孔赖强, 等. 基于双向长短期记忆网络含间接健康指标的锂电池 SOH 估计 [J]. *电力系统自动化*, 2024, 48(4): 160-168.
- FANG Sidun, LIU Longzhen, KONG Laiqiang, et al. State-of-health estimation for lithium-ion batteries incorporating indirect health indicators based on bi-directional long short-term memory networks [J]. *Automation of Electric Power Systems*, 2024, 48(4): 160-168.
- [16] DING Can, GUO Qing, ZHANG Lulu, et al. A hybrid data-driven approach for state of health estimation in lithium-ion batteries [J]. *Energy Sources: Part A Recovery, Utilization, and Environmental Effects*, 2024, 46(1): 67-83.
- [17] 司江宽, 吐松江·卡日, 范想, 等. 基于 SO-PAA-GAF 和 AdaBoost 集成学习的高压断路器故障诊断 [J]. *电力系统保护与控制*, 2024, 52(3): 152-160.
- SI Jiangkuan, TUSONGJIANG Kari, FAN Xiang, et al. Fault diagnosis of high-voltage circuit breaker based on SO-PAA-GAF and AdaBoost ensemble learning [J]. *Power System Protection and Control*, 2024, 52(3): 152-160.
- [18] OSPINA AGUDELO B, ZAMBONI W, MONMASON E. Application domain extension of incremental capacity-based battery SoH indicators [J]. *Energy*, 2021, 234: 121224.
- [19] XU Zhicheng, WANG Jun, LUND P D, et al. Estimation and prediction of state of health of electric vehicle batteries using discrete incremental capacity analysis based on real driving data [J]. *Energy*, 2021, 225: 120160.
- [20] 钱伟, 王亚丰, 王晨, 等. 基于 BP 神经网络与 H^∞ 滤波的锂电池 SoH-SoC 联合估计研究 [J]. *仪器仪表学报*, 2024, 45(6): 307-319.
- QIAN Wei, WANG Yafeng, WANG Chen, et al. Joint estimation of SoH-SoC for lithium battery based on BP neural network and H^∞ filter [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(6): 307-319.
- [21] 李习龙, 张涌, 张伟, 等. 基于健康因子和 CNN-BiLSTM 的锂离子电池健康状态预测 [J/OL]. *南京信息工程大学学报*. (2024-07-19)[2024-09-29]. <https://doi.org/10.13878/j.cnki.jnuist.20240514002>.
- LI Xilong, ZHANG Yong, ZHANG Wei, et al. Prediction of lithium-ion battery health status based on health factors and CNN-BiLSTM [J/OL]. *Journal of*

Nanjing University of Information Science & Technology. (2024-07-19)[2024-08-20]. <https://doi.org/10.13878/j.cnki.jnuist.20240514002>.

[22] 黄杰明, 黄小荣, 张庆波, 等. 基于 WPT 与 SSA 优化的数据驱动电池健康状态估计 [J/OL]. 电源学报. (2024-05-24)[2024-07-12]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20240523.1722.002.html>. HUANG Jieming, HUANG Xiaorong, ZHANG Qingbo, et al. Data-driven battery health state estimation based on WPT and SSA optimization [J/OL]. Journal of Power Supply. (2024-05-24)[2024-07-20]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20240523.1722.002.html>.

[23] 钟耿钦, 王学梅, 康龙云. 基于 GRU-BP 的锂电池部分充电数据 SOH 估计 [J/OL]. 电源学报. (2024-04-26)[2024-06-16]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20240426.1058.038.html>. ZHONG Gengqin, WANG Xuemei, KANG Longyun. SOH estimation of partial charging data for lithium batteries based on GRU-BP [J/OL]. Journal of Power Supply. (2024-04-26)[2024-05-05]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20240426.1058.038.html>.

[24] 董浩, 毛玲, 屈克庆, 等. 基于温度和 SOC 的锂离子电池特征提取及 SOH 估计 [J]. 浙江大学学报(工学版), 2023, 57(7): 1470-1478. DONG Hao, MAO Ling, QU Keqing, et al. Factor extraction and SOH estimation of lithium-ion battery based on temperature and SOC [J]. Journal of Zhejiang University(Engineering Science), 2023, 57(7): 1470-1478.

[25] GAO Renjing, ZHANG Yunfei, LYU Z. A SOH estimation method of lithium-ion batteries based on partial charging data [J]. Journal of Energy Storage, 2024, 103(Part A): 114309.

[26] KARABOGA D, BASTURK B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm [J]. Journal of Global Optimization, 2007, 39(3): 459-471.

(编辑 李慧敏)