

DOI: 10.13382/j.jemi.B2105034

基于 GBDT 算法的锂电池剩余使用寿命预测*

刘琼 张豹

(北京信息科技大学自动化学院 北京 100192)

摘要: 针对现有方法对锂电池剩余使用寿命(RUL)预测精度不高,模型训练时间较长的问题,提出一种基于梯度提升决策树算法(GBDT)结合网格搜索法(GS)的预测模型。首先,分析锂电池的充放电循环过程,确定电压、电流、温度为可用健康因子(HI);其次,处理历史数据中的异常值,并均值化可用健康因子数据为特征输入;最后,通过GBDT算法建立锂电池剩余使用寿命预测模型,并采用GS优化模型参数。基于NASA锂电池容量衰减数据,实验结果表明,模型在RMSE、MAE、MAPE评价指标上相对其他方法均提升了约10倍,并且可将锂电池剩余使用寿命预测误差率控制在0.05以内,训练时间缩减至4.5s。

关键词: GBDT; 剩余使用寿命; 锂电池; 网格搜索; 健康因子

中图分类号: TP183 **文献标识码:** A **国家标准学科分类代码:** 510.40

Remaining useful lifetime prediction for lithium battery based on GBDT algorithm

Liu Qiong Zhang Bao

(College of Automation, Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: To solve the problems of the existing remaining useful lifetime prediction methods for lithium battery with low prediction accuracy and long training time, a prediction model based on GBDT algorithm with grid search method is proposed. Firstly, analyze the charge-discharge cycle of lithium battery and select voltage, current and temperature as useful health index. Secondly, process the outliers of historical data and average useful health index data as feature input. Finally, establish the remaining useful lifetime prediction model for lithium battery by GBDT algorithm and optimize parameters by grid search method. Based on the capacity decay data of NASA lithium battery, the results show that the prediction model is superior to other methods about tenfold in RMSE, MAE, MAPE. The remaining useful lifetime prediction error is within 0.05 and the training time reduces to 4.5 s.

Keywords: GBDT; remaining useful lifetime; lithium battery; grid search; health index

0 引言

随着新能源革命的崛起,锂电池以其成本低、寿命长、绿色清洁、能量密度高等优点,逐渐被运用到生活的各个方面^[1-3]。锂电池在充放电循环过程中,内部会发生一系列的物理和化学变化,从而导致电池内阻增大,容量衰减^[4],当电池容量减小到失效阈值时(低于标称容量的70%),电池的性能会大大的降低,此时需要及时的维修,更换,否则将可能导致电池充放电不稳定,甚至发生爆炸,引发火灾等事故^[5]。为了避免这些情况的发生,及

时对锂电池的健康状态(state of health, SOH)进行快速、准确的评估,具有重要的研究意义^[6]。

作为反映锂电池SOH的最重要的评价标准,剩余使用寿命(remaining useful lifetime, RUL)^[7]一直都是预测研究的焦点。

目前锂电池的RUL预测主要分为模型法和数据驱动法^[8]。模型法是通过分析锂电池的物理和化学原理,建立数学和物理模型来描述锂电池的性能退化过程,如建立等效电路模型、电化学模型、布朗运动模型等^[9]实现短期SOH评估和长期RUL预测。但电池内部复杂的变化和外界环境的干扰,时刻影响着模型的预测精度。数

收稿日期: 2021-12-18 Received Date: 2021-12-18

* 基金项目:北京市自然科学基金面上项目(4202026,3212005)资助

据驱动法,不需要考虑电池内部的物理化学反应,仅通过电池外部的特征选取和特征表达便可准确预测电池的 RUL。如 Park 等^[10]使用电压、电流、温度、充电曲线等多个测量数据,结合长短时记忆(long short term memory, LSTM)算法构建了锂电池的 RUL 预测模型。王英楷等^[11]提出联合一维卷积(1DCNN)和 LSTM 对锂电池容量衰减数据进行实验,提高了锂电池的 RUL 预测精度。史永胜等^[12]采用分层极限学习机(hierarchical extreme learning machine, H-ELM)的方法,利用少量的循环数据改善了锂电池 RUL 预测结果滞后的缺点。王宇胜等^[13]结合 LSTM 和支持向量机(support vector machine, SVM)算法较好地拟合了锂电池的容量衰减变化。

综合以上分析,为了提高锂电池的 SOH 评估和 RUL 预测的精度,本文提出建立基于梯度提升决策树(gradient boosting decision tree, GBDT)算法结合网格搜索(grid search, GS)的预测模型。同时,为了较大程度的挖掘数据间的依赖信息,减少外界不确定因素的干扰,实验将以每个充放电周期内的平均电压、平均电流、平均温度为特征向量来捕捉锂电池容量在衰减过程中的微小变化。GBDT 算法的高效准确和 GS 的寻优能力,使得锂电池的 SOH 评估和 RUL 预测的精度更高,模型训练时长更短。

1 锂电池健康因子分析

1.1 锂电池工作原理

锂电池主要由正极、负极、隔膜、电解质 4 个部分组成^[14]。正负极材料可以保证 Li^+ 可逆地嵌入与脱出,以便能量的储存和释放。电解质则具有极低的 e^- 电导率和极高的 Li^+ 电导率,以便于 Li^+ 在电解液中快速地传导并减少自电。隔膜处于正、负极材料之间,避免了电池因两电极直接接触而导致短路情况的发生。此外,隔膜还具有良好的浸润性,这有助于在锂电池内部形成 Li^+ 的迁移通道。

以钴酸锂/石墨锂电池为例:充电时, Li^+ 从正极脱出,经过隔膜和电解液嵌入到负极石墨材料中, e^- 则从外电路流向负极并伴随着正极材料中 Co^{3+} 的氧化,正极材料中 Li^+ 浓度降低,负极材料中 Li^+ 浓度升高。放电时, Li^+ 从负极脱出,经过隔膜和电解液嵌入到正极材料中, e^- 则从外电路流向正极并伴随着正极材料中高价钴的还原。其工作原理如图 1 所示。

1.2 锂电池健康因子

锂电池虽然具有绿色清洁、能量密度高、可重复利用等优点,但在充放电过程中不可避免会产生电解液等材料损耗,而内部的一系列物理化学反应则会导致电池




图 1 锂电池工作原理

Fig. 1 Working principle of lithium battery

的性能降低,容量衰减。锂电池的 RUL 是指在一定的充放电循环过程后,锂电池的最大可用容量衰减到某一规定的失效阈值所需要的充放电循环次数^[7]。如图 2 所示。




图 2 锂电池性能参数随充放电周期的变化曲线

Fig. 2 Curve of lithium battery parameters within charge-discharge cycle

影响锂电池 SOH 的健康因子包括电压、电流、容量、内阻、电池温度等。SOH 定义式为:

$$SOH(i) = \frac{C_i}{C_e} \times 100\%, (i = 1, 2, 3, \dots, N) \quad (1)$$

式中: C_i 为第 i 次充放电循环的电池容量, C_e 为电池的额定容量。显然, SOH 会随着充放电过程的进行而发生明显的变化^[15]。

随着持续的充放电,电池内部的物理化学反应会导致其温度升高,增加了内阻、容量等数据的测量难度。因此,实验将选择电压、电流、温度为主要特征向量,并对锂电池每个周期内的特征数据进行均值化处理,以便更好地捕捉 SOH 的变化情况。

2 数据分析与预处理

2.1 数据集

本文以 NASA 锂电池充放电实验数据(<https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>)为实验数据集,该数据集包含 B0005、B0006、B0007、B0018 四组 18650 型钴酸锂电池,分别在充电、放电、阻抗 3 种模式下所测得的电压、电流、温度、容量、阻

抗等数据。该型号电池的额定容量为 2 Ah,用 1.5 A 的恒定电流 (CC) 对其充电,直到电池电压达到 4.2 V,然后以恒定电压 (CV) 继续充电,直到充电电流降至 20 mA。用 2 A 的恒定电流 (CC) 进行放电,直到 4 种电池的电压分别降至 2.7、2.5、2.2、2.5 V^[16]。持续的充放电循环会加速电池的老化,通过从 0.1~5 Hz 的电化学阻抗谱频率扫描获取电池内部的阻抗数据,有助于深入了解电池内部参数随电池老化而发生的变化。

当锂电池的容量衰减至额定容量的 70% 时,被视为电池的老化阈值。4 组电池的容量衰减情况如图 3 所示。图 3 中的容量突变为锂电池在休息时的物理,化学反应松弛,该过程会实现锂离子的短暂再生,从而使得锂电池容量发生突增,并且同种型号电池也会出现初始容量不同的情况。

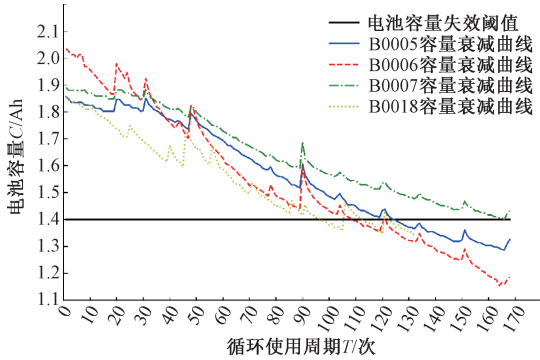


图 3 4 种锂电池的容量衰减曲线

Fig. 3 Capacity decay curves of four lithium batteries

2.2 数据预处理

在原始数据集中存在部分异常值的情况,无法直接实现数据挖掘和特征工程的分析研究。所以,在建立预测模型之前,需对原始数据进行预处理,以便降低异常值对模型预测精度的影响。针对异常值,实验选择使用该异常值前后各 10 个数据的平均值来替换。即:

$$x_i = \frac{(x_{i-10} + \dots + x_{i-1}) + (x_{i+1} + \dots + x_{i+10})}{20} \quad (2)$$

式中: x_i 为异常值的替换值, x_{i-1} 为异常值的前一个测量值, x_{i+1} 为异常值的后一个测量值。

由于在每个充放电循环周期内的电压、电流、温度的测量数据量不等,而且数据容易受到外界环境的干扰和偶发因素的影响,无法将其直接作为模型的输入数据使用,故需对每个周期内的数据进行均值化处理,以便获得可输入的实验数据,即平均电压、平均电流、平均温度。其中,均值的计算公式如下:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3)$$

式中: \bar{x} 为均值数据, x_i 为样本数据, n 为样本数。均值化

后的数据不仅可以直接作为模型的输入数据,还可以减少外界不确定因素的影响。

3 本文算法

3.1 GBDT 算法原理

梯度提升决策树算法 (gradient boosting decision tree, GBDT) 是 Boosting 集成学习算法的一种,常被用于处理分类,回归问题。该算法采用前向分布式进行迭代,每次迭代以损失函数最小为优化目标,学习基函数及更新其权重系数^[17]。假设第 $t-1$ 次迭代得到的学习器为 $f_{t-1}(x)$,损失函数为 $L(y, f_{t-1}(x))$,则第 t 次迭代的目的是寻找一个基函数 $g(x, \theta_t)$ 使得损失函数 $L(y, f_t(x))$ 最小。本文选择以回归树作为基学习器,平方误差为损失函数,即:

$$L(y, f_t(x)) = L(y, f_{t-1}(x) + g(x, \theta_t)) = [y - f_{t-1}(x) - g(x, \theta_t)]^2 = [r - g(x, \theta_t)]^2 \quad (4)$$

其中, $r = y - f_{t-1}(x)$,被称为残差,在每次迭代时实际是沿着负梯度的方向拟合每棵回归树,使残差逐渐减小。Friedman 在文献 [18] 中提出梯度提升法 (gradient boosting),在每次迭代时,使用泰勒公式的一阶展开对损失函数进行近似,即:

$$r \approx - \left[\frac{\partial L(y_i, f(x_i))}{\partial f(x_i)} \right]_{f(x) = f_{t-1}(x)} \quad (5)$$

Friedman 所提出的方法与实际的损失函数值更接近、函数的收敛速度更快、模型的预测准确率更高。GBDT 算法原理如图 4 所示。




图 4 GBDT 算法原理

Fig. 4 GBDT algorithm

3.2 本文算法

本文在确定以回归树为基学习器,平方误差为损失函数后,采用 GBDT 算法执行分裂特征的选择和最佳分裂点的计算。首先,分别计算以电压、电流、温度为分裂特征的平方差损失,并选择损失函数值最小的特征为分裂特征;其次,根据该特征,计算在不同分裂点下的分裂增益 Gain,并选择分裂增益 Gain 最大的分裂点为最佳分裂点;最后,采用贪心算法遍历所有分裂特征的所有分裂点,循环迭代分裂过程,生成 M 个基学习器,并完成整个模型的权值分布更新。即,权值的更新值与学习器的误差率成反比。

其中分裂增益 Gain 的计算如下:

$$Gain = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (6)$$

式中: G_L 为左子树的梯度值, G_R 为右子树的梯度值, H_L 为左子树的设置分数, H_R 为右子树的设置分数, γ 为叶子个数。

其中,假设电压、电流、温度 3 个输入特征的平方误差损失分别为 V_Loss 、 C_Loss 、 T_Loss ,权值更新的过程如图 5 所示。

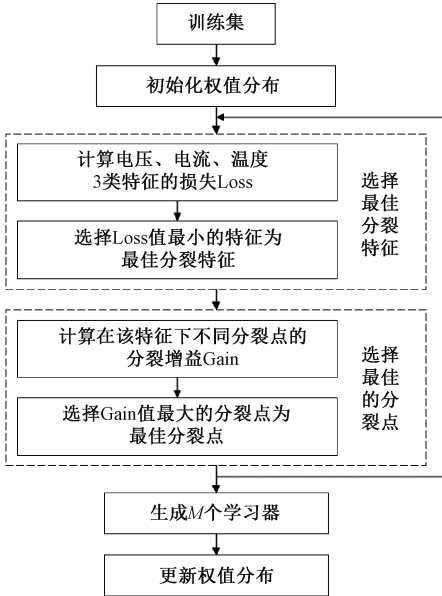


图 5 权值更新流程

Fig. 5 The weight update flowchart

3.3 基于网格搜索的参数优化

在模型训练时,学习率 l 、决策树的最大深度 d 、决策树的个数 n ,等参数对预测结果具有较大的影响,采用网格搜索法(GS)^[19]将待搜索参数在取值的空间范围内划分网格,依据经验,分别将 l 、 n 、 d 取值空间设置为 $[0.05,$

$0.15]$ 、 $[1, 10]$ 、 $[50, 150]$,空间步长设置为 0.01 、 1 、 5 。依据取值范围和空间步长,利用每一个待搜索参数的不同取值组合,对模型进行迭代训练,将使 RMSE 最小的各参数值保存为模型的最终参数。GS 优化模型参数过程如图 6 所示。

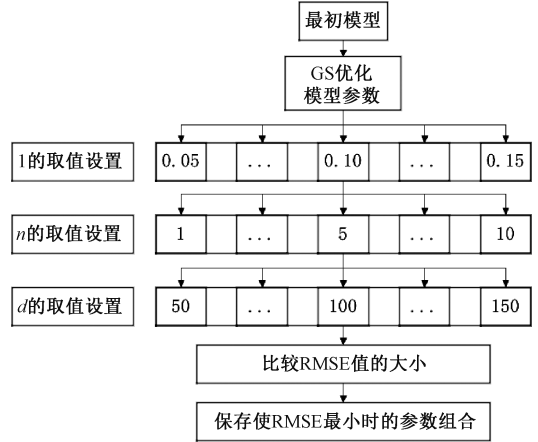


图 6 GS 优化模型参数原理

Fig. 6 GS optimize parameters of model

其中,CART 回归树算法中的剪枝策略主要被用于控制树的生长,抑制模型过拟合的发生。在经过多轮优化后,获得了具有通用性的超参数组合,即当学习率 $l=0.1$ 、决策树的最大深度 $d=5$ 、决策树的个数 $n=100$ 时,模型的 RMSE 值最小。

4 实验及结果分析

4.1 实验设置

本文将 GBDT 算法和 GS 相结合,基于 NASA 锂电池充放电实验数据,在 PyTorch 深度学习框架中实现。由于 NASA 锂电池充放电实验的数据量较少,其中 B0005、B0006、B0007 这 3 组锂电池各包含 168 个充放电循环周期,实验中则以前 100 个周期内的实验数据为训练集,后 68 个周期内的实验数据为测试集,而 B0018 号锂电池共包含 132 个充放电循环周期,实验中则以前 100 个周期内的实验数据为训练集,后 32 个周期内的数据为测试集。模型训练过程如图 7 所示。

4.2 评价标准

实验采用均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和平均百分比误差 (mean absolute percentage error, MAPE) 对模型的预测性能进行评估。3 个评估指标的计算公式分别如下:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (7)$$

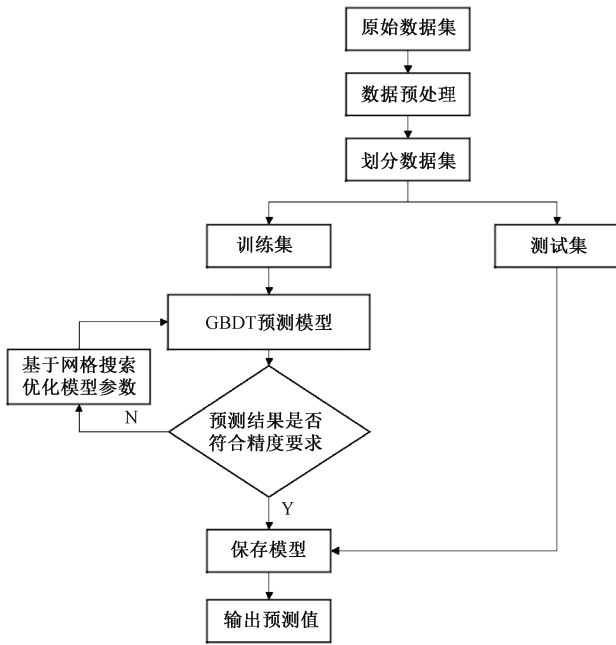


图 7 模型训练流程

Fig. 7 The model training flowchart

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (8)$$

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (9)$$

式中： y_i 为真实值； \hat{y}_i 为预测值； m 为样本数。当 RMSE、MAE、MAPE 的值越小时，说明模型的预测性能越好。

4.3 结果分析

对 B0005、B0006、B0007、B0018 这 4 组 18650 型锂电池的测试集数据进行预测输出，结果分别如图 8 ~ 11 所示。




图 8 B0005 号锂电池容量预测结果

Fig. 8 Capacity prediction of B0005




图 9 B0006 号锂电池容量预测结果

Fig. 9 Capacity prediction of B0006

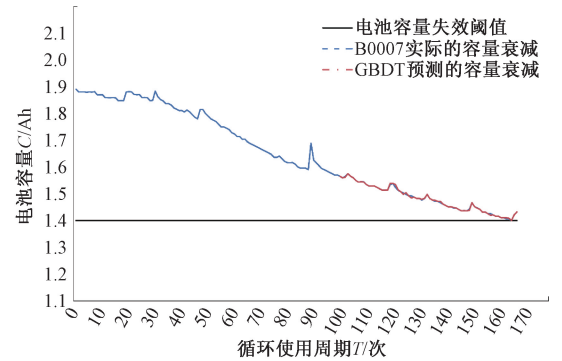


图 10 B0007 号锂电池容量预测结果

Fig. 10 Capacity prediction of B0007




图 11 B0018 号锂电池容量预测结果

Fig. 11 Capacity prediction of B0018

进行预测拟合，可实现对锂电池 SOH 的准确评估。模型对 4 种型号锂电池的 RUL 进行了相应的预测输出，预测结果如表 1 所示。

表 1 4 种型号锂电池的 RUL 预测

Table 1 RUL prediction of four lithium batteries

电池编号	C_r	C_p	RUL
B0005	125	125.041	-0.041
B0006	109	109.023	-0.023
B0007	166	165.979	0.021
B0018	97	96.993	0.007

从图 8~11 可以看出，本文基于 GBDT 算法结合 GS 所建立的预测模型可以高效的对锂电池的容量衰减曲线

表 1 中, C_r 表示锂电池的真实失效周期, C_p 表示锂电池的预测失效周期。分析表 1 可知, 该预测模型可将锂电池的 RUL 预测误差控制在 0.05 以内, 基本可实现对锂电池 RUL 的准确预测, 这可为判断锂电池是否失效提供有效的预测工具。由图 11 可知, B0018 组锂电池在到达失效周期后, 出现了容量突增现象, 这可为锂电池提供短暂的使用时间。所以, 即使锂电池已经到达了真实失效周期, 但与预测失效周期之间仍存在可接受的误差。此外, 依据 RMSE、MAE、MAPE 指标结果对比分析了本文模型与其他模型的预测性能, 其中本文所提出的模型在 3 项指标上的结果均优于其他模型, 对比结果如表 2 所示。表中“-”表示无参考值。

表 2 不同预测模型的性能指标

Table 2 Comparison of different prediction models

电池编号	实验方法	RMSE	MAE	MAPE
B0005	GWO_SVR ^[5]	0.014 7	0.010 0	-
	1DCNN_LSTM ^[11]	-	0.009 2	0.620 0
	LSTM_SVR ^[13]	0.594 0	-	0.598 0
	GA_SVR ^[20]	0.640 0	-	0.710 0
	GBDT(本文算法)	0.002 1	0.001 1	0.047 5
B0006	GWO_SVR	0.033 8	0.030 0	-
	1DCNN_LSTM	-	0.011 0	0.710 0
	GBDT(本文算法)	0.003 0	0.001 2	0.090 3
	GWO_SVR	0.0135	0.008 5	-
B0007	1DCNN_LSTM	-	0.013 0	0.830 0
	LSTM_SVR	0.566 0	-	0.564 0
	GA_SVR	0.590 0	-	0.610 0
	GBDT(本文算法)	0.001 8	0.001 5	0.046 7
B0018	GWO_SVR	0.020 4	0.014 8	-
	GBDT(本文算法)	0.004 3	0.001 9	0.150 4

5 结 论

本文针对 NASA 锂电池充放电实验数据, 建立了基于 GBDT 算法结合 GS 的 RUL 预测模型, 并对比分析了不同模型的预测性能和实验结果, 由实验结果可知, 该模型可将锂电池的 RUL 预测误差控制在 0.05 以内, 实现对锂电池 RUL 的准确预测。此外, 优化后模型的 RMSE、MAE、MAPE 这 3 项指标均优于其他预测模型, 整体预测性能最优。未来将进一步研究影响锂电池 RUL 的其他健康因子, 以便更准确地预测锂电池的 RUL, 并对锂电池的使用保护、延用维修给出合理性的建议。

参考文献

[1] 刘大同, 周建宝, 郭力萌, 等. 锂离子电池健康评估和寿命预测综述[J]. 仪器仪表学报, 2015, 36(1): 1-16.
LIU D T, ZHOU J B, GUO L M, et al. Survey on lithium-ion battery health assessment and cycle life estimation[J]. Chinese Journal of Scientific Instrument,

2015, 36(1): 1-16.

- [2] 雷津, 邓磊, 李小谦, 等. 基于 EKF 的船舶动力锂电池剩余容量估算[J]. 电子测量技术, 2016, 39(12): 85-88.
LEI J, DENG L, LI X Q, et al. Accurate SOC estimation of the power Li-ion battery based on EKF[J]. Electronic Measurement Technology, 2016, 39(12): 85-88.
- [3] 王文靖, 梁旭, 温菲菲. 无人机机载发电机故障诊断技术研究[J]. 国外电子测量技术, 2016, 35(8): 94-98.
WANG W J, LIANG X, WEN F F. Study on fault diagnosis technology of UAV airborne generators[J]. Foreign Electronic Measurement Technology, 2016, 35(8): 94-98.
- [4] 姚芳, 张楠, 黄凯. 锂离子电池状态估算与寿命预测综述[J]. 电源学报, 2020, 18(3): 175-183.
YAO F, ZHANG N, HUANG K. Review of state estimation and life prediction for lithium-ion batteries[J]. Journal of Power Supply, 2020, 18(3): 175-183.
- [5] 杨战社, 王云浩, 孔晨再. 基于 GWO-SVR 的锂电池剩余使用寿命预测[J/OL]. 电源学报; 1-13[2022-10-19].
YANG ZH SH, WANG Y H, KONG CH Z. Remaining useful life prediction of lithium-ion batteries based on support vector regression optimized and grey wolf optimizations[J/OL]. Journal of Power Supply: 1-13 [2021-10-11].
- [6] 张代华, 张润翔, 毕星海, 等. 基于有监督核自组织映射的锂电池健康状态预测[J]. 南京理工大学学报, 2020, 230(1): 61-66.
ZHANG D H, ZHANG J X, BI X H, et al. Prediction of SOH of lithium batteries based on supervised kernel self-organizing map[J]. Journal of Nanjing University of Science and Technology, 2020, 230(1): 61-66.
- [7] 高小雨. 锂离子电池剩余寿命预测多参数优化方法[D]. 成都: 电子科技大学, 2020.
GAO X Y. Multi parameter optimization method for remaining useful life prediction of lithium ion battery[D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [8] 苏伟, 钟国彬, 沈佳妮, 等. 锂离子电池故障诊断技术进展[J]. 储能科学与技术, 2019, 8(2): 225-236.
SU W, ZHONG G B, SHEN J N, et al. The progress in fault diagnosis techniques for lithium-ion batteries[J]. Energy Storage Science and Technology, 2019, 8(2): 225-236.
- [9] 杨彦茹, 温杰, 史元浩, 等. 基于 CEEMDAN 和 SVR 的锂离子电池剩余使用寿命预测[J]. 电子测量与仪器学报 2020, 34(12): 197-205.

- YANG Y R, WEN J, SHI Y H, et al. Remaining useful life prediction for lithium-ion battery based on CEEMDAN and SVR [J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34(12): 197-205.
- [10] PARK K, CHOI Y, CHOI W J, et al. LSTM-based battery remaining useful life prediction with multi-channel charging profiles [J]. *IEEE Access*, 2020, 8: 20786-20798.
- [11] 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.
- WANG Y K, ZHANG H, WANG X H. A hybrid 1DCNN-LSTM model for predicting lithium ion battery state of health [J]. *Energy Storage Science and Technology*, 2022, 11(1): 240-245.
- [12] 史永胜, 洪元涛, 丁恩松, 等. 基于分层极限学习机的锂离子电池剩余使用寿命预测 [J]. *电子器件*, 2021, 44(3): 652-658.
- SHI Y SH, HONG Y T, DING EN S, et al. The remaining useful life prediction of lithium-ion battery based on hierarchical extreme learning machine [J]. *Chinese Journal of Electron Devices*, 2021, 44(3): 652-658.
- [13] 王宇胜, 陈德旺, 蔡俊鹏, 等. 基于 LSTM-SVR 的锂电池健康状态预测研究 [J]. *电源技术*, 2020, 44(12): 1784-1787.
- WANG Y SH, CHEN D W, CAI J P, et al. Research on lithium battery state of health prediction based on LSTM-SVR [J]. *Chinese Journal of Power Sources*, 2020, 44(12): 1784-1787.
- [14] 韩啸, 张成锟, 吴华龙, 等. 锂离子电池的工作原理与关键材料 [J]. *金属功能材料*, 2021, 28(2): 37-58.
- HAN X, ZHANG CH K, WU H L, et al. Working mechanism and key materials of the lithium ion batteries [J]. *Metallic Functional Materials*, 2021, 28(2): 37-58.
- [15] 李龙刚, 李立伟, 杨玉新, 等. 基于改进灰狼优化与支持向量回归的锂电池健康状态预测 [J]. *南京理工大学学报*, 2020, 231(2): 154-161, 170.
- LI L G, LI L W, YANG Y X, et al. Prediction for state of health of lithium-ion battery by improved grey wolf optimization and support vector regression [J]. *Journal of Nanjing University of Science and Technology*, 2020, 231(2): 154-161, 170.
- [16] 陈赐阳, 陈德旺. 基于 CNN-LSTM 的锂电池剩余寿命 (RUL) 间接预测研究 [J]. *电源技术*, 2021, 45(5): 589-594.
- CHEN C Y, CHEN D W. Research on indirect prediction of lithium battery RUL based on CNN-LSTM [J]. *Chinese Journal of Power Sources*, 2021, 45(5): 589-594.
- [17] 张豹, 刘琼, 吴细宝, 等. 基于集成学习的涡扇发动机剩余寿命预测, 2022, 48(7): 47-52.
- ZHANG B, LIU Q, WU X B, et al. Remaining useful lifetime prediction of turbofan engine based on ensemble learning [J]. *China Measurement & Test*, 2022, 48(7): 47-52.
- [18] FRIEDMAN J H. Greedy function approximation: A gradient boosting machine [J]. *Annals of Statistics*, 2001, 29(5): 1189-1232.
- [19] 奉国和. SVM 分类核函数及参数选择比较 [J]. *计算机工程与应用*, 2011, 47(3): 123-124, 128.
- FENG G H. Parameter optimizing for support vector machines classification [J]. *Computer Engineering and Applications*, 2011, 47(3): 123-124, 128.
- [20] 刘皓, 胡明昕, 朱一亨, 等. 基于遗传算法和支持向量回归的锂电池健康状态预测 [J]. *南京理工大学学报*, 2018, 220(3): 329-334, 351.
- LIU H, HU M X, ZHU Y H, et al. Health status prediction of lithium batteries based on genetic algorithm and support vector regression [J]. *Journal of Nanjing University of Science and Technology*, 2018, 220(3): 329-334, 351.

作者简介



刘琼, 2006 年于国防科技大学获得学士学位, 2012 年于北京航空航天大学获得博士学位, 现为北京信息科技大学副教授, 主要研究方向为模式识别、机器学习、寿命预测。

E-mail: liuqionglq@126.com.

Liu Qiong received her B. Sc. degree from National University of Defense Technology in 2006 and Ph. D. degree from Beihang University in 2012, respectively. Now she is an associate professor in Beijing Information Science and Technology University. Her main research interests include pattern recognition, machine learning and prediction of remaining useful lifetime.



张豹, 2019 年于华北科技学院获得学士学位, 2022 年于北京信息科技大学获得硕士学位, 主要研究方向为深度学习、剩余使用寿命预测。

E-mail: 15732671448@163.com

Zhang Bao received his B. Sc. degree from North China Institute of Science & Technology University in 2019 and received his M. Sc. degree from Beijing Information Science and Technology University in 2022. His main research interests include deep learning and prediction of remaining useful lifetime.