

DOI:10.19651/j.cnki.emt.2107683

# 基于 BiLSTM 神经网络的锂电池 SOH 估计与 RUL 预测<sup>\*</sup>

王义 刘欣 高德欣

(青岛科技大学 自动化与电子工程学院 青岛 266061)

**摘要:** 针对锂电池健康状态(SOH)估计与剩余寿命(RUL)预测问题,设计一种基于双向长短期记忆(BiLSTM)神经网络模型的预测方法。首先,提取美国国家航空航天局(NASA)锂电池的容量数据,将容量数据转为SOH数据并作为模型输入数据。其次,建立双层BiLSTM神经网络,使用加速自适应矩估计算法(Nadam)优化函数动态调整学习率。然后,通过BiLSTM神经网络模型分析锂电池数据,建立电池容量、SOH和RUL之间的联系。最后,全连接层输出电池SOH的估计曲线,从而预测其剩余寿命。通过NASA数据进行预测实验,BiLSTM神经网络的RUL预测误差稳定在3以内,SOH预测曲线的拟合度稳定在94.211%~95.839%,BiLSTM神经网络具有更高的鲁棒性和准确性。

**关键词:** 锂电池;健康状态估;剩余寿命预测;双向长短期记忆

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

## The SOH estimation and RUL prediction of lithium battery based on BiLSTM

Wang Yi Liu Xin Gao Dexin

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

**Abstract:** Aiming at the problems of state of health (SOH) estimation and remaining useful life (RUL) prediction of lithium batteries, a prediction method based on bi-directional long short term memory (BiLSTM) neural network model is designed. Firstly, the capacity data of lithium battery of national aeronautics and space administration (NASA) is extracted, and the capacity data is converted into SOH data and used as the model input data. Secondly, a two-layer BiLSTM neural network is built and the nesterov-accelerated adaptive moment estimation algorithm (nesterov-accelerated adaptive moment estimation, Nadam) is used optimization function to dynamically adjust the learning rate. Then, the lithium battery data is analyzed through the BiLSTM neural network model to establish the connection between battery capacity, SOH and RUL. Finally, the fully connected layer outputs the estimated curve of the battery SOH to predict its remaining life. In the prediction experiments with NASA data, the RUL prediction error of the BiLSTM neural network is stable within 3, and the fit of the SOH prediction curve is stable at 94.211%~95.839%. The BiLSTM neural network has higher robustness and accuracy.

**Keywords:** lithium battery; state of health; remaining useful life prediction; bi-directional long short-term memory

## 0 引言

锂电池在循环充放电过程中,由于内部不确定的化学反应和外界环境因素的影响,锂电池健康状态不断下降直至达到退役标准。精准的锂电池健康状态<sup>[1-3]</sup>估计能效避

免电池故障造成的损失,锂电池剩余寿命<sup>[4-6]</sup>预测能有效推算电池的剩余使用循环次数,有效提高锂电池长期使用的安全性,并及时预测电池是否接近失效阈值,防止锂电池出现故障。

目前,国内外对锂电池健康状态(state of health,

收稿日期:2021-08-24

\*基金项目:国家自然科学基金(61673357)、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)、山东省研究生导师指导能力提升项目(SDYY18092)资助

SOH)估计和剩余寿命(remaining useful life, RUL)的预测方法已有诸多成果,通过智能学习(极限学习机<sup>[7]</sup>、反向传播神经网络<sup>[8]</sup>、差分整合移动平均自回归模型<sup>[9]</sup>等)挖掘锂电池工作数据中的健康信息进行 SOH 估计和 RUL 预测。文献[10]推导出了电池循环寿命与电池容量两者之间的后验概率密度公式,简化了经验模型,并将神经网络模型处理的历史数据训练结果用作改进粒子滤波动态方程的观测,该方法对粒子滤波算法进行了改进,提高了模型预测锂电池剩余寿命的精度,但粒子滤波的训练数据时容易出现计算量过大的现象。文献[11]设计一种利用量子粒子群对相关向量机优化的电池剩余寿命预测方法。该方法针对传统预测方法的训练时间较长和输出不稳定等问题,采用泛化能力更好的相关向量机方法来提高预测稳定性。针对上述方法缺少对锂电池数据的时序性分析,文献[12]利用长期记忆(long short-term memory, LSTM)神经网络具有可以保留数据中的时序信息的特点,能够充分考虑历史信息的持续性影响,在锂电池循环寿命预测领域且具有较高的预测精度。本实验考虑在传统方法的基础上进一步提高预

测精度,且考虑实际应用,对电池容量数据进行分点预测。

锂电池数据具有时序性,双向长短期记忆(bi-directional long short-term memory, BiLSTM)<sup>[13-14]</sup>具有记忆能力,能更好地长期分析时间序列之间的联系。本文提出了一种基于 BiLSTM 神经网络算法的锂电池 SOH 估计和 RUL 预测方法,BiLSTM 神经网络对锂电池数据进行双向深度处理,从而准确预测电池 SOH 变化曲线和 RUL 值。

## 1 BiLSTM 神经网络

循环神经网络(recurrent neural network, RNN)能够学习输入序列的非线性特征,但长期处理输入序列存在着梯度爆炸和消失的现象。LSTM 在 RNN 的基础上加入记忆单元,可对时间序列进行长期分析且防止梯度消失。但 LSTM 只单向训练输入数据序列,在提取数据特征时相对单一。BiLSTM 神经网络对锂电池 SOH 数据进行双向分析,提高锂电池 SOH、RUL 预测准确性,基于锂电池 BiLSTM 神经网络如图 1 所示。

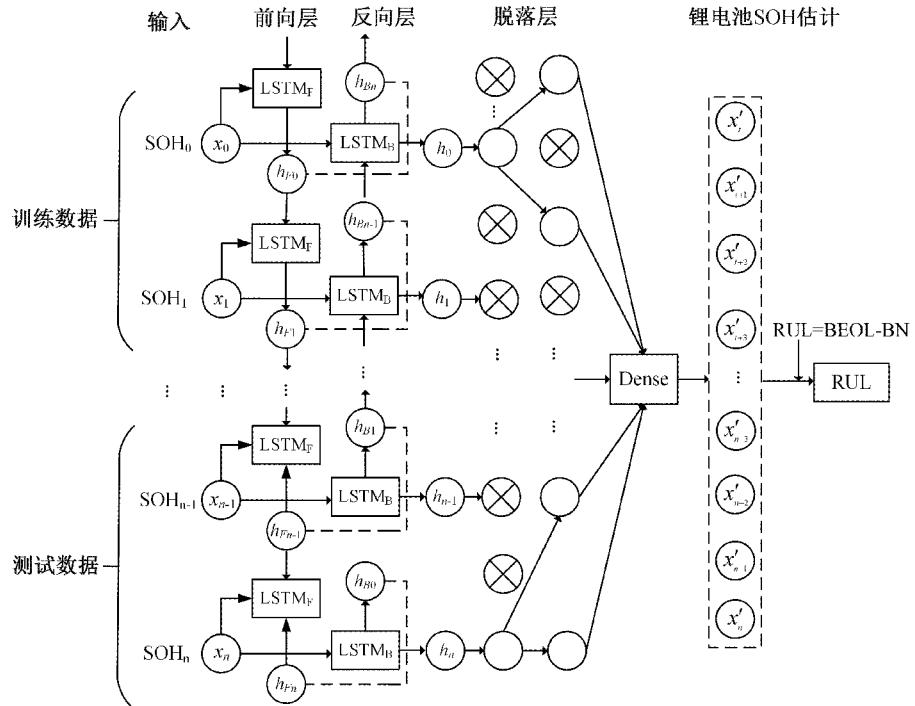


图 1 基于锂电池的 BiLSTM 神经网络设计

LSTM 模型由时间  $t$  的输入数据  $x_t$ 、记忆单元状态  $C_t$ 、隐藏层状态  $h_t$ 、忘记门  $f_t$  和输出门  $o_t$  组成。

1) 遗忘门选择删除 SOH 数据中的弱相关信息:

$$f_t = \sigma(\mathbf{W}_f[h_{t-1}, x_t] + \mathbf{b}_f) \quad (1)$$

式中:  $h_{t-1}$  表示  $t-1$  时刻存储的 SOH 信息,  $x_t$  表示 SOH 数据的输入,  $\mathbf{W}_f$ 、 $\mathbf{b}_f$  表示训练参数,  $f_t$  表示 LSTM 训练 SOH 的权重,  $\sigma$  表示 sigmoid 功能。

2) 输入门和 sigmoid 层、隐藏层共同更新记忆单元的

状态:

$$C_t = f_t C_{t-1} + \sigma \tanh(\mathbf{W}_c[h_{t-1}, x_t] + \mathbf{b}_c) \quad (2)$$

式中:  $\mathbf{W}_c$  和  $\mathbf{b}_c$  表示为训练参数,  $C_{t-1}$  表示  $t-1$  时刻记忆单元状态中保留 SOH 数据中的重要信息,  $C_t$  表示  $t$  时刻记忆单元状态中保留 SOH 数据中的重要信息。

3) 输出门决定输出信息:

$$h_t = \sigma(\mathbf{W}_o[h_{t-1}, x_t] + \mathbf{b}_o) \tanh(c_t) \quad (3)$$

式中:  $\sigma$  为 sigmoid 功能,  $\mathbf{W}_o$  表示 SOH 数据在 LSTM 输

出门训练时的权重矩阵,  $b_o$  表示 SOH 数据在 LSTM 输出门训练时的偏置。

激活函数 SELU 对 SOH 数据进行非线性变化, 公式如式(4)所示。

$$f(n) = \lambda \begin{cases} \alpha(\exp(n) - 1), & n \leq 0 \\ n, & n > 0 \end{cases} \quad (4)$$

式中:  $\alpha \approx 1.673$ ,  $\lambda \approx 1.050$ 。

在 BiLSTM 中采用加速自适应矩估计算法(nestrov-accelerated adaptive moment estimation, Nadam)<sup>[15]</sup>优化器更新网络的权值和偏置, Nadam 对学习率和梯度变化具有动态约束的能力, 适用于处理非平稳目标, 如式(5)~(10)所示。

$$\hat{\mathbf{g}}_t = \frac{\mathbf{g}_t}{1 - \prod_{i=1}^t \mu_i} \quad (5)$$

$$\mathbf{m}_t = \mu_t \cdot \mathbf{m}_{t-1} + (1 - \mu_t) \cdot \mathbf{g}_t \quad (6)$$

$$\hat{\mathbf{m}}_t = \frac{1}{1 - \prod_{i=1}^{t+1} \mu_i} \quad (7)$$

$$\mathbf{n}_t = \nu \cdot \mathbf{n}_{t-1} + (1 - \nu) \cdot \mathbf{g}_t^2 \quad (8)$$

$$\hat{\mathbf{n}}_t = \frac{\mathbf{n}_t}{1 - \nu} \bar{\mathbf{m}}_t = (1 - \mu_t) \cdot \hat{\mathbf{g}}_t + \mu_{t+1} \cdot \hat{\mathbf{m}}_t \quad (9)$$

$$\Delta\theta_t = -\frac{\bar{\mathbf{m}}_t}{\sqrt{\hat{\mathbf{n}}_t + \epsilon}} \cdot \eta \quad (10)$$

式中:  $\mathbf{m}_t$  为梯度一阶距估计,  $\mathbf{n}_t$  为梯度二阶距估计,  $\hat{\mathbf{m}}_t$  对  $\mathbf{m}_t$  进行优化校正、 $\hat{\mathbf{n}}_t$  对  $\mathbf{n}_t$  进行优化校正,  $\hat{\mathbf{g}}_t$  对  $\mathbf{g}_t$  进行优化校正,  $-\frac{\bar{\mathbf{m}}_t}{\sqrt{\hat{\mathbf{n}}_t + \epsilon}}$  对学习率进行动态约束。

BiLSTM 模型将锂电池 SOH 数据  $\{x_0, x_1, \dots, x_n\}$  分别嵌入正向和反向 LSTM 隐藏层, 分别输出  $\{h_{F0}, h_{F1}, \dots, h_{Fn}\}$  和  $\{h_{Bn}, h_{Bn-1}, \dots, h_{B0}\}$ , 将二者相结合最终输出  $\{h_0, h_1, \dots, h_n\}$ 。

## 2 实验数据源

### 2.1 锂电池 SOH 和 RUL

SOH 定义如式(11)所示。

$$SOH(t) = \frac{LBC_t}{LBC_0} \times 100\% \quad (11)$$

式中:  $LBC_t$  为锂电池满电容量,  $LBC_0$  为锂电池额定容量。

锂电池 RUL 是指 SOH 值衰减至其 70% 之间的循环次数, 如式(12)所示。

$$RUL = Battery_{EOL} - Battery_N \quad (12)$$

式中:  $Battery_{EOL}$  表示 SOH 值首次下降至其 70% 的循环次数,  $Battery_N$  为当前循环次数。

### 2.2 预测评价指标

本文使用 RUL 绝对误差 (absolute error,  $RUL_{ae}$ )、平均绝对误差 (mean absolute error, MAE) 和决定系数 (coefficient of determination,  $R^2$ ) 为评价标准, 对 BiLSTM

模型预测的锂电池 SOH 和 RUL 的进行评判。 $RUL_{ae}$ 、MAE 和  $R^2$  如式(13)~(15)所示。

$$RUL_{ae} = |Battery_{EOL} - Battery_{EOL}| \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(\mathbf{m}_i - \hat{\mathbf{m}}_i)| \quad (14)$$

$$R^2 = 1 - \frac{\sum_i (\hat{\mathbf{m}}_i - \bar{\mathbf{m}})^2}{\sum_i (\mathbf{m}_i - \bar{\mathbf{m}})^2} \quad (15)$$

式中:  $\mathbf{m}_i$  表示 SOH 数据,  $\hat{\mathbf{m}}_i$  表示 SOH 值,  $\bar{\mathbf{m}}$  表示 SOH 平均值。 $Battery_{EOL}$  为锂电池的预测寿命, 表示预测 SOH 值达到退役标准时的充放电循环次数。

### 2.3 锂电池数据源

本文采用美国国家航空航天局(National Aeronautics and Space Administration, NASA)的 18650 型 B5 和 B6 锂电池数据集, 锂电池在恒温 24 °C 的工作环境下进行循环充放电实验。锂电池 SOH 衰退曲线如图 2 所示。

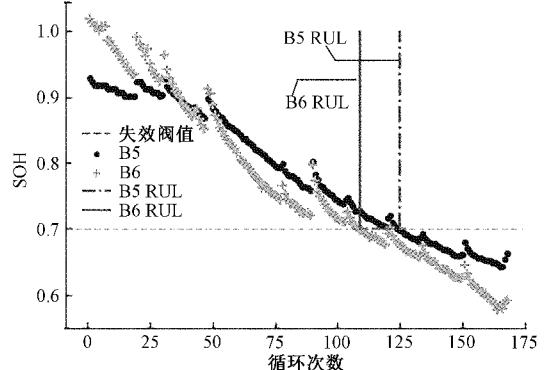


图 2 NASA 锂电池 SOH 衰退曲线和 RUL 示意图

随着循环次数的增加, B5 与 B6 锂电池的容量会逐渐衰减, 在该过程中会存在容量再生现象, B5 首次达到失效阈值点为 125 循环次数点, B6 首次达到失效阈值点为 109 循环次数点。

## 3 BiLSTM 模型的锂电池 SOH 估计与 RUL 预测

BiLSTM 模型分别与 CNN 模型、RNN 模型和 LSTM 模型进行测试比较。采用 NASA 的 B5 和 B6 锂电池数据分别以 70 次循环和 80 次循环作为预测点, 估计之后锂电池 SOH 的变化并预测 RUL。不同的预测模型结构如表 1 所示, 表 1 中  $C_i$  表示卷积层数,  $R_i$  表示 RNN 层数,  $D_i$  表示全连接层数,  $MP_i$  表示最大池化层数,  $B_i$  表示 Dense 层数,  $L_i$  表示 LSTM 层数,  $R_u$  表示 RNN 隐藏层单元数,  $F_u$  表示滤波器个数,  $D_{1u}$  表示第一层 Dense 单元数,  $D_{2u}$  表示第二层 Dense 单元数,  $L_u$  表示 LSTM 隐藏层单元数,  $B_u$  表示 BiLSTM 层单元数。SOH 估计曲线和 RUL 预测结果如表 2、图 3 和 4 所示。

由表 2、图 3 和 4 可知, RNN 模型预测 SOH 曲线与实际 SOH 曲线的拟合度和 RUL 预测准确性相对最低。在

表1 锂电池预测模型构成

方法	隐藏层层数	隐藏层设置	激活函数	dropout	优化函数	批处理大小
CNN	$C_1=1 \& MP_1=1 \& D_1=2$	$F_n=4 \& D_{1n}=100 \& D_{2n}=1$	SELU	\	Nadam	8
RNN	$R_1=2 \& D_1=2$	$R_u=80 \& D_{1u}=100 \& D_{2u}=1$	SELU	0.2	Nadam	8
LSTM	$L_1=2 \& D_1=2$	$L_u=80 \& D_{1u}=100 \& D_{2u}=1$	SELU	0.2	Nadam	8
BiLSTM	$B_1=2 \& D_1=2$	$B_u=80 \& D_{1u}=100 \& D_{2u}=1$	SELU	0.2	Nadam	8

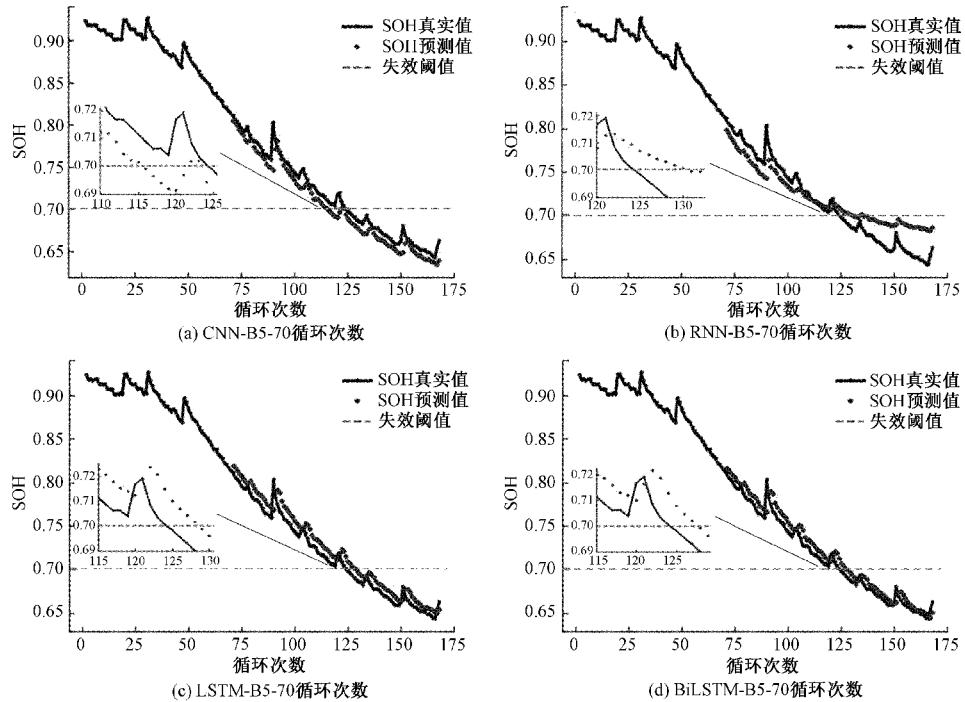


图3 B5锂电池70次循环后的SOH估计和RUL预测

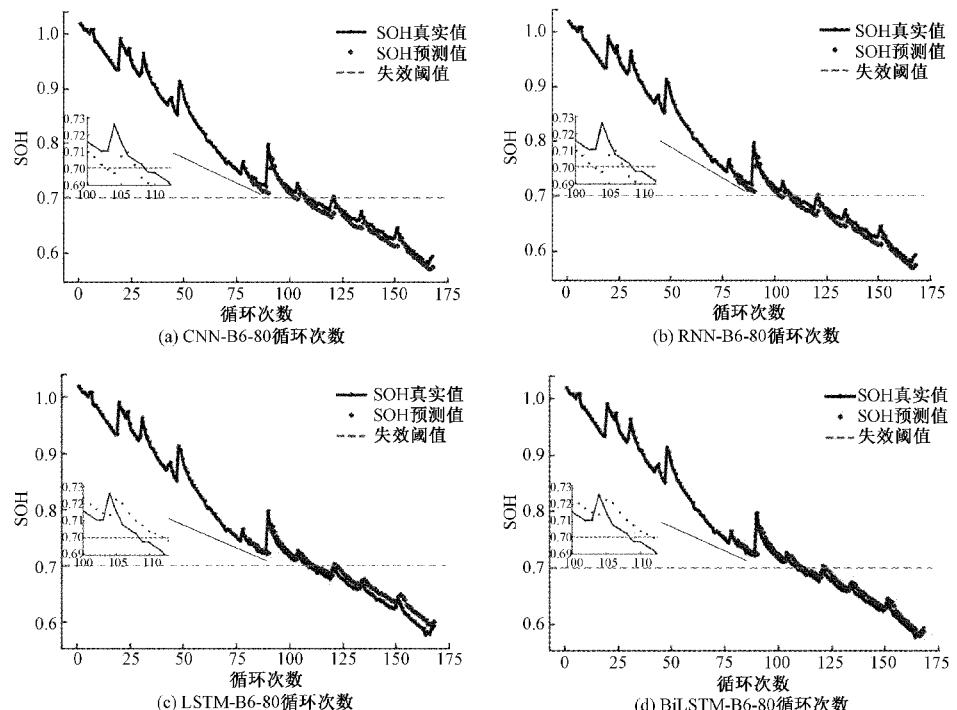


图4 B6锂电池80次循环后的SOH估计和RUL预测

表2 锂电池预测模型构成

方法	电池序号	预测点	$RUL_{ae}$	MAE/%	$R^2/%$
CNN	5	70	9	0.988 6	93.886
		80	8	0.951 0	92.168
	6	70	6	1.302 2	90.205
		80	6	0.999 0	91.883
RNN	5	70	6	1.692 4	82.711
		80	3	1.036 4	89.402
	6	70	24	2.360 2	75.669
		80	10	2.124 8	81.870
LSTM	5	70	4	1.060 9	94.419
		80	5	0.612 0	95.236
	6	70	4	1.088 9	94.270
		80	4	1.202 7	91.575
BiLSTM	5	70	3	0.872 9	95.839
		80	0	0.567 0	95.780
	6	70	3	0.962 8	94.923
		80	3	0.962 8	94.211

四个不同的预测点处,RNN模型SOH估计和RUL预测的结果指标: $R^2$ 值最高为89.402%;MAE值最低为1.036 4%; $RUL_{ae}$ 值最低为3,最大为24。RNN模型预测存在梯度爆炸和预测不稳定等问题,当训练数据较少时,预测准确度较低。

CNN模型适用于时间序列的深层提取,与RNN模型相比,SOH曲线估计稳定性和RUL预测准确度更高。在4个不同的预测点处,CNN模型SOH估计和RUL预测的结果指标: $R^2$ 值最高为93.886%;MAE值最低为0.951 0%; $RUL_{ae}$ 值最低为6,最大为9。

与CNN模型相比,LSTM模型通过存储单元存储重要信息,对时间序列具有较强的分析能力。与RNN模型相比,LSTM模型能更好地解决梯度爆炸和长期依赖问题。在4个不同的预测点处,LSTM模型SOH估计和RUL预测的结果指标: $R^2$ 值最高为95.236%;MAE值最低为0.612 0%; $RUL_{ae}$ 值在5以内。

与LSTM模型相比,BiLSTM模型从两个方向对数据进行分析,全面提高了预测精度和稳定性。BiLSTM模型预测 $RUL_{ae}$ 值在3以内,每个预测点的 $R^2$ 值在94%以上,MAE值稳定在1%以下,BiLSTM模型预测SOH曲线与实际SOH曲线的拟合度稳定性和拟合度都大幅度提升。

## 4 结论

本文提出基于BiLSTM融合神经网络的锂电池SOH估计和RUL预测方法。双向长短记忆神经网络从前向层和反向层训练输入序列,提高了预测精度和稳定性。使用NASA锂电池数据来验证算法的实用性,通过训练部分数据,建立容量与SOH、RUL之间的联系,估计锂电池SOH

随循环次数的增加而衰退的曲线,从而预测锂电池RUL。此实验只用了BiLSTM单一算法,并未考虑到锂电池容量的再生问题,因此未来可以利用其他算法解决该问题,从而进一步提高预测精度。

## 参考文献

- [1] 刘大同,宋宇晨,武巍,等.锂电池组健康状态估计综述[J].仪器仪表学报,2020,41(11): 1-18.
- [2] 王聪聪,叶思成,裴春兴,等.电池健康状态实验与评估方法综述[J].电池,2021,51(2):197-200.
- [3] 王振新,秦鹏,康健强,等.基丁衰退机理的三元锂电池SOH的诊断与估算[J].电子测量技术,2020,43(10): 7-13.
- [4] 张伟,王文.基于新健康指标的锂电池容量估计研究[J].电子测量技术,2020,43(2):10-15.
- [5] 丁阳征,贾建芳.多组间接参数的锂电池剩余寿命预测[J].电子测量技术,2019,42(17):111-118.
- [6] 刘月峰,赵光权,彭喜元.锂离子电池循环寿命的融合预测方法[J].仪器仪表学报,2015,36(7):1462-1469.
- [7] 姜媛媛,刘柱,罗慧,等.锂电池剩余寿命的ELM间接预测方法[J].电子测量与仪器学报,2016,30(2): 179-185.
- [8] 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.
- [9] 陶耀东,李宁.基于ARIMA模型的工业锂电池剩余使用寿命预测[J].计算机系统应用,2017,26(11):282-287.
- [10] 张宁,汤建林,彭发豫,等.磷酸铁锂动力电池循环寿命预测方法[J].电子测量与仪器学报,2021,35(1):33-39.
- [11] 何畏,罗潇,曾珍,等.利用QPSO改进相关向量机的电池寿命预测[J].电子测量与仪器学报,2020,34(6): 18-24.
- [12] 王军祥.基于长短期记忆网络的锂电池循环寿命预测[J].成都大学学报(自然科学版),2020,39(3):282-285.
- [13] 蔡亮,周泓岑,白恒,等.基丁多层次BiLSTM和改进粒子群算法的应用负载预测方法[J].浙江大学学报(工学版),2020,54(12):2414-2422.
- [14] 龚飘怡,罗云峰,方哲梅,等.基于Attention-BiLSTM-LSTM神经网络的短期电力负荷预测方法[J].计算机应用,2021,41(S1):81-86.
- [15] HAN Y, WANG C, REN Y, et al. Short-term prediction of bus passenger flow based on a hybrid optimized LSTM Network [J]. ISPRS International Journal of Geo-Information, 2019, 8(9): 366.

## 作者简介

王义,硕士研究生,主要研究方向为深度学习、电动汽车充电设备与充电方法等。

E-mail:1668375030@qq.com

刘欣,硕士研究生,主要研究方向为深度学习、锂离子电池检测技术等。

E-mail:1045129518@qq.com

高德欣,博士,教授,主要研究方向为人工智能、优化控制、电动汽车充电技术等。

E-mail:qdgaodexin@126.com