

DOI:10.13232/j.cnki.jnju.2021.04.015

基于新健康因子的锂电池健康状态估计和剩余寿命预测

冯海林, 张 翀*

(西安电子科技大学数学与统计学院, 西安, 710126)

摘 要:容量和内阻是评估锂离子电池健康状态和预测其剩余寿命的重要指标,然而电池容量和内阻难以直接在线测量.通过分析锂离子电池充电过程中电流和电压的变化特征后提取出两种健康因子,并且证明所提因子与电池容量高度相关,进一步建立了用于锂电池容量估计的两因子线性回归模型.在此基础上,通过结合BP(back propagation)神经网络和粒子群优化思想设计锂离子电池健康状态估计算法.考虑到锂电池的健康状态和剩余使用寿命之间存在一定的映射关系,因此再利用所提取的健康因子和其健康状态估计结果设计了锂电池的剩余使用寿命预测算法.实验结果表明,所提取的健康因子能够准确地进行电池容量估计并应用于在线评估锂离子电池的健康状态和预测其剩余使用寿命.

关键词:锂离子电池,健康状态,线性回归模型,剩余使用寿命

中图分类号:TM912,TB115

文献标志码:A

State of health estimation and remaining using life prediction of lithium-ion batteries based on new health indicators

Feng Hailin, Zhang Xuan*

(School of Mathematics and Statistics, Xidian University, Xi'an 710126, China)

Abstract: The capacity and internal resistance are important indicators to estimate the state of health (SOH) and predict remaining useful life (RUL) of lithium-ion batteries. However, the capacity and internal resistance of lithium-ion batteries are difficult to be directly measured online. In this paper, two health indicators are extracted after analyzing the characteristics of charging current and voltage changes during the charging process of lithium-ion batteries. Through analysis, it is concluded that the indicators are highly correlated with the battery capacity, and a two-indicators linear regression model is established to estimate the battery capacity. On this basis, BP neural network and particle swarm optimization are combined to design the SOH estimation algorithm of lithium-ion batteries. Considering that there is a certain mapping relationship between SOH and RUL of lithium batteries, the RUL prediction algorithm of lithium-ion batteries is designed by using the health indicators and the SOH estimation results. The experimental results show that the proposed indicators can accurately estimate the battery capacity and can be applied to online SOH estimation and RUL prediction of lithium-ion batteries.

Key words: lithium-ion batteries, linear regression model, remaining useful life, state of health

锂离子电池因其可循环使用和寿命长等优点,在电动汽车行业中得到大量应用.但是,锂离子电池发生故障可能会造成一些灾难性事故,如

电动汽车电池的爆炸起火等^[1-2],因此有效的电池管理对于监控电池状态以保障其安全使用尤为重要^[3],其中电池的健康状态(state of health,

基金项目:陕西省自然科学基金(2021JZ-19),国家自然科学基金(61877067)

收稿日期:2021-01-03

* 通讯联系人, E-mail: 1227666798@qq.com

SOH)估计和剩余使用寿命(remaining useful life, RUL)预测是电池管理中的核心问题^[4]。

电池的容量和内阻通常被称为直接健康因子,用于电池的SOH估计和RUL预测中,但测量电池的容量和内阻需要昂贵的仪器并且测量过程十分耗时,这就使得在线测量这些数据极为困难^[5-6]。因此近年来,研究者更关注在电压、电流和温度等容易在线监测的参数中寻找出一些新的健康因子替代容量或内阻。在锂电池的放电过程中,Liu et al^[7]通过分析电池放电电压的变化趋势,使用等放电电压差的时间间隔(TIEDVD)作为锂电池的健康因子表征电池健康状态;Yang et al^[8]基于放电温度变化率提取出新的健康因子;Zhou et al^[9]提取出平均电压衰减(MVF)作为健康因子描述电池的退化过程;Widodo et al^[10]基于放电电压样本熵特性来评估电池的健康状态。这些研究结果均基于放电信息获得,但是放电数据存在数据不稳定情况,如电池因使用环境的干扰而测量不够准确,同时实际应用中也很少存在电池电量一次性耗费完的情况^[11]。相比于放电过程,电池的充电过程大多是静态的,受外部因素的影响较小,并且往往是充满电后再使用电池,所以在充电过程中测量的数据会更准确,从充电数据中提取健康因子更符合实际应用。

目前,锂电池的SOH估计和RUL预测大致从基于模型的角度和数据驱动的角度实现^[12]。基于模型的方法通常需要深入了解锂离子电池的电化学机理或构建等效电路来模拟其退化过程,不便于实际应用^[13]。随着人工智能的快速发展,机器学习中的BP(back propagation)神经网络等基于数据驱动的方法被大量应用于电池的SOH估计和RUL预测中^[14]。但是传统的BP神经网络采用的最速下降法会使训练过程陷入局部最优,导致模型的收敛性变差^[15]。

另外值得注意的问题是模型输入的选取和SOH估计与RUL预测之间的关系。Yang et al^[16]利用充电数据提取出四个间接健康因子用于预测模型的输入。与选择循环数作为模型输入相比,这样的做法更加具有广泛的用途和意义,但不足之处是他们只进行了SOH估计而没有考虑到SOH与RUL之间的内在联系。Jia et al^[17]虽然将

SOH和RUL关联起来,但实验中依旧涉及电池容量并且基于放电过程,这使得在线进行SOH估计和RUL预测依旧困难。

为解决上述研究中存在的问题:电池容量在线测量困难、数据不稳定、指标单一和算法收敛性差等,本文从较为稳定的充电过程中提取出两种健康因子,通过相关性分析证明这两种健康因子与容量相关,并基于这些因子建立线性回归模型进行电池容量估计,进一步采用粒子群优化方法(particle swarm optimization, PSO)^[18]对BP神经网络的模型参数进行寻优以此设计锂离子电池SOH估计和RUL预测算法。

本文结构如下:第一部分提取出健康因子并建立线性回归模型,第二部分为PSO-BP神经网络模型下SOH估计和RUL预测算法的设计,第三部分是实验结果及其分析,最后给出结论。

1 健康因子的构建

1.1 实验数据描述 本文采用NASA PCoE提供的电池数据^[19],实验中使用四个18650型号(5, 6, 7, 8号电池)的锂离子电池在24℃室温条件下进行重复充放电循环。其中充电过程分为恒流充电和恒压充电模式:首先电池在1.5 A电流下进行恒流充电,当电池电压到达4.2 V时转为恒压充电,保持恒压模式继续充电,直到电池电流下降至0.2 A时充电结束。电池的放电过程:保持电流2 A不变,当四个电池的电压从4.2 V分别降至2.7, 2.5, 2.2, 2.5 V时放电结束。

1.2 特征提取 锂离子电池的退化与不断进行的充放电循环有关,随着循环次数的增加,电解液与电池正负极的活性材料不断消耗锂离子,从而导致电池表面电荷传递的阻抗增大,电池容量损失,健康状态变差,剩余寿命减少^[20]。通常认为,当锂离子电池的容量从2 Ah下降到1.4 Ah,即下降至自身额定容量的30%时,电池寿命终止^[9,21]。图1为四个锂离子电池的容量退化趋势图。

如前文所述,在实际应用中锂离子电池难以保持恒流状态进行持续放电,而其充电过程为恒流-恒压模式,相对稳定。图2a所示即为5号锂电池在充电过程中的电流变化趋势图,图2b即为充电电流曲线对比图。





图1 电池容量退化曲线图

Fig.1 Capacity degradation curves of batteries

从图2a中可以看出,一个新的锂离子电池在刚开始充电时所需要的恒流充电时间最长,恒压充电时间最短,随着不断地充放电循环,电池容量持续下降,恒流充电时间变得越来越短,恒压充电时间越来越长.并且在其恒压充电过程中,电流在循环初期以较快的速度降至0.2 A,但随着循环数的增加,电流下降速度逐渐放缓.进一步,图2b显示出当电流从1.5 A开始下降时,由于不同循环周期下电流的下降速度不同,经过相同的充电时间 Δt 后所下降的电流值是不相同的.这表



明在恒压充电阶段锂电池电流下降的幅度与容量退化有一定的关系,因此在本文研究中选用电池的额定电流1.5 A与经过 Δt 后得到的电流值的差值作为特征.为解决测量过程中因客观因素造成数据波动所带来的误差影响,实验中在锂电池恒流充电阶段结束,即电流从1.5 A开始下降时,以500 s为时间间隔,分别在500,1000,1500 s时测量充电电流并计算电流差,记其充电电流差及数据序列为:

$$\Delta I_{ij} = 1.5A - I_{ij} \quad i=1,2,3; j=1,2,\dots,n \quad (1)$$

$$\Delta I_i = \{\Delta I_{i1}, \Delta I_{i2}, \dots, \Delta I_{in}\} \quad i=1,2,3; j=1,2,\dots,n \quad (2)$$

式中, ΔI_{ij} 为其充电电流差, ΔI_i 为第*i*个时间间隔下充电电流差的数据序列.*i*=1,2,3分别代表500,1000,1500 s三个时间间隔,*j*为第*j*个循环周期,*n*为总循环周期数,1.5 A为额定电流, I_{ij} 为第*i*个时间间隔在第*j*个周期下对应的电流值.

图3为不同时间间隔下充电电流差与循环周期之间的关系图,可以发现随着充放电循环的增加,充电电流差皆呈下降趋势,这与电池容量退化趋势相似.




图2 充电过程中的(a)充电电流曲线和(b)充电电流曲线对比

Fig.2 (a) Current curves and (b) comparison of current curves during charging

同样,根据实验绘制出如图4a所示的5号电池在充电过程中电压的变化趋势图,可以发现在电池的恒流充电阶段,充电电压在循环初期以较为缓慢的速度上升至4.2 V,但是随着充放电循环的增加,电压上升速度逐渐加快,比前一个周期更快地达到4.2 V.因此再选取如图4b所示的电

压曲线进行分析,当电压从某一定点电压开始上升时,由于不同周期下电压的上升速度有所不同,经过相同充电时间 Δt 后到达的电压是不同的,所以它们与额定电压4.2 V之间的电压差值也是不同的.这一现象反映出在恒流充电阶段锂电池电压变化的幅度与容量退化存在一定联系,因此可




图3 不同时间间隔下的充电电流差

Fig.3 Charging current difference at different time intervals

选取额定电压 4.2 V 与定点电压在相同 Δt 后得到的电压值的差值作为特征. 本文以 3.8 V 为定点电压, 500 s 为时间间隔, 在 500, 1000, 1500 s 时测量充电电压并计算其电压差, 记其充电电压差及数据序列为:

$$\Delta V_{ij} = 4.2V - V_{ij} \quad i = 1, 2, 3; j = 1, 2, \dots, n \quad (3)$$

$$\Delta V_i = \{\Delta V_{i1}, \Delta V_{i2}, \dots, \Delta V_{in}\} \quad i = 1, 2, 3; j = 1, 2, \dots, n \quad (4)$$

式中, ΔV_{ij} 为其充电电压差, ΔV_i 为第 i 个时间间隔下充电电压差的数据序列. $i = 1, 2, 3$ 分别代表 500, 1000, 1500 s 三个时间间隔, j 为第 j 个循环周期, n 为总周期数, 4.2 V 为额定电压值, V_{ij} 为第 i 个时间间隔在第 j 个周期下对应的电压值.

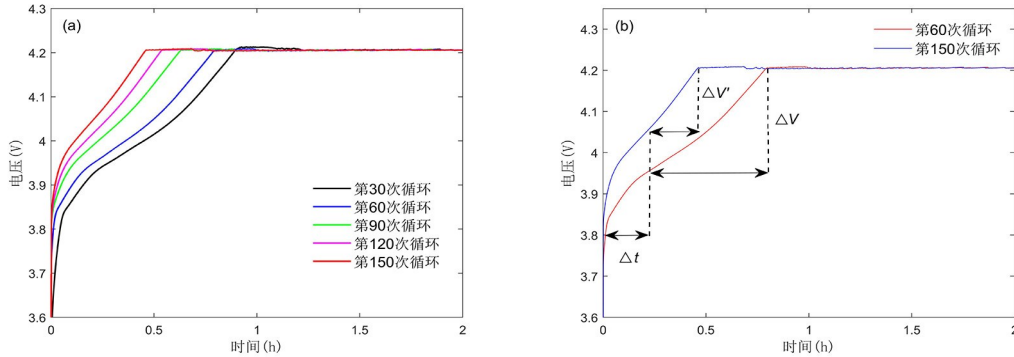


图4 充电过程的(a)电压曲线和(b)电压曲线对比

Fig.4 (a) Voltage curves and (b) comparison of voltage curves during charging

图5为不同时间间隔下充电电压差与循环周期之间的关系图, 结合图3和图5可以发现两组图中的充电电流差和充电电压差皆呈下降趋势且与容量退化趋势相似. 因此为进一步分析所提取特征与容量之间的关系, 接下来对实验数据进行相关性分析.

1.3 相关性分析 为分析不同时间间隔下充电电流差和电压差与电池容量间的相关性, 可以分别计算两者的 Pearson 相关性系数和 Spearman 秩相关系数:

$$r_i = \frac{\sum_{j=1}^n (\Delta I_{ij} - \bar{\Delta I}_i)(C_j - \bar{C})}{\sqrt{\sum_{j=1}^n (\Delta I_{ij} - \bar{\Delta I}_i)^2} \sqrt{\sum_{j=1}^n (C_j - \bar{C})^2}} \quad i = 1, 2, 3 \quad (5)$$

$$\rho_i = 1 - \frac{6 \sum_{j=1}^n d_{ij}^2}{n(n^2 - 1)} \quad i = 1, 2, 3 \quad (6)$$

式中, r_i 为 Pearson 相关性系数, ρ_i 为 Spearman 秩相关系数. $i = 1, 2, 3$ 分别代表 500, 1000, 1500 s 三个时间间隔, j 为第 j 个循环周期, n 为周期数, C_j




图 5 不同时间间隔下的充电电压差

Fig.5 Charging voltage difference at different time intervals

表示电池在第 j 个周期下的实际容量, \bar{C} 为容量平均值, ΔI_{ij} 代表第 i 个时间间隔在第 j 个周期的充电电流差, $\overline{\Delta I_i}$ 为其平均值, d_{ij} 为将 ΔI_{ij} 和电池实际容量 C_j 按照降序排列后所得的位置差. 充电电压差的相关性分析同理, 计算结果如表 1 所示.

表 1 相关性分析结果

Table 1 Results of correlation analysis

ΔI_i	Pearson	Spearman	ΔV_i	Pearson	Spearman
ΔI_1	0.8907	0.9116	ΔV_1	0.9712	0.9621
ΔI_2	0.9440	0.9511	ΔV_2	0.9679	0.9620
ΔI_3	0.9721	0.9777	ΔV_3	0.9799	0.9793

从表 1 中可以发现, 除 ΔI_1 外, 其余充电电流差的相关性系数皆在 0.9 以上且呈正相关. 并且随着时间间隔的增加, 相关性系数越来越接近 1, 即充电过程中电流的下降趋势越来越稳定, 数据间的相关性变得越来越高. 而不同时间间隔下的充电电压差与容量的相关性系数均在 0.95 以上, 这说明其下降趋势一直保持稳定状态, 且具有较高的相关性. 因此, 充电电流差和电压差与容量高度相关, 可以作为描述电池退化状态的健康因子.

1.4 线性回归模型的建立 1.3 的相关性分析表明, 不同时间间隔下的充电电流差和电压差与容量退化高度相关. 因此本文建立以电池容量为因变量, 健康因子电流差和电压差为自变量的线性回归模型:

$$C = A\Delta I + B\Delta V + E + \epsilon \quad (7)$$

式中, C 为电池容量, ΔI 和 ΔV 分别为电流差和电压差, A, B, E 为模型系数, ϵ 为模型误差.

需要说明的是, 在充电过程中每个周期的电

流差和电压差会随时间变化有一定的差异, 并且在图 1 中可以看出, 电池在循环初期以及第 48 和第 90 周期出现容量增生现象, 即随着充放电循环次数的增加, 容量数据会出现较大幅度的波动. 因此, 为使模型 (7) 的参数估计更加准确, 本文将电池容量的退化过程划分为四个阶段. 第一阶段: 初始下降阶段, 选取第 1~47 周期; 第二阶段: 稳定下降阶段, 选取第 48~89 周期; 第三阶段: 性能衰退阶段, 选取第 90~124 周期; 第四阶段: 性能失效阶段, 选取第 125~168 周期. 通过分别使用不同阶段的电流差和电压差数据去估计 (7) 中的模型参数, 使得容量估计更为准确. 现将四个阶段的数据用于模型 (7), 即有:

$$C_t = \sum_{i=1}^3 A_{ti} \Delta I_{ti} + \sum_{i=1}^3 B_{ti} \Delta V_{ti} + E_t + \epsilon \quad (8)$$

$$t = 1, 2, 3, 4$$

式中, t 代表四个不同的阶段, $i = 1, 2, 3$ 分别代表 500, 1000, 1500 s 三个时间间隔, C_t 为不同阶段下的电池实际容量, ΔI_{ti} 为第 t 阶段下不同时间间隔的充电电流差, ΔV_{ti} 为第 t 阶段下不同时间间隔的充电电压差, A_{ti} 和 B_{ti} 分别为四个阶段下的模型系数, E_t 为常数项, ϵ 为误差项.

利用最小二乘法得到的四个阶段模型参数 A_{ti} 、 B_{ti} 和 E_t 的值如表 2 所示. 因此进一步利用模型 (8) 得到电池容量的估计值, 图 6 为锂电池的容量估计曲线图.

本文使用误差平方和 (E_{ts}) 和拟合优度 (R_{ts}) 作为模型误差与拟合程度的评价标准, 即:

$$E_{ts} = \sum_{j=1}^N (C_{tj} - \hat{C}_{tj})^2 \quad t = 1, 2, 3, 4 \quad (9)$$

表2 不同阶段的线性回归模型参数

Table 2 Linear regression model parameters at different stage

阶段	A_{t1}	A_{t2}	A_{t3}	B_{t1}	B_{t2}	B_{t3}	E_t
$t=1$	-0.0745	0.1237	1.3172	1.6714	-2.6411	2.1524	0.3614
$t=2$	0.4942	-0.1468	0.6272	24.3235	-62.5289	33.6344	2.2381
$t=3$	0.5789	0.0406	-1.6221	6.9042	-28.5255	18.6002	4.1719
$t=4$	0.2512	0.1285	0.5030	-2.5241	-5.1970	6.6076	1.4775




图6 线性回归模型拟合曲线图

Fig. 6 Fitting curve of line regression model

$$R_{ts} = 1 - \frac{\sum_{j=1}^N (C_{tj} - \hat{C}_{tj})^2}{\sum_{j=1}^N (C_{tj} - \bar{C}_t)^2} \quad (10)$$

$t=1, 2, 3, 4$

式中, t 代表四个不同的阶段, N 为 t 阶段的样本数量, C_{tj} 为第 t 阶段第 j 个周期下电池的实际容量, \hat{C}_{tj} 为第 t 阶段第 j 个周期下电池的容量估计值, \bar{C}_t 为第 t 阶段下电池实际容量的平均值. 评价结果如表3所示.

表3 线性回归模型评价结果

Table 3 Evaluation results of linear regression model

阶段	E_{ts}	R_{ts}
$t=1$	0.0114	0.7165
$t=2$	0.0123	0.9520
$t=3$	0.0155	0.8168
$t=4$	0.0062	0.8487

图6的拟合曲线图直观显示出通过线性回归模型得到的电池容量估计曲线十分贴近电池容量的实际曲线. 表3的评价结果也表明对于误差平方和 E_{ts} , 数值结果均较小且接近于0. 而在拟合优度 R_{ts} 中, R_{1s} 最小, 这是由于电池在循环初期不断出现容量增生现象, 该现象导致本阶段的拟合效果较差. 在第二阶段由于电池容量稳定下降, 所

以得到的 R_{2s} 最接近1, 线性关系最强. 拟合曲线图和模型评价结果表明电流差和电压差作为健康因子可以直接用于容量估计, 因此可进一步用于锂电池的健康状态估计和剩余寿命预测.

2 SOH估计与RUL预测

通过 PSO-BP 神经网络算法, 结合所提取的健康因子和电池估计容量设计 SOH 估计和 RUL 预测. SOH 作为衡量电池退化程度的重要指标, 通常使用容量比进行定义, 即当前周期的容量与初始周期容量的比值^[22]. 但为解决容量在线测量困难等问题, 实验中通过使用电池的估计容量来替代电池的实际容量, 因此第 j 个周期下的 soh 值可以记为:

$$soh(j) = \frac{\hat{c}(j)}{\hat{c}(1)} \quad (11)$$

式中, $\hat{c}(1)$ 为电池估计容量的初始容量, $\hat{c}(j)$ 为第 j 个周期下电池的估计容量.

由于锂离子电池的 SOH 与其性能密切相关, 而电池的 RUL 能够更直观地反映出电池性能的退化程度, 故 SOH 和 RUL 之间存在着一定的映射关系, 因此可以结合 SOH 信息进行 RUL 预测. 从图1中可以发现, 当锂电池的容量损失达到自身额定容量的30%时, 认为锂电池性能失效, 即5号电池在第124个周期时寿命终止, 为此可以作为 RUL 预测的依据^[21].

2.1 PSO-BP 算法介绍 PSO-BP 算法是指利用 PSO 算法改变 BP 神经网络的权值和阈值, 以达到最优化的目的. 其优化过程: 首先根据数据确定网络结构; 接着利用 PSO 算法对 BP 神经网络结构的参数值进行优化, 得到最优权值和阈值; 最后将所得到的结果赋予网络, 使用 BP 神经网络进行训练与预测.

BP神经网络一般采用输入层、隐含层和输出层三层结构,因此在进行SOH估计时使用健康因子即充电电流差和电压差作为模型的输入,进行RUL预测时使用健康因子和其SOH值作为模型的输入,SOH与RUL分别为两个模型的输出.令 X_m 为模型中输入层的输入变量, Y_n 为模型中输出层的输出值, w_{ij} 和 w_{jk} 分别为输入层到隐含层和隐含层到输出层的连接权值.各层的单元输出之间存在以下对应关系:

$$P_i = \sigma \left(\sum_{j=1}^m W_{ij} X_j + \theta_i \right) \quad j=1,2,\dots,l \quad (12)$$

$$Q_k = \gamma \left(\sum_{j=1}^l W_{jk} P_j + \theta_k \right) \quad k=1,2,\dots,n \quad (13)$$

式中, σ 为隐藏层的激活函数,一般选择logsig函数或tansig函数, γ 为输出层的激活函数,一般选为线性purelin函数.

在设计PSO算法时,对任意一个粒子 i ,记其位置向量为 $e_i = (e_{i1}, e_{i2}, \dots, e_{in})$,速度向量为 $v_i = (v_{i1}, v_{i2}, \dots, v_{in})$,单个粒子经历过的最优解向量为 $l_i = (l_{i1}, l_{i2}, \dots, l_{in})$,种群中所有粒子经历过的最优解向量为 $l_q = (l_{q1}, l_{q2}, \dots, l_{qn})$,迭代关系为:

$$v_{iu}(h+1) = \omega v_{iu}(h) + k_1 p_1 (l_{iu}(h) - e_{iu}(h)) + k_2 p_2 (l_{qu}(h) - e_{iu}(h)) \quad (14)$$

$$e_{iu}(h+1) = e_{iu}(h) + v_{iu}(h+1) \quad (15)$$

式中, ω 代表惯性权重系数, $u=1,2,\dots,n$, n 为空间维数. h 为迭代次数, $i=1,2,\dots,s$, s 为种群的样本数, p_1 和 p_2 为在0和1之间的随机数, k_1 和 k_2 为常数. $v_{iu} \in [-v_{\max}, v_{\max}]$, $e_{iu} \in [-e_{\max}, e_{\max}]$ 通常由实际情况决定,并且一般令 $v_{\max} = ke_{\max}$.

2.2 算法流程 图7为SOH估计和RUL预测的基本流程图,共分为以下四个步骤:

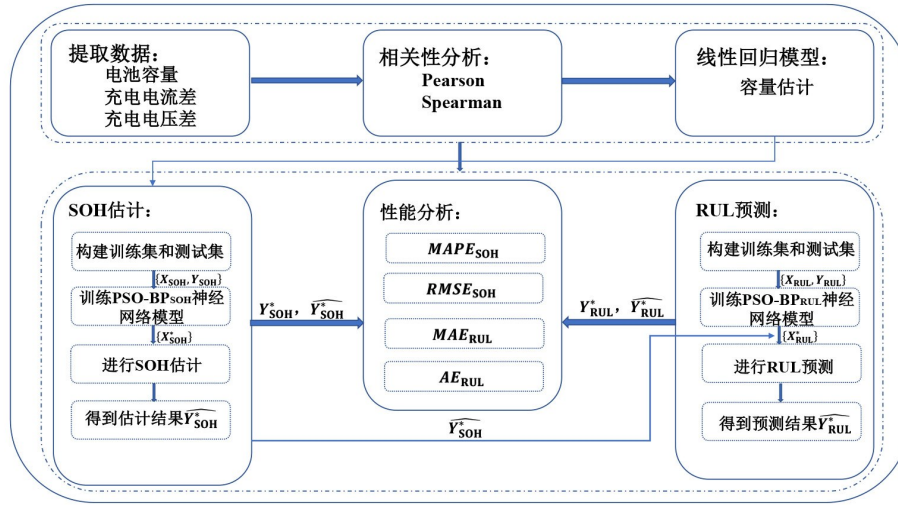


图7 基于PSO-BP神经网络的SOH估计和RUL预测流程

Fig. 7 The process of SOH estimation and RUL prediction based on PSO-BP neural network

Step1. 提取数据并进行预处理

首先按照500,1000,1500 s提取出电流和电压并计算得到电流差和电压差作为健康因子,其次通过线性回归模型得到电池估计容量数据并记为 \hat{C} ,即:

$$\Delta I_i = [\Delta I_i(1), \Delta I_i(2), \dots, \Delta I_i(n)] \quad i=1,2,3 \quad (16)$$

$$\Delta V_i = [\Delta V_i(1), \Delta V_i(2), \dots, \Delta V_i(n)] \quad i=1,2,3 \quad (17)$$

$$\hat{C} = [\hat{c}(1), \hat{c}(2), \dots, \hat{c}(n)] \quad (18)$$

记SOH序列为:

$$SOH = \frac{\hat{c}}{\hat{c}(1)} = [soh(1), soh(2), \dots, soh(n)] \quad (19)$$

式中, $i=1,2,3$ 分别代表500,1000,1500 s三个时间间隔, $\hat{c}(1)$ 为电池估计容量的初始容量, n 为总循环周期数.

Step2. SOH估计

建立训练集 $\{X_{SOH}, Y_{SOH}\}$ 和测试集 $\{X_{SOH}^*, Y_{SOH}^*\}$, 其中前 k 个周期的健康因子构成训练集并记为 X_{SOH} , 其余周期的健康因子构成测试集并记为 X_{SOH}^* . 前 k 个周期的 SOH 构成 Y_{SOH} , 其余周期的 SOH 构成 Y_{SOH}^* . 将训练集 $\{X_{SOH}, Y_{SOH}\}$ 带入 PSO-BP 模型中进行训练, 当训练完成后输入 X_{SOH}^* 进行 SOH 估计, 所有估计值构成估计集 $\widehat{Y_{SOH}^*}$.

Step3. RUL 预测

建立训练集 $\{X_{RUL}, Y_{RUL}\}$ 和测试集 $\{X_{RUL}^*, Y_{RUL}^*\}$, 其中训练集的输入 X_{RUL} 由前 k 个周期的健康因子和其 Y_{SOH} 构成, 测试集 X_{RUL}^* 由其余周期的健康因子与上一步得到的 SOH 估计值 $\widehat{Y_{SOH}^*}$ 构成. 将训练集 $\{X_{RUL}, Y_{RUL}\}$ 带入 PSO-BP 模型中进行训练, 当训练完成后将 X_{RUL}^* 作为输入进行 RUL 预测, 得到的预测值构成预测集 $\widehat{Y_{RUL}^*}$.

Step4. 性能分析

本文对 SOH 估计采用平均绝对百分比误差 (MAPE) 和均方根误差 (RMSE) 作为评价标准, 对 RUL 预测采用平均绝对误差 (MAE) 和绝对误差 (AE) 作为评价标准进行性能分析:

$$MAPE_{SOH} = \frac{100\%}{n-k} \sum_{j=k+1}^n \left| \frac{\widehat{soh}(j) - soh(j)}{soh(j)} \right| \quad (20)$$

$$RMSE_{SOH} = \sqrt{\frac{\sum_{j=k+1}^n (\widehat{soh}(j) - soh(j))^2}{n-k}} \quad (21)$$

$$MAE_{RUL} = \frac{1}{n-k} \sum_{j=k+1}^n |\widehat{rul}(j) - rul(j)| \quad (22)$$

$$AE_{RUL} = |\widehat{rul} - rul| \quad (23)$$

式中, $j = k+1, k+2, \dots, n$, n 为总周期数, k 为加入训练的周期数, $soh(j)$ 和 $\widehat{soh}(j)$ 分别为第 j 个周期下 SOH 的实际值和估计值, $rul(j)$ 和 $\widehat{rul}(j)$ 分别第 j 个周期下 RUL 的实际值和预测值, \widehat{rul} 为预测得到的剩余使用寿命周期数, rul 为实际的剩余使用寿命周期数.

3 实验结果

3.1 SOH 估计 为验证在 PSO-BP 神经网络模型下估计锂离子电池 SOH 的准确性, 本文使用极

限学习机 (Extreme Learning Machine, ELM) 算法^[23]对电池进行 SOH 估计并作为对照. 分别选用前 80 周期和前 100 周期的数据训练模型, 并以第 81 周期和第 101 周期为起点进行估计. 估计结果如图 8 所示:

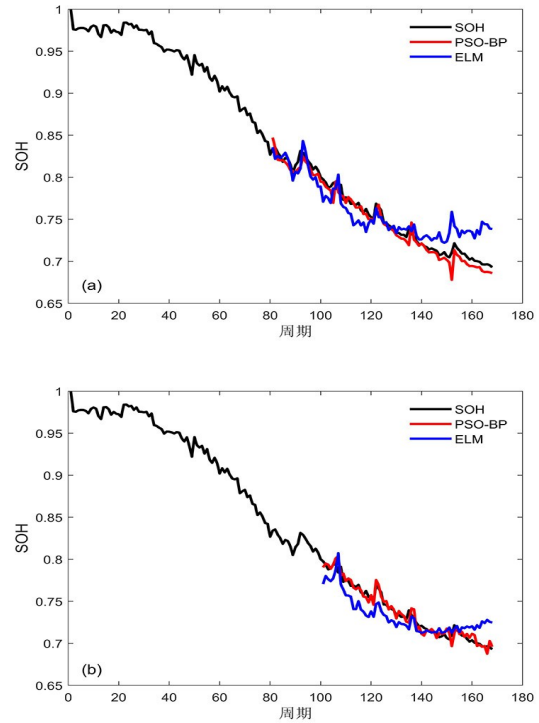


图 8 (a)以第 81 周期为起点和(b)以第 101 周期为起点的 SOH 估计结果图

Fig. 8 SOH estimation result: (a) starting point is 81 and (b) starting point is 101

从图 8 中可以看出, 基于 PSO-BP 模型得到的估计结果明显优于基于 ELM 模型得到的估计结果, 其中基于前者的 SOH 估计值随着锂电池充放电循环的增加, 总体呈现退化趋势, 并且退化趋势与电池实际的 SOH 退化趋势相似; 而基于后者的 SOH 估计虽然也呈现了退化趋势, 但是随着循环周期数的不断增加, 退化趋势曲线与实际曲线相差较为明显, 即其估计效果略差. 而且从图 8 中还可以发现, 随着训练数据的增多, 在基于 PSO-BP 模型下的 SOH 估计中, 以第 101 周期为起点得到的估计曲线明显比以第 81 周期为起点得到的估计曲线更贴近于实际退化曲线. 除此之外, 本文还以第 91 周期和第 111 周期为起点进行了

SOH 估计,表 4 为其 SOH 估计的数值结果.

表 4 显示虽然估计起点不同,但 PSO-BP 模型下的估计误差均小于 ELM 模型下得到的估计误差.其次,在 PSO-BP 模型下,参与训练的数据越多,即估计的起点越晚,误差越小,估计结果也更加准确.因此,所提取的健康因子可以在 PSO-BP 模型下进行较为准确的 SOH 估计.

表 4 SOH 估计的数值结果

Table 4 Numerical results of SOH estimation

算法	起点	MAPE	RMSE
PSO-BP	81	0.8144%	0.0079
	91	0.8042%	0.0080
	101	0.6858%	0.0064
	111	0.4809%	0.0043
ELM	81	2.1231%	0.0198
	91	2.1273%	0.0189
	101	1.9036%	0.0166
	111	1.6253%	0.0140

3.2 RUL 预测 基于 SOH 与 RUL 的关系,本文将健康因子及其 SOH 值作为输入进行模型训练,并且通过加入 SOH 的估计值 \widehat{Y}_{SOH}^* 进行 RUL 预测,RUL 预测结果如图 9 所示.

图 9 为在两个不同预测起点下得到的 RUL 预测结果,以第 81 周期为预测起点明显劣于以第 101 周期为预测起点得到的预测曲线,而且以第 101 周期为起点得到的预测曲线更符合真实的 RUL 下降趋势,呈现出更强的线性关系.此外本文也以第 91 和第 111 周期为预测起点进行了 RUL 预测,表 5 为其数值结果.

从表 5 中可以看出,以第 81 周期为预测起点得到的 AE 值为 6,即电池在第 118 周期时寿命终止.以第 101 周期为预测起点得到的 AE 值为 2,即电池在第 126 周期时寿命终止.表内其他结果也显示出随着训练数据的增多,得到的 RUL 预测结果越来越接近实际的 RUL 结果.除此之外,MAE 也随着训练数据的增加而不断减小.因此,通过上述分析可以发现基于 PSO-BP 神经网络模型得到的 RUL 预测结果与实际结果相差不大,这就证明所提取的健康因子和其 SOH 值在该模型下可以进行较为准确的 RUL 预测,且该模型具有较高的预测精度.




图 9 (a)以第 81 周期为起点和(b)以第 101 周期为起点的 RUL 预测结果图

Fig. 9 RUL prediction result: (a) starting point is 81, and (b) starting point is 101

表 5 RUL 预测的数值结果

Table 5 Numerical results of RUL prediction

算法	起点	实际 RUL	预测 RUL	MAE	AE
PSO-BP	81	43	37	5.7831	6
	91	33	36	5.3150	3
	101	23	25	5.2546	2
	111	13	14	4.3498	1

4 结 论

针对锂离子电池容量在线测量困难等问题,本文首先从相对稳定的充电过程中提取出不同时间间隔的充电电流和电压并计算出相应的电流差和电压差,经过相关性分析证明它们与容量高度相关,可以作为替代容量的健康因子.其次建立线性回归模型实现电池的容量估计,并根据所提取的健康因子与电池估计容量设计出一种基于 PSO-BP 神经网络模型的 SOH 估计算法,最后根

据健康因子和上一步得到的 SOH 数据设计出 RUL 预测算法。另外,本文使用两种因子进行建模和预测,弥补了单一因子建模的信息不完整性,也提高了预测精度。实验结果表明:所提取的健康因子可以用来描述锂离子电池的退化过程并进行容量估计,且在 SOH 估计和 RUL 预测方面表现良好,在一定程度上解决了电池容量在线测量困难的问题,具有良好的应用前景。

参考文献

- [1] Zhao Q, Qin X L, Zhao H B, et al. A novel prediction method based on the support vector regression for the remaining useful life of lithium - ion batteries. *Microelectronics & Reliability*, 2018(85):99—108.
- [2] Wang Q S, Mao B B, Stolarov S I, et al. A review of lithium ion battery failure mechanisms and fire prevention strategies. *Progress in Energy and Combustion Science*, 2019(73):95—131.
- [3] Xing Y, Ma E W M, Tsui K L, et al. Battery Management Systems in Electric and Hybrid Vehicles. *Energies*, 2011, 4(12):1840—1857.
- [4] 彭宇,刘大同,彭喜元.故障预测与健康技术综述. *电子测量与仪器学报*, 2010, 24(1):1—9. (Peng Y, Liu D T, Peng X Y. A review: Prognostics and health management. *Journal of Electronic Measurement and Instrument*, 2010, 24(1):1—9.)
- [5] Wei J W, Dong G Z, Chen Z H. Remaining useful life prediction and state of health diagnosis for lithium-ion batteries using particle filter and support vector regression. *IEEE Transactions on Industrial Electronics*, 2018, 65(7):5634—5643.
- [6] Lei Y G, Li N P, Guo L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*, 2018(104):799—834.
- [7] Liu D T, Wang H, Peng Y, et al. Satellite lithium-ion battery remaining cycle life prediction with novel indirect health indicator extraction. *Energies*, 2013, 6(8):3654—3668.
- [8] Yang L, Zhao L L, Su X H, et al. A lithium - ion battery RUL prognosis method using temperature changing rate//2016 IEEE International Conference on Prognostics and Health Management. Ottawa, Canada:IEEE Press, 2016:1—7.
- [9] Zhou Y P, Huang M H, Chen Y P, et al. A novel health indicator for on - line lithium - ion batteries remaining useful life prediction. *Journal of Power Sources*, 2016(321):1—10.
- [10] Widodo A, Shim M C, Caesarendra W. Intelligent prognostics for battery health monitoring based on sample entropy. *Expert Systems with Application*, 2011, 38(9):11763—11769.
- [11] 高栋,黄妙华,周亚鹏.基于充电电流数据的锂电池容量估计. *电源技术*, 2018, 42(10):1447—1450, 1580. (Gao D, Huang M H, Zhou Y P. Lithium-ion battery's capacity estimation based on charging current data. *Chinese Journal of Power Sources*, 2018, 42(10):1447—1450, 1580.)
- [12] Kan M S, Tan A C C, Mathew J. A review on prognostic techniques for non - stationary and non-linear rotating systems. *Mechanical Systems & Signal Processing*, 2015(62—63):1—20.
- [13] Jin X, Vora A, Hoshing V, et al. Physically - based reduced-order capacity loss model for graphite anodes in Li - ion battery cells. *Journal of Power Sources*, 2017(342):750—761.
- [14] Guo Y F, Zhao Z S, Huang L M. SoC Estimation of lithium battery based on improved BP neural network. *Energy Procedia*, 2017(105):4153—4158.
- [15] Geng P, Wang J Z, Xu X Y, et al. SOC Prediction of power lithium battery using BP neural network theory based on keras. *International Core Journal of Engineering*, 2020, 6(1):171—181.
- [16] Yang D, Zhang X, Pan R, et al. A novel Gaussian process regression model for state - of - health estimation of lithium - ion battery using charging curve. *Journal of Power Sources*, 2018(384):387—395.
- [17] Jia J F, Liang J Y, Shi Y H, et al. SOH and RUL prediction of lithium-ion batteries based on Gaussian process regression with indirect health indicators. *Energies*, 2020, 13(2):387—395.
- [18] Ebrahimzade H, Khayati G R, Schaffie M. PSO - ANN-based prediction of cobalt leaching rate from waste lithium - ion batteries. *Journal of Material Cycles and Waste Management*, 2020, 22(1):228—239.
- [19] Saha B, Goebel K, Poll S, et al. Prognostics methods for battery health monitoring using a Bayesian

- framework. IEEE Transactions on Instrumentation and Measurement, 2009, 58(2): 291—296.
- [20] Sun Y Q, Hao X L, Pecht M, et al. Remaining useful life prediction for lithium-ion batteries based on an integrated health indicator. Microelectronics & Reliability, 2018(88—90): 1189—1194.
- [21] Yu J B. State of health prediction of lithium-ion batteries: Multiscale logic regression and Gaussian process regression ensemble. Reliability Engineering & System Safety, 2018(174): 82—95.
- [22] Wu J, Wang Y J, Zhang X, et al. A novel state of health estimation method of Li-ion battery using group method of data handling. Journal of Power Sources, 2016(327): 457—464.
- [23] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications. Neurocomputing, 2006, 70(1—3): 489—501.

(责任编辑 杨 贞)