

采用深度学习的全寿命周期锂电池荷电状态估计

张林^{1,2}, 巫春玲^{1,2}, 黄鑫蓉^{1,2}, 李艳波^{1,2}

(1. 长安大学能源与电气工程学院, 710064, 西安;

2. 长安大学陕西省交通新能源开发、应用与汽车节能技术重点实验室, 710064, 西安)

摘要: 针对锂离子电池的健康状态(SOH)随着充放电循环次数的增加而持续退化,导致在整个寿命周期内准确估计电池的荷电状态(SOC)难度较高的问题,提出了一种采用深度学习的全寿命周期内锂离子电池 SOC 估计模型。该模型采用被估计时刻及之前多个历史时刻的电流、电压和温度组成的序列数据作为模型的输入,先采用一维卷积神经网络(1D CNN)提取序列的特征,再用门控循环单元(GRU)建立特征与 SOC 之间的非线性关系,然后采用贝叶斯优化方法(BO)对网络超参数进行寻优以提升预测的精度。采用两个公开数据集对所提出的模型进行验证,实验结果表明:所提模型在较宽的 SOH 范围内实现了精确的 SOC 预测,且预测精度显著优于采用单个深度学习模型的预测精度;与 CNN 和 BiLSTM 模型相比,所提模型的均方根误差分别平均降低了 15.16% 和 45.22%;当输入序列的长度为 10、数据采样间隔时间为 1 min 时,在两个数据集上预测的均方根误差均低于 2%。

关键词: 锂离子电池;荷电状态估计;深度学习;健康状态

中图分类号: TM912 **文献标志码:** A

DOI: 10.7652/xjtuxb202410003 **文章编号:** 0253-987X(2024)10-0036-08

Deep Learning-Based State-of-Charge Estimation for Lithium-Ion Batteries Across the Entire Life Cycle

ZHANG Lin^{1,2}, WU Chunling^{1,2}, HUANG Xinrong^{1,2}, LI Yanbo^{1,2}

(1. School of Energy and Electrical Engineering, Chang'an University, Xi'an 710064, China; 2. Key Laboratory of Shaanxi Province Development and Application of New Transportation Energy, Chang'an University Xi'an 710064, China)

Abstract: Accurately estimating the state-of-charge (SOC) of lithium-ion batteries throughout their entire life cycle is challenging due to the continuous degradation of their state-of-health (SOH) with increasing charge-discharge cycles. To address this issue, a deep learning-based SOC estimation model for lithium-ion batteries is proposed. The model utilizes sequential data consisting of current, voltage and temperature measurements from the estimated time and preceding time steps as input. It leverages one-dimensional convolutional neural networks (1D CNN) to extract features from the sequence and uses gated recurrent units (GRU) to establish the nonlinear relationship between the features and SOC. Bayesian optimization (BO) is applied to optimize the network hyperparameters, enhancing prediction accuracy. The proposed model is validated using two publicly available datasets. Experimental results demonstrate that it achieves accurate SOC predictions within a wide range of SOH and outperforms single deep learning models in terms of prediction accuracy. Compared with CNN and BiLSTM models, the proposed

收稿日期: 2024-03-29。 作者简介: 张林(1981—),男,博士,副教授。 基金项目: 陕西省重点研发计划资助项目(2022GY-193);陕西省教育厅服务地方专项科学研究计划资助项目(23JE021);秦创原引用高层次创新创业人才项目(QCYRCXM-2023-112)。

网络出版时间: 2024-05-29

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20240528.1240.009>

model reduces the root mean square error by an average of 15.16% and 45.22%, respectively. When the input sequence length is set to 10 and the data sampling interval is 1 minute, the root mean square error of the predictions is below 2% for both datasets.

Keywords: lithium-ion battery; state of charge; deep learning; state of health

锂离子电池具有能量密度高、热效应小、使用寿命长和自放电率低等诸多优点,不仅是动力电池最理想的选择,而且在储能领域得到了广泛应用^[1]。为了提升锂离子电池的安全性和性能,创造更高的经济效益,高智能的电池管理系统(battery management system, BMS)不可或缺。其中,锂离子电池的荷电状态(state of charge, SOC)估计是 BMS 中最重要的功能之一。精确的 SOC 估计可以及时更新电池的剩余电量,防止电池过充电和过放电,提升电池的使用效率,同时也对电池的安全工作和延长电池使用寿命具有重要意义^[2]。

在电池工作过程中, SOC 是一个动态变化的参数且无法通过实时测试获得,只能根据相关测试参数间接估计,因此实时而精确的 SOC 估计一直是业内的研究热点。作为一个复杂的电化学系统,电池 SOC 的变化影响因素众多且关联关系复杂,比如环境温度、充放电电流、自放电效应和电池的健康状态(state of health, SOH)等都会对电池 SOC 的估计产生影响^[3-4]。

目前 SOC 估计的方法众多,如安时积分法^[5]、开路电压法^[6]、模型法^[7]、数据驱动法^[8]等。不同的方法有各自的缺点,比如安时积分法的精度受限于初始值和传感器的精度;开路电压法难以实现准确的实时估计;基于模型的方法泛化能力较差等。

在诸多的方法中,深度学习方法通过强大的数据处理和特征提取能力,直接建立电池的电压、电流、温度等实时测试数据与 SOC 之间的映射模型,获得准确而稳定的 SOC 估计结果。相比于其他方法,深度学习方法既不需要 SOC 的初始值,也不存在累计误差,其特有的自学习能力还可以及时利用新的测试数据实时修正模型,调整预测结果,可以及时适应新的应用场景,拓展模型的应用范围^[9-10]。目前,基于深度学习的 SOC 估计方法已经成为最受业界关注的方法之一。

锂离子电池的实时 SOC 估计属于典型的时间序列预测,最适合采用循环神经网络(recurrent neural network, RNN)进行建模^[11]。目前,基于长短期记忆神经网络(long short-term memory, LSTM)^[12]、门控循环单元神经网络(gated recurrent unit, GRU)^[13]以及双向长短期记忆神经网络(bidirectional long short-term memory, BiLSTM)^[14]的 SOC 估计都已有文献报道。为了提升 SOC 估计的精度,对网络结构进行优

化,采用多层 RNN^[15],以及 RNN 与其他类型的神经网络相结合^[16-17]的预测方法也有文献报道。

虽然已经有了丰富的文献报道,但是目前锂离子电池 SOC 估计还存在一些难题需要解决,其中最关注的问题之一是随着充放电循环次数的增加,电池的 SOH 会持续下降,如果模型中没有考虑 SOH 的退化或者模型没有随着 SOH 的变化而更新,就会导致 SOC 估计精度随着电池退化而降低,误差增大。由于 SOH 的下降是一个缓慢且同样无法在电池工作中实时测试的参数,因此全寿命周期内 SOC 的估计具有较高的难度,目前相关的报道还较少。有文献^[18]报道了 SOH 和 SOC 联合估算,采用 SOH 的估计结果修正 SOC 的估计结果。该方法可以部分解决上述问题,但这样 SOC 的估算精度会被 SOH 的估算精度所影响。

针对上述问题,本文开展了全寿命周期内锂离子电池 SOC 估计方法研究,采用被估计时刻前一段时间的多个时刻的测试数据组成的数据序列作为预测模型的输入,建立了基于贝叶斯优化方法的一维卷积神经网络和 GRU 网络(1D CNN-GRU)锂离子电池 SOC 预测模型。

1 不同 SOH 下锂离子电池的 SOC

本文从美国国家航天局(NASA)提供的电池容量退化数据集中提取了 18650 型钴酸锂离子电池不同 SOH 下电压特性和 SOC 随电压的变化^[19],如图 1 所示。其中 SOH 的计算方法如下

$$S_{OH} = \frac{C_t}{C_0} \times 100\% \tag{1}$$

式中: S_{OH} 为电池的健康状态; C_0 为初始容量; C_t 为当下电池容量。

SOC 的计算方法如下

$$S_{OC} = S_{OC0} - \frac{\int_0^t Idt}{C_t} \tag{2}$$

式中: S_{OC} 为电池荷电状态; S_{OC0} 为初始荷电状态; I 为电池的充放电电流,设充电时电流为负,放电时电流为正。

图 1(a)是不同 SOH 下电池充电的电压曲线,随着电池 SOH 的下降,电池恒流充电过程中的电压上升斜率增大,恒流充电时间下降,电池处于恒压充电

的时间越来越长。从图中可以看到,当 $S_{OH} \approx 1$ 时,恒压充电阶段 S_{OC} 的变化范围为 $72\% \sim 100\%$,而当 $S_{OH} \approx 0.6$ 时, S_{OC} 的变化范围达 $37\% \sim 100\%$ 。在恒压充电阶段,电池的端电压几乎不发生变化,仅有电流的轻微变化,这给这个阶段 SOC 的准确估计带来了困难。

图 1(b)是在不同 SOH 下电池 SOC 随电压的变化图。从图中可以看到:在不同的 SOH 下,电池端电压对应的 SOC 是不相同的;在充电过程中,相同电池端压降下的 SOC 随 SOH 的下降而下降;在放电过程中,不同 SOH 下 SOC 的漂移趋势与充电相反。




图 1 不同 SOH 下锂离子电池的电压及 SOC 曲线
Fig. 1 Voltage and SOC curve of Li-ion battery under different SOH

目前,基于深度学习的锂离子电池 SOC 估计建模方法,普遍采用被估计时刻的电池电压、电流、温度等实时测试数据作为特征。但从上面的分析可以看到,由于电池 SOH 退化过程中电学特性的漂移,导致在不同 SOH 下电池的实时测试数据与 SOC 之间不再是单值函数关系,从而造成 SOC 估计精度的下降。

基于图 1 的分析,为了提升全寿命周期内 SOC 估计的准确性,本文采用被估计时刻及前一段时间内的多个历史时刻的数据组成的数据序列作为深度学习模型的输入。与单个时刻的数据相比,包含多个历史时刻的数据序列可以反映不同 SOH 下电池特性的退化,可以在全寿命周期内建立输入数据与 SOC 的精确关联。数据序列的采集过程如下所示:

- (1) 将测试输入数据处理为由电压 (V)、电流 (I)、温度 (T) 和时间 (t) 组成的四变量数据序列;
- (2) 根据应用场景,确定模型输入的序列长度 n (同时也是序列包含的时刻个数),以及相邻数据的测试时间间隔 Δt 。
- (3) 将待估计时刻及此时刻前 $n-1$ 个相互间隔 Δt 的时刻对应的 V 、 I 、 T ,组成 $3 \times n$ 的数据序列,作为 SOC 估计模型的输入。

2 基于贝叶斯优化 CNN-GRU 的电池 SOC 估计模型

本文结合 CNN 和 GRU 在序列数据建模方面各自的优势,提出了采用 CNN-GRU 的锂离子电池 SOC 估计模型,该模型将采用前文所述方法提取的数据序列作为模型输入,先采用若干个一维 CNN 层提取数据中 SOC 和 SOH 有关的深层特征,采用池化层将卷积层的输出减少到单个向量作为 GRU 层的输入;再由 GRU 建立 SOC 与输入特征的非线性关系;在 GRU 层后面加入 Dropout 层以避免过拟合;最后通过全连接层 (FC) 输出得到 SOC 的预测值。采用贝叶斯优化方法对网络的超参数进行寻优,以获得最佳性能的网络。模型示意图如图 2 所示。




图 2 贝叶斯优化 CNN-GRU 模型示意图
Fig. 2 Schematic diagram of CNN-GRU with Bayesian optimization

2.1 CNN 的原理

对于锂离子电池 SOC 估计场景,传感器获得的数据是典型的一维序列数据,特别适合采用一维 CNN 进行特征提取。一维 CNN 的计算过程^[20]如下

$$M_N = f(M_{N-1} * W_N + b_N) \quad (3)$$

式中: M_N 为网络第 N 层向下一层传递的值; M_{N-1} 为网络第 $N-1$ 层的输入; W_N 为第 N 层卷积核的权值向量; $*$ 代表卷积操作; b_N 为偏移向量,通过激活函数 $f(\cdot)$ 映射出该层的输出 M_N ,往往会采用池化层对输入 M_{N-1} 进行特征降维

$$M_N = \text{Pooling}(M_{N-1}) \quad (4)$$

2.2 GRU 的原理

时间序列预测适合采用循环神经网络建模,为解决传统 RNN 的短时记忆和计算收敛性等问题, Hochreiter 与 Schmidhuber 提出了 LSTM 网络^[21]。在 LSTM 的基础上,又衍生出 BiLSTM^[22] 和 GRU^[23] 等网络结构。

在诸多的模型中,GRU 具有不逊于 LSTM 的建模精度,同时又具有计算速度快、存储空间小等优点。GRU 只有两个门控结构,更新门 z_t 和重置门 r_t ,其运算过程为:以时刻 t 的输入 x_t 与时刻 $t-1$ 的隐藏层状态 h_{t-1} 为输入,通过式(5)~(6)更新重置门的输出 z_t 、更新门的输出 r_t ,再用式(7)更新候选状态 h'_t ,最后用式(8)更新隐藏层状态 h_t 。

$$r_t = \sigma(W_{rx}x_t + W_{rh}h_{t-1} + b_r) \quad (5)$$

$$z_t = \sigma(W_{zx}x_t + W_{zh}h_{t-1} + b_z) \quad (6)$$

$$h'_t = \tanh(W_{hx}x_t + W_{hr}r_th_{t-1} + b_h) \quad (7)$$

$$h_t = (1 - z_t)h_{t-1} + z_th'_t \quad (8)$$

式中: W_{rx} 、 W_{rh} 、 W_{zx} 、 W_{zh} 、 W_{hx} 、 W_{hr} 分别为更新门、重置门以及隐藏层等的权重; b_r 、 b_z 、 b_h 为上述各门的偏置; σ 和 $\tanh$ 为激活函数。

2.3 贝叶斯优化

深度学习模型的精度除了和训练数据的质量、网络结构的合理性等因素相关以外,还和模型的诸多超参数密切相关。通过优化各种超参数,可以显著的提升模型的精确度。深度学习模型的参数众多,相互关联性复杂,这给人工调参带来了困难。

本文采用贝叶斯优化方法对模型进行超参数的自动寻优^[24]。贝叶斯优化在 CNN-GRU 模型的超参数寻优过程如图 3 所示,计算步骤如下:

(1)根据预设的超参数范围,随机产生初始样本点,代入概率代理模型中,对 CNN-GRU 模型进行

训练,获得目标函数输出的损失值对概率代理模型进行修正;

(2)采用采样函数在修正后的概率代理模型中选取下一组样本点,再次对 CNN-GRU 模型进行训练,获得新的目标函数,更新样本集和概率代理模型;

(3)如果新的样本点对应的目标函数损失值符合要求,结束计算,输出当前选取的最佳参数;

(4)如果新的样本点对应的目标函数损失值不符合要求,将样本点更新到样本集中,重复执行第 2 步。

本文以获得最小的均方根误差 (root mean square error, RMSE) 为优化目标,采用高斯过程作为概率代理模型,获得了优化的参数值后,再对数据进行预测和误差分析。

3 数据预处理与网络参数设置

3.1 数据集

本文采用 2 个数据集对模型进行训练和验证,分别是美国国家航空航天局(NASA)的锂离子电池随机使用数据集^[25]和电池容量退化数据集^[19],后文分别用数据集 1 和数据集 2 代替。

3.1.1 NASA 锂离子电池随机使用数据集

该数据集由 NASA Ames 预测科学中心于 2014 年测试获得,测试对象为 LG Chem 公司生产的 18650 型锂离子电池,电池正极为钴氧化物,负极为石墨,额定容量为 2.1 A·h,常规工作电压范围为 3.2~4.2 V。该数据集共包括 28 块电池,根据不同的测试工况分成 7 组。

本文选择 17#~20# 电池(B17~B20)对模型进行验证,这一组电池是在 25℃ 的环境温度下进行随机游走(randomwalk, RW)循环和参考性能测试。测试中将电池重复充电至 4.2 V,然后使用 0.5 A 和 5 A 之间的放电电流的随机序列将其放电至 3.2 V,测试中使用定制的概率分布在 RW 放电操作期间每 1 min 选择一个新的负载设定。在每 50 个 RW 循环之后,执行一系列的参考充放电循环,以便提供电池状态健康的参考基准。参考充放电循环中的充电采用先恒流再恒压的方式,其中恒流段充电电流为 2 A,放电电流为 1 A。测试数据包括电池的采样时间、端电压、电流、电池温度等。电池容量在参考测试次数下的容量退化如图 3 所示。4 个电池共计 110 个完整的充放电循环,测试总时长 590.09 h,一共 45 803 个测试点。




图 3 电池容量随参考测试次数的退化

Fig. 3 Degradation of battery capacity with the reference tests

3.1.2 NASA 锂离子电池容量退化数据集

该数据采集于卓越故障预测中心(Prognostics Center of Excellence, PCoE)研发的锂离子电池加速寿命试验平台,测试对象为 18650 型钴酸锂离子电池,额定容量为 $2 \text{ A} \cdot \text{h}$,测试过程中对电池在不同工况下进行多次充放电循环。本文选择 B5、B6、B7、B18 这一组电池的测试数据,该组电池在 24°C 的环境温度下测试,充电时采用先恒流再恒压的方式,其中恒流段充电电流为 1.5 A ,放电电流均为 2 A ,电池的放电截止电压从 2.2 V 到 2.7 V 各不相同。

随循环次数增加,电池容量的退化如图 4 所示。从图中可以看到,不同电池的退化幅度略有区别,但都具有相似的退化趋势。4 个电池共计 632 个完整的充放电循环,测试总时长 $2\,377.85 \text{ h}$,一共 $2\,077\,016$ 个测试点。




图 4 电池容量随循环次数的退化

Fig. 4 Battery capacity degradation with number of cycles

3.1.3 数据的预处理

根据前文的分析,单个数据的时间间隔 Δt 越小、 n 越大,数据序列就包含更丰富的电池 SOH 相关信息,SOC 估计就越精确。但在实际应用中,越长时间跨度的数据可能引入的噪声也越多。考虑锂电池充放电的特点,本文在计算中选取 $\Delta t = 1 \text{ min}$, n 分别取 5、10、15、20。

本文先采用安时积分法计算出每个测试点对应的 SOC,再每间隔 1 min 选取一条数据组成训练数据集。最终随机使用数据集共选取了 $35\,538$ 条数据;容量退化数据集共选取了 $150\,718$ 条数据。

训练时,选取前 3 块电池所有数据和第 4 块电池的一部分前期循环数据进行模型训练和验证(占总循环数的 90%),第 4 块电池的剩余循环数据用于测试,对应数据集 1 中 B20 电池的后 11 个循环和数据集 2 中 B18 电池的后 63 个循环。

3.2 网络结构与参数设置

结合网络结构的特点和作者调试的经验,本文选择 3 个卷积层,并将卷积核大小 S_{filter} 、卷积核个数 N_{filter} 和 LSTM 单元的个数 N_{hidunit} 作为贝叶斯优化的寻优参数。其中 3 个卷积层的卷积核个数分别为 N_{filter} 、 $2N_{\text{filter}}$ 、 $2N_{\text{filter}}$,卷积核大小均为 S_{filter} ,步长均为 1,均对输入采用左填充。贝叶斯优化的寻优范围为 $S_{\text{filter}} \in [2, 8]$; $N_{\text{filter}} = 2^k$, $k \in [5, 9]$; $N_{\text{hidunit}} = 2^l$, $l \in [4, 12]$ 。设置模型训练的批次大小为 $1\,024$,初始学习率为 0.001 ,最大 Epoch 值为 100 ,Dropout 层的丢弃率为 0.2 。

4 模型训练与验证

为了定量评价 SOC 估计的精确度,本文采用 3 个误差评价指标,分别是均方根误差、平均绝对误差(mean absolute error, MAE)和 R^2 (R-squared),计算方法如下

$$\sigma_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - R_i)^2} \quad (9)$$

$$\sigma_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |F_i - R_i| \quad (10)$$

$$R^2 = \frac{\sum_{i=1}^n (F_i - R_i)^2 / n}{\sum_{i=1}^n (\bar{F} - R_i)^2 / n} \quad (11)$$

式中: σ_{RMSE} 为均方根误差; σ_{MAE} 为平均绝对误差; F_i

为第 i 个预测值; R_i 为第 i 个真实值; $\bar{F}$ 为真实值的平均值; n 为数据的样本量。 σ_{MAE} 反映预测值与实际值的偏差程度; σ_{RMSE} 反映预测的精度; R^2 反映的是预测值与实际值的拟合效果。不同序列长度下锂离子电池 SOC 的预测结果如表 1 所示。其中, σ_{RMSE} 和 σ_{MAE} 越小, R^2 越接近 1, 说明预测越精确。

表 1 不同序列长度下的锂离子电池 SOC 预测误差
Table 1 Prediction error of SOC under different sequence lengths

n	数据集	$\sigma_{\text{RMSE}}/10^{-2}$	$\sigma_{\text{MAE}}/10^{-2}$	R^2
5	1	2.91	1.88	0.990
	2	2.46	1.54	0.994
10	1	1.72	1.22	0.997
	2	1.70	1.07	0.997
15	1	1.58	1.09	0.997
	2	1.66	1.05	0.997
20	1	1.48	1.06	0.997
	2	1.40	1.04	0.998

从表 1 可以看到, 预测的误差随着序列长度上升而下降。从前文的分析可知, 这是由于随着序列长度的上升, 输入的数据片段包含了更长电压跨度内电池的退化信息。本文选用的两个数据集, 充放电的电流各不相同, 但均取得了较高的预测精度, 显示了模型对不同应用场景具有较强的适应能力。

从表中还可以看到, 当 $n=10$ 时, 预测的精度已经比较高, 两个数据集的预测 RMSE 均低于 2%; n 继续增长, 预测精度的提升幅度相对有限, 因此在应用中, 选择适当大小的 n 可以有效折中预测精度和模型复杂度。

当 $n=10$ 时, SOC 的预测值和实际值的对比如图 5 所示, 图中显示的是电池不同阶段的 3 个充放电循环。





图 5 SOC 的预测值和实际值
Fig. 5 Predicted and actual values of SOC

从图 5 可以看到, SOC 预测值和实际值吻合得较好, 显示了模型可以实现在较长时间跨度下高精度的预测。此时数据集 1 对应的参数寻优结果为: $S_{\text{filter}}=6, N_{\text{filter}}=64, N_{\text{hidunit}}=1\,024$; 数据集 2 对应的参数寻优结果为: $S_{\text{filter}}=6, N_{\text{filter}}=32, N_{\text{hidunit}}=2\,048$ 。

当贝叶斯优化训练数据集 1 时, 网络参数的部分计算结果如表 2 所示。

表 2 不同网络参数下的锂离子电池 SOC 的预测误差
Table 2 Prediction error of SOC under different network parameters

编号	N_{hidunit}	S_{filter}	N_{filter}	$\sigma_{\text{RMSE}}/\%$
1	32	8	128	2.31
2	16	6	64	2.27
3	4 096	6	32	1.86
4	32	3	64	3.27
5	256	5	32	1.97
6	1 024	6	64	1.75
7	256	2	256	4.34
8	2 048	8	64	1.79
9	4 096	7	64	2.13
10	512	8	512	3.21
⋮	⋮	⋮	⋮	⋮

从表 2 可以看到, 不同的网络参数下训练获得的 CNN-GRU 模型的预测精度有明显的差别, 而且难以通过观察部分计算结果获得明显的规律。尤其是当深度学习模型的参数多、参数可调整范围大的情况下, 通过贝叶斯优化方法可以有效提升模型的精度。

为了验证本模型提升预测精度的能力, 对比了不同模型的预测精度, 如表 3 所示。为了便于对比,

其中 n 均取 10;CNN 模型采用了与表 2 中的 CNN 层相同的结构,卷积核大小和数量采用贝叶斯优化方法进行寻优;BiLSTM、GRU、LSTM 模型的神经元数量采用贝叶斯优化方法进行了寻优。从表 3 可以看到:在两个数据集上本文提出的模型的预测精度都高于仅采用 CNN 或者其他类型 RNN 模型的估计精度;相比于 CNN 模型, σ_{RMSE} 平均降低了 15.16%;相比于 BiLSTM 模型, σ_{RMSE} 平均降低了 45.22%。

表 3 不同模型对锂离子电池 SOC 的预测精度
Table 3 Prediction accuracy of SOC under different models

模型	数据集	$\sigma_{\text{RMSE}}/10^{-2}$	$\sigma_{\text{MAE}}/10^{-2}$	R^2
CNN-GRU	1	1.72	1.22	0.997
	2	1.70	1.07	0.997
CNN	1	2.43	1.65	0.993
	2	1.83	1.20	0.997
BiLSTM	1	3.30	2.18	0.987
	2	2.96	2.10	0.991
LSTM	1	3.53	2.26	0.986
	2	2.70	1.95	0.993
GRU	1	3.89	2.64	0.983
	2	2.80	1.98	0.992

图 6 是不同模型下数据集 1 电池 B20 的最后一个周期的 SOC 的预测值和实际值。可以看到,相比于 CNN 和 BiLSTM 模型,CNN-GRU 模型的预测值与实际值吻合更好,相比于采用单个模型预测精度更高。




图 6 数据集 1 不同模型的 SOC 的预测值和实际值
Fig. 6 Predicted and actual values of SOC under different models

5 结 语

锂离子电池从投入使用到最后退役,时间跨度往往长达数年。在整个生命周期中,锂离子电池的容量会发生显著的下降,如果 SOC 估计时不考虑电

池 SOH 和容量的退化,估计的精度必然会随着电池使用时间的延长而下降。在电池的使用过程中,多次对模型进行校准显然是困难的。本文基于对电池不同 SOH 下电学特性退化规律进行分析的基础上,对深度学习模型的输入数据进行了优化,并提出了可以在全寿命周期内准确预测 SOC 的深度学习模型,经过不同数据集验证并和其他模型对比后发现,本文提出的模型实现了较高的预测精度。可以预见,在不同的应用场景中,如果对输入的数据序列的长度和数据间隔时间进行优化,预测精度还有提升的空间。在将来不同的应用场景中,考虑到电池的容量和充放电电流等因素不同,可以对模型输入的数据序列长度和数据间隔时间进行优化,以提升模型的泛化能力。

参考文献:

[1] 谢小荣,马宁嘉,刘威,等. 新型电力系统中储能应用功能的综述与展望 [J]. 中国电机工程学报, 2023, 43(1): 158-168.
XIE Xiaorong, MA Ningjia, LIU Wei, et al. Functions of energy storage in renewable energy dominated power systems: review and prospect [J]. Proceedings of the CSEE, 2023, 43(1): 158-168.

[2] WANG Yujie, TIAN Jiaqiang, SUN Zhendong, 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.

[3] HU Xiaosong, FENG Fei, LIU Kailong, et al. State estimation for advanced battery management: key challenges and future trends [J]. Renewable and Sustainable Energy Reviews, 2019, 114: 109334.

[4] HOSSAIN LIPU M S, HANNAN M A, KARIM T F, et al. Intelligent algorithms and control strategies for battery management system in electric vehicles: progress, challenges and future outlook [J]. Journal of Cleaner Production, 2021, 292: 126044.

[5] 李哲,卢兰光,欧阳明高. 提高安时积分法估算电池 SOC 精度的方法比较 [J]. 清华大学学报(自然科学版), 2010, 50(8): 1293-1296.
LI Zhe, LU Languang, OUYANG Minggao. Comparison of methods for improving SOC estimation accuracy through an Ampere-hour integration approach [J]. Journal of Tsinghua University(Science and Technology), 2010, 50(8): 1293-1296.

[6] LIN Cheng, YU Quanqing, XIONG Rui, et al. A study on the impact of open circuit voltage tests on state

- of charge estimation for lithium-ion batteries [J]. *Applied Energy*, 2017, 205: 892-902.
- [7] 武龙星, 庞辉, 晋佳敏, 等. 基于电化学模型的锂离子电池荷电状态估计方法综述 [J]. *电工技术学报*, 2022, 37(7): 1703-1725.
- WU Longxing, PANG Hui, JIN Jiamin, et al. A review of SOC estimation methods for lithium-ion batteries based on electrochemical model [J]. *Transactions of China Electrotechnical Society*, 2022, 37 (7): 1703-1725.
- [8] 成文晶, 潘庭龙. 基于分布估计算法 LSSVM 的锂电池 SOC 预测 [J]. *储能科学与技术*, 2020, 9(6): 1948-1953.
- CHENG Wenjing, PAN Tinglong. Prediction for SOC of lithium-ion batteries by estimating the distribution algorithm with LSSVM [J]. *Energy Storage Science and Technology*, 2020, 9(6): 1948-1953.
- [9] TIAN Jinpeng, XIONG Rui, SHEN Weixiang, et al. State-of-charge estimation of LiFePO₄ batteries in electric vehicles: a deep-learning enabled approach [J]. *Applied Energy*, 2021, 291: 116812.
- [10] LIU Yuefeng, HE Yingjie, BIAN Haodong, et al. A review of lithium-ion battery state of charge estimation based on deep learning: directions for improvement and future trends [J]. *Journal of Energy Storage*, 2022, 52(Part A): 104664.
- [11] YANG Fangfang, LI Weihua, LI Chuan, et al. State-of-charge estimation of lithium-ion batteries based on gated recurrent neural network [J]. *Energy*, 2019, 175: 66-75.
- [12] CHEMALI E, KOLLMEYER P J, PREINDL M, et al. Long short-term memory networks for accurate state-of-charge estimation of li-ion batteries [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(8): 6730-6739.
- [13] YANG Fangfang, LI Weihua, LI Chuan, et al. State-of-charge estimation of lithium-ion batteries based on gated recurrent neural network [J]. *Energy*, 2019, 175: 66-75.
- [14] BIAN Chong, HE Huoliang, YANG Shunkun. Stacked bidirectional long short-term memory networks for state-of-charge estimation of lithium-ion batteries [J]. *Energy*, 2020, 191: 116538.
- [15] YANG Fangfang, SONG Xiangbao, XU Fan, et al. State-of-charge estimation of lithium-ion batteries via long short-term memory network [J]. *IEEE Access*, 2019, 7: 53792-53799.
- [16] YANG Fangfang, ZHANG Shaohui, LI Weihua, et al. State-of-charge estimation of lithium-ion batteries using LSTM and UKF [J]. *Energy*, 2020, 201: 117664.
- [17] TIAN Yong, LAI Rucong, LI Xiaoyu, et al. A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter [J]. *Applied Energy*, 2020, 265: 114789.
- [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): 681-691.
- 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): 681-691.
- [19] PENNA J A M, NASCIMENTO C L, RODRIGUES L R. Health monitoring and remaining useful life estimation of lithium-ion aeronautical batteries [C]//2012 IEEE Aerospace Conference. Piscataway, NJ, USA: IEEE, 2012: 1-12.
- [20] BHATTACHARJEE A, VERMA A, MISHRA S, et al. Estimating state of charge for xEV batteries using 1D convolutional neural networks and transfer learning [J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(4): 3123-3135.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [22] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures [J]. *Neural Networks*, 2005, 18(5/6): 602-610.
- [23] XU Congyuan, SHEN Jizhong, DU Xin, et al. An intrusion detection system using a deep neural network with gated recurrent units [J]. *IEEE Access*, 2018, 6: 48697-48707.
- [24] 崔佳旭, 杨博. 贝叶斯优化方法和应用综述 [J]. *软件学报*, 2018, 29(10): 3068-3090.
- CUI Jiaxu, YANG Bo. Survey on Bayesian optimization methodology and applications [J]. *Journal of Software*, 2018, 29(10): 3068-3090.
- [25] BOLE B, KULKARNI C S, DAIGLE M. Adaptation of an electrochemistry-based li-ion battery model to account for deterioration observed under randomized use [C]//Proceedings of the Annual Conference of the PHM Society 2014. Moffett Field, CA, USA: The Prognostics and Health Management Society, 2014: 1-9.

(编辑 刘杨 陶晴)