

DOI:10.19651/j.cnki.emt.2210510

基于 CNN-BiLSTM 网络的锂离子 电池健康状态检测方法*

朱振宇 高德欣

(青岛科技大学自动化与电子工程学院 青岛 266061)

摘要: 锂离子电池健康状态(SOH)是锂离子电池可靠运行的重要参考指标,为提高电池健康状态检测的精确性,提出一种基于 CNN-BiLSTM 网络的锂电池健康状态检测方法。该方法使用 CALCE 锂离子电池容量衰减数据集,提取电池健康因子(HI)作为模型输入数据,同时利用灰色关联分析法(GRA)验证 HI 选取的合理性,采用卷积神经网络(CNN)、双向长短期记忆神经网络(BiLSTM)构建网络模型,对电池容量进行预测,实现锂离子电池健康状态检测。实验结果表明,该方法 SOH 检测的平均绝对误差为 1.3%,均方根误差为 1.78%,精确度和可靠性较高。

关键词: 锂电池;健康状态;卷积神经网络;双向长短期记忆神经网络

中图分类号: TM911 **文献标识码:** A **国家标准学科分类代码:** 530.4130

Lithium-ion batteries state of health detection method based on CNN-BiLSTM network

Zhu Zhenyu Gao Dexin

(College of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: The state of health (SOH) of lithium-ion batteries is an important reference indicator for the reliable operation of lithium-ion batteries. To improve the accuracy of the battery state of health detection, a method for the lithium batteries state of health detection based on the CNN-BiLSTM network is proposed. This method uses CALCE lithium-ion battery capacity decay data set, extracts battery health indicator (HI) as the model input data, and uses grey relational analysis (GRA) to verify the rationality of HI selection. Convolutional neural networks (CNN) and bi-directional long short-term memory (BiLSTM) are used to construct network models to predict battery capacity and to detect the health status of lithium-ion batteries. The results show that the method has 1.79% RMSE and 1.3% MAE for SOH detection, with high accuracy and reliability.

Keywords: lithium-ion battery; state of health; convolutional neural networks; bi-directional long short-term memory

0 引 言

锂离子电池作为一种理想储能设备,被广泛应用于新能源汽车等领域,其可靠性可以保证储能系统的稳定运行^[1-3]。而随着电池持续充放电过程会导致电池性能发生退化,电池老化程度可以通过电池健康状态(state of health, SOH)进行描述^[4-5]。目前,锂电池健康状态检测大多采用基于模型的方法和基于数据驱动的方法^[1,5],其中,基于模型的方法可以较好地反映电池内部化学变化特性。文献[6]通过建立多时间尺度状态空间方程,提取电池健康因子(health indicator, HI),使用双指数退化模型和无迹粒

子滤波(unscented particle filter, UPF)对电池 SOH 进行估计。文献[7]建立一阶 RC 等效电路模型检测电池老化,模型参数通过可变遗忘因子最小二乘递推算法(recursive least square, RLS)进行动态辨识,提高梯次利用锂电池各项状态估计的准确性。然而基于模型的方法计算过程复杂,模型参数辨识困难,基于数据驱动的方法无须依赖于准确的物理、化学模型构造,只需使用电池运行数据,映射出电池衰退变化^[3,8],可行性较好。

近年来,人工神经网络(artificial neural network, ANN)作为数据驱动的典型方法被广泛应用于锂离子电池健康状态检测^[1,3,9-12]。文献[11]建立一维卷积神经网络

收稿日期:2022-06-28

* 基金项目:山东省重点研发计划项目(公益类)(2019GGX101012)、山东省高等学校科学技术计划项目(J18KA323)资助

(1d convolutional neural networks, 1DCNN), 实现锂离子电池的 SOH 预测, 并对比分析不同网络结构及参数对 SOH 预测精度的影响。文献[12]建立基于模拟退火算法(simulated annealing, SA)的 BP 神经网络模型, 对比分析 SA 算法优化后对 SOH 预测的影响。为克服单一神经网络模型的缺点, 混合模型逐渐出现。文献[13]通过建立 1DCNN-LSTM 混合模型进行锂离子电池 SOH 预测, 在美国国家航空航天局(National Aeronautics and Space Administration, NASA)锂电池数据集进行验证, 预测结果优于单一神经网络模型, 预测拟合度和准确性更高。文献[14]建立一种 CNN-LSTM-DNN 混杂模型进行锂离子电池 RUL 预测, 在 NASA 和马里兰大学高级生命周期工程中心(Center for Advanced Life Cycle Engineering, CALCE)的两种电池数据集上进行实验, 结果证明该模型具有较好的精确性, 适用性更广。

为进一步提高电池健康状态检测精度, 本文使用 CALCE 锂离子电池老化数据集, 提取电池健康因子, 通过灰色关联分析法(grey relational analysis, GRA)筛选健康因子, 构建 CNN-BiLSTM 模型对电池容量和健康因子进行学习, 实现电池健康状态检测。

1 锂电池健康因子提取

1.1 锂电池 SOH 定义

锂离子电池性能退化程度可以使用 SOH 作为参考指标, 可以通过锂离子电池容量表征^[5], 如式(1)所示。

$$\text{SOH}(\tau) = \frac{C_{\tau}}{C_0} \times 100\% \quad (1)$$

式中: C_{τ} 为循环 τ -th 的电池容量, C_0 为电池初始标称容量。

为确保系统安全稳定运行, 电池失效阈值通常是容量降低到标称容量的 70%~80%^[15]。选择失效阈值为电池容量衰减至初始容量 80%, 则电池寿命结束(end of life, EOL)定义如式(2)所示。

$$\text{EOL} = C_0 \times 0.8 \quad (2)$$

式中: EOL 为失效阈值, C_0 为电池初始标称容量。

1.2 锂离子电池老化数据分析

锂离子电池老化实验所需周期较长, 目前公开的老化实验数据集较少, 本文选用 CALCE 电池数据集进行试验^[16], 数据集所选用的 CS2 型锂离子电池主要技术参数如表 1 所示。

表 1 实验数据集信息

电池组	参数	数值
CS2-35、CS2-36、 CS2-37、CS2-38	额定电压/V	4.2
	额定容量/Ah	1.1
	充电电流/A	0.55
	放电电流/A	1.1
	放电电压范围/V	4.2~2.7

锂离子电池容量真实值由安时积分法计算获得, 由于锂离子电池充放电过程所采集数据为离散数据, 因此将积分过程转化为累加求和, 如式(3)所示。

$$C = \int_0^t i d\tau = \lim_{n \rightarrow \infty} \sum_{k=2}^n i(k) \times (i(k) - i(k-1)) \quad (3)$$

式中: t 为放电时间, i 为放电电流, C 为锂离子电池容量真实值。计算得到锂电池的容量退化曲线如图 1 所示。




图 1 锂电池容量退化曲线

由图 1 可知, 容量随电池循环次数的增加逐渐衰退, 然而, 容量衰退并不是平滑向下的, 曲线中存在波动部分, 说明每个实验电池均有容量再生现象, 不能仅靠循环次数来预测电池容量, 因此本文采用提取锂电池健康因子的方式用于锂电池健康状态检测。

1.3 健康因子提取

锂离子电池 SOH 与其充放电过程中电压、电流、温度等密切相关, 因此 HI 的选择便极为重要, 第 τ 个 HI 序列可描述为:

$$\text{HI}(\tau) = \{H_{\tau}^1, H_{\tau}^2, \dots, H_{\tau}^n\} \quad (4)$$

首先获取锂电池每次充放电循环数据, 后提取恒压充电时间(constant voltage charging time, CVCT)记为 HI1; 恒流充电时间(constant current charging time, CCCT)记为 HI2; 电池端电压变换率记为 HI3。同时为分析所构建的电池健康因子与锂离子电池容量间的相关性, 采用灰色关联分析法来检验所提取 HI 的合理性, 公式如下:

$$\Delta_i(k) = |y(k) - x_i(k)| \quad (5)$$

式中: HI 序列 $x_i(k)$ 和电池容量序列 $y(k)$ 对应元素相减取绝对结果得到 $\Delta_i(k)$, 后通过关联矩阵得到相关系数; 关联矩阵如式(6)所示。

$$\delta_i(k) = \frac{\min_i \min_k \Delta_i(k) + \rho \max_i \max_k \Delta_i(k)}{\Delta_i(k) + \rho \max_i \max_k \Delta_i(k)} \quad (6)$$

式中: ρ 为分辨系数, 一般取值为 0.5。各健康因子与容量的相关系数由式(5)和(6)计算, 所得结果如表 2 所示。

表 2 健康因子灰色关联度

健康因子	CS2_35	CS2_36	CS2_37	CS2_38	平均值
HI1	0.667 3	0.659 8	0.682 8	0.667 3	0.669 3
HI2	0.945 9	0.964 8	0.966 8	0.945 9	0.955 8
HI3	0.791 4	0.731 9	0.737 9	0.791 4	0.763 1

表 2 显示电池恒流充电时间 HI2 与电池容量相关度最大,其次为电池端电压变换率 HI3,相关度大于 0.7,故选择 HI2 和 HI3 作为描述电池健康状态退化的健康因子。CS2_35 电池提取的电池恒流充电时间、电池端电压变换率与电池 SOH 映射关系如图 2 所示。图中显示 HI 值变化趋势与 SOH 衰退变化趋势是基本一致的,因此使用 HI2 和 HI3 作为神经网络输入值来进行锂离子电池健康状态检测是可行的。通过进一步分析图 2(a)与图 2(b),在循环次数逐渐增加过程中,电池恒流充电时间 HI2 则呈现相对稳定下降趋势;而电池端电压变换率 HI3 呈现先相对稳定,而后快速降低的趋势。

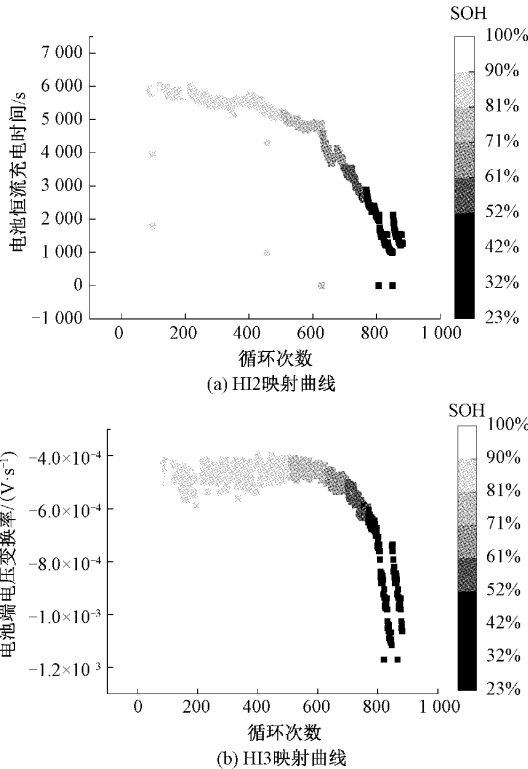


图 2 HI 与电池健康状态映射关系曲线

2 CNN-BiLSTM 网络设计

HI 数据是随时间变化的一维时序数据,为挖掘出数据中的时序特征以及 HI 和电池容量衰退间的映射规律,本文提出一种基于 CNN-BiLSTM 模型的锂离子电池健康状态检测方法。

2.1 CNN 网络

卷积神经网络通过卷积与池化操作将简单的数据特征映射到复杂的高维空间,一维卷积网络有良好的时间序列处理能力,图 3 为一维卷积网络的工作原理^[17],其中网络沿时间序列增加方向移动,卷积核大小为 3×1 ,移动步长为 1。

卷积网络通过对锂离子电池 HI 数据的局部区域进行卷积操作,输出对应的特征映射,从而提取 HI 数据上的有




图 3 一维卷积网络示意图

效特征。其输出为:

$$c_i = g(W_{CNN} * x_i + b_{CNN}) \quad (7)$$

式中: W_{CNN} 为卷积核权重, x_i 为输入序列, $*$ 为卷积运算, b_{CNN} 为偏置参数, g 为激活函数, c_i 表示一维卷积计算输出。

2.2 BiLSTM 网络

LSTM 作为 RNN 的改进网络模型,由遗忘门、输入门和输出门组成,结构如图 4 所示,计算过程如下^[1]:

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \quad (8)$$

$$i_t = \sigma(W_i [h_{t-1}, x_t] + b_i) \quad (9)$$

$$\bar{C}_t = \tanh(W_c [h_{t-1}, x_t] + b_c) \quad (10)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \bar{C}_t \quad (11)$$

$$O_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (12)$$

$$h_t = O_t \odot \tanh(C_t) \quad (13)$$

式中: C_t 是记忆单元状态, f_t 、 i_t 和 O_t 分别为遗忘门、输入门和输出门, b_f 、 b_i 、 b_o 为各门控单元对应的偏置, b_c 为输入状态偏置, W_f 、 W_i 、 W_o 为各门控单元对应权重, W_c 为输入状态权重, $\sigma(\cdot)$ 为 sigmoid 函数。

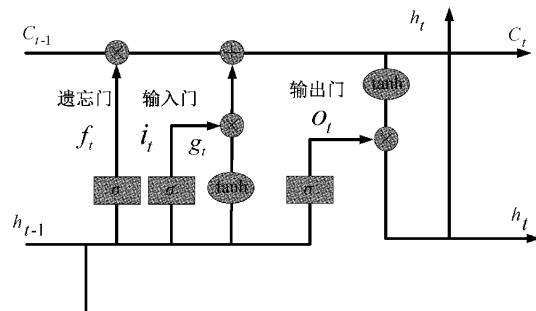


图 4 LSTM 网络结构图

BiLSTM 由两层方向相反的 LSTM 网络组成,可以同时拟合双向信息。前向隐藏层升序读取经过 CNN 网络输出序列,反向隐藏层降序读取 CNN 网络输出序列,公式如下:

$$\vec{h}_t = \text{LSTM}(x_t, \vec{h}_{t-1}) \quad (14)$$

$$\bar{h}_i = \text{LSTM}(x_i, \bar{h}_{i+1}) \quad (15)$$

式中: \bar{h}_i 表示前向隐藏状态, \bar{h}_i 表示后向隐藏状态。

2.3 CNN-BiLSTM 网络

CNN-BiLSTM 网络结构如图 5 所示,网络通过一维卷积网络对锂离子电池 HI 数据进行卷积运算,学习其有效特征,同时卷积运算减少所需训练参数的数量,并且通过权重共享降低计算量,减轻模型过拟合。BiLSTM 网络的引入可以捕获一维卷积网络所提取的信息,并且在更长的时间序列预测任务中表现得更好。同时添加全连接层,通过激活函数输出电池容量的预测结果,实现锂离子电池健康状态检测。

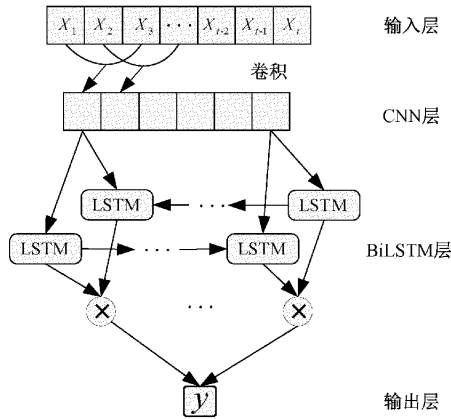


图 5 CNN-BiLSTM 网络结构

2.4 电池健康状态检测流程

基于 CNN-BiLSTM 网络的锂离子电池健康状态检测流程如图 6 所示,使用锂电池 HI 序列作为模型输入值,并初始化模型超参数。使用训练集对模型进行训练,寻找模型最优超参数,将每迭代一轮的最优模型进行记录,当达到最大迭代次数时,利用测试集对模型进行测试,得到锂电池健康状态检测结果。




图 6 锂离子电池健康状态检测流程

3 方法验证

为验证所提方法对锂离子电池健康状态检测的有效性,对 CALCE 电池数据集进行如表 3 所示的数据集划分,进行方法验证。

3.1 评价标准

为方便对比不同模型的检测效果,采用标准误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和模型决定系数 R^2 作为性能指标进行评价。RMSE, MAE, R^2 公式如式 (16)~(18) 所示。

表 3 数据集划分

数据	训练数据	测试数据
数据集一	CS2_36、CS2_37、CS2_38	CS2_35
数据集二	CS2_35、CS2_37、CS2_38	CS2_36
数据集三	CS2_35、CS2_36、CS2_38	CS2_37
数据集四	CS2_35、CS2_36、CS2_37	CS2_38

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (16)$$

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

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (18)$$

式 (16)、(17)、(18) 中, y_i 与 \hat{y}_i 分别为第 i 次充放电循环时容量的真实值与检测值, \bar{y} 为平均值。

3.2 模型对比分析

在数据集划分基础上,使用 HI 数据作为模型 CNN-BiLSTM 模型输入,实现对锂离子电池健康状态检测,模型参数设置如表 4 所示。

表 4 网络模型参数

参数名称	参数值
输入层	电池容量和 HI
卷积层	filters=64, kernel_size=3
BiLSTM 层	unit=128
Dropout 层	节点丢失概率 0.25
全连接层	unit=1
激活函数	ReLU、LeakyReLU
Epochs	200
Batch_size	128
优化器	Adam
学习率 η	0.001

CNN-BiLSTM 网络同时与 CNN、LSTM 及 GRU 网络模型进行对比训练,评估结果如表 5 所示。数据集一结果显示, CNN、LSTM 和 GRU 网络的 MAE 和 RMSE 分别获得 (0.045 8, 0.051 9), (0.034 9, 0.040 3), (0.044 5, 0.050 6); 而 CNN-BiLSTM 网络误差 MAE 为 0.018 6, RMSE 为 0.021 9 均低于其他网络模型, 特别 $R^2=0.989 0$, 拟合度最优。在剩余数据集中, CNN-BiLSTM 网络估计误差均小于其他模型估计误差。整体结果表明, CNN-BiLSTM 网络在四组数据集中, 均有优异的表现, MAE、RMSE 和 R^2 的指标均优于 CNN、LSTM 和 GRU 网络模型, 模型 SOH 检测最大均方根误差不超过 2.19%, 最大平均绝对误差为 1.86%, 模型检测精确度较高。

表 5 电池健康状态检测评估结果

数据集	模型	评价指标		
		MAE	RMSE	R^2
数据集一	CNN-BiLSTM	0.018 6	0.021 9	0.989 0
	CNN	0.045 8	0.051 9	0.937 6
	LSTM	0.034 9	0.040 3	0.962 4
	GRU	0.044 5	0.050 6	0.940 7
数据集二	CNN-BiLSTM	0.013 3	0.018 1	0.995 1
	CNN	0.064 7	0.072 4	0.921 9
	LSTM	0.023 2	0.033 9	0.982 9
	GRU	0.044 0	0.050 2	0.962 4
数据集三	CNN-BiLSTM	0.009 1	0.014 5	0.995 1
	CNN	0.049 9	0.056 9	0.924 8
	LSTM	0.021 5	0.030 4	0.978 5
	GRU	0.043 8	0.049 9	0.942 1
数据集四	CNN-BiLSTM	0.011 2	0.017 1	0.993 0
	CNN	0.047 6	0.054 9	0.927 6
	LSTM	0.023 4	0.034 4	0.971 6
	GRU	0.036 1	0.043 6	0.954 2

为直观地分析模型的检测效果,全局量结果如图 7 所示。CNN 网络全局量结果, R^2 值为 0.928, RMSE 值为 5.9%, MAE 值为 5.2%, 估计误差较大, 评价指标值对比其他网络最差, 表明 CNN 网络对时间序列数据的检测能力较神经网络差; CNN-BiLSTM 网络模型实现 1.79% 的均方根误差和 1.3% 的平均绝对误差, 对比其他网络模

型检测精确度最高。综上指标证明 CNN-BiLSTM 网络模型通过结合 CNN 和 Bi-LSTM 网络的各自优点, 提高锂电池健康状态检测的精度和长期检测性能, 能够满足锂离子动力电池健康状态检测需求, 具有较高的准确性和可靠性。

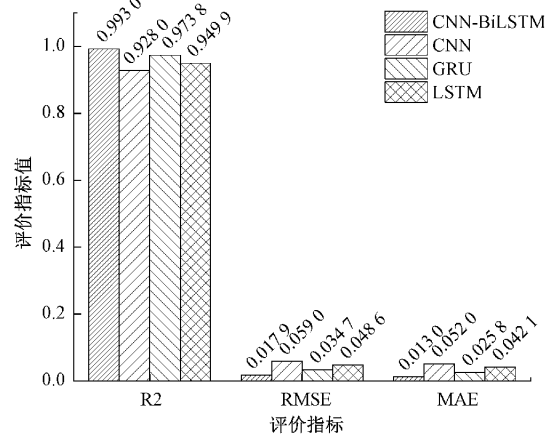


图 7 电池健康状态检测性能评估全局量结果

图 8 为电池健康状态检测曲线。图 8(a)~(d) 中检测结果显示, 当电池出现容量再生现象时, CNN、LSTM 及 GRU 均没有较好的对容量再生现象进行有效处理, 导致在再生点处检测误差较大; 其中 CNN 网络在检测后期波动较大, 长时间检测精度较低。CNN-BiLSTM 网络表现出优秀的检测能力, 可靠性较高, 能够更好的处理 HI 和电池容量间的长短期依赖关系和电池容量再生问题。综上, CNN-BiLSTM 网络能够较好的对锂离子动力电池容量衰减趋势进行映射, 提高了锂离子动力电池健康状态检测的准确性。

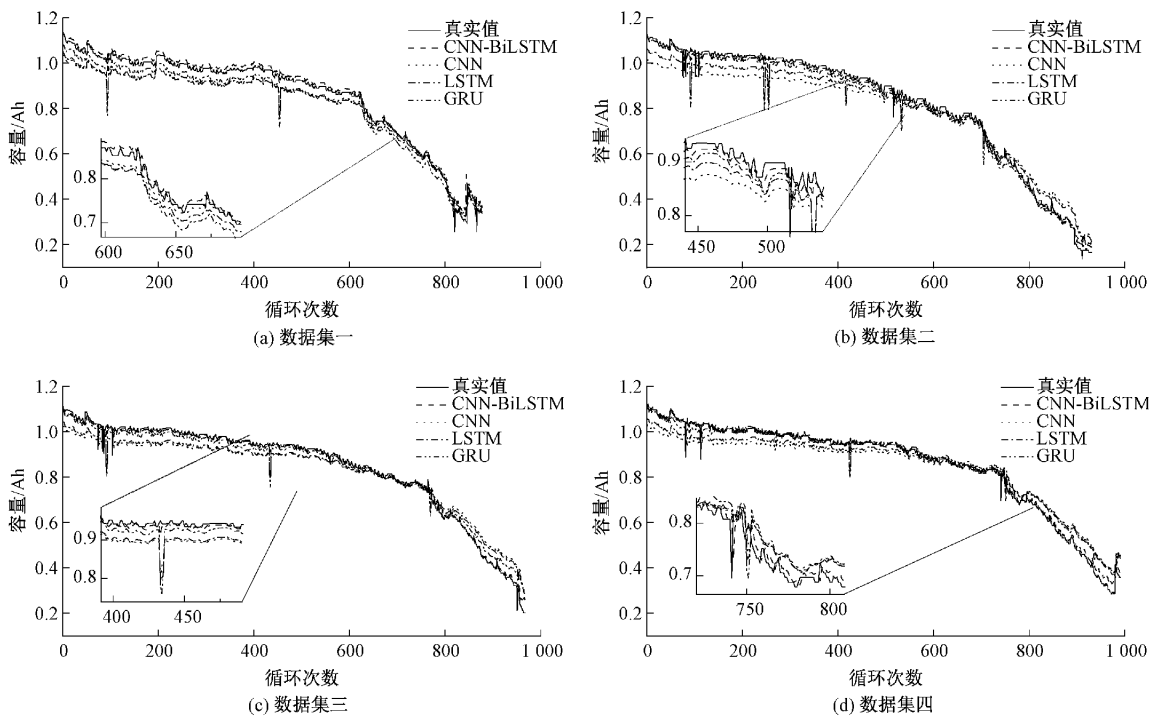


图 8 电池健康状态检测结果

4 结 论

本文提出一种基于 CNN-BiLSTM 网络的锂离子电池健康状态检测方法,以 CALCE 数据集为依托,提取恒压充电时间、恒流充电时间和电池端电压变换率作为电池健康因子,并采用灰色关联法进行筛选;建立 CNN-BiLSTM 模型进行学习训练,实验结果表明,该模型 SOH 检测的平均绝对误差为 1.3%,均方根误差为 1.78%。CNN-BiLSTM 网络模型能更好挖掘锂电池 HI 数据中深层特征,对锂电池健康状态有更好的长期检测能力,检测精确度和拟合度更高,为锂电池健康状态检测提供一种可行性方法。通过仿真实验对比,CNN-BiLSTM 网络模型作为混合网络模型,较单一网络模型更适合进行锂电池健康状态检测。

本研究目前仅以锂离子电池离线老化数据为例开展了研究,下一步还将针对电动汽车的动力电池应用数据开展进一步研究。

参考文献

- [1] 王义,刘欣,高德欣.基于 BiLSTM 神经网络的锂电池 SOH 估计与 RUL 预测[J].电子测量技术,2021,44(20):1-5.
- [2] 江境宏,明志茂,赵可沧,等.动力电池系统检测评价标准体系探讨与检测关键技术分析[J].电子测量技术,2022,45(4):45-52.
- [3] 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.
- [4] 郭庆,李敬,胡鸿志,等.锂离子电池内阻测量系统设计[J].仪表技术与传感器,2020(11):54-58,63.
- [5] 王萍,彭香园,程泽.基于 DTV-IGPR 模型的锂离子电池 SOH 估计方法[J].汽车工程,2021,43(11):1710-1719.
- [6] 高德欣,刘欣,杨清.基于卷积神经网络与双向长短时融合的锂离子电池剩余使用寿命预测[J].信息与控制,2022,51(3):318-329.
- [7] 杜帮华,张宇,吴铁洲,等.梯次利用锂离子电池等效模型参数在线辨识方法[J].储能科学与技术,2021,10(1):342-348.
- [8] 徐宏东,高海波,林治国,等.基于 CS-SVR 模型的锂离子电池 SOH 预测[J].电池,2020,50(5):424-427.
- [9] QU J, LIU F, MA Y, et al. A neural-network-based method for RUL prediction and SOH monitoring of Lithium-Ion battery[J]. IEEE Access, 2019, 7(99): 87178-87191.
- [10] 林名强,吴登高,郑耿峰,等.基于表面温度和增量容量的锂电池健康状态估计[J].汽车工程,2021,43(9): 1285-1290,1284.
- [11] 李超然,肖飞,樊亚翔,等.基于卷积神经网络的锂离子电池 SOH 估算[J].电工技术学报,2020,35(19): 4106-4119.
- [12] 徐元中,曹翰林,吴铁洲.基于 SA-BP 神经网络算法的电池 SOH 预测[J].电源技术,2020,44(3):341-345.
- [13] 王英楷,张红,王星辉.基于 1DCNN-LSTM 的锂离子电池 SOH 预测[J].储能科学与技术,2022,11(1): 240-245.
- [14] ZRAIBI B, OKAR C, CHAOUI H, et al. Remaining useful life assessment for Lithium-ion batteries using CNN-LSTM-DNN hybrid method [J]. IEEE Transactions on Vehicular Technology, 2021, 70(5): 4252-4261.
- [15] 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.
- [16] SAXENA S, HENDRICKS C, PECHT M. Cycle life testing and modeling of graphite/LiCoO₂ cells under different state of charge ranges[J]. Journal of Power Sources, 2016, 327: 394-400.
- [17] 王英楷,张红,王星辉.基于 1DCNN-LSTM 的锂离子电池 SOH 预测[J].储能科学与技术,2022,11(1): 240-245.

作者简介

朱振宇,硕士研究生,主要研究方向为锂离子电池健康状态研究。

E-mail:809442278@qq.com

高德欣(通信作者),博士,教授,主要研究方向为电动汽车技术,人工智能控制等。

E-mail:qdgaoixin@126.com