# 基于等幅度充电时间的锂离子电池 健康状态估计

## 林甜甜,陈自强,刘健

(上海交通大学 海洋工程国家重点实验室,高新船舶与深海开发装备协同创新中心,上海 200240)

摘要:目的 提出一种基于健康因子的 SOH 估计方法,以准确估计锂离子电池的健康状态。方法 选取锂离 子电池恒流充电过程中两恒定压差下的时间间隔作为健康因子,基于健康因子估计电池的健康状态。采用 高斯过程回归模型进行电池健康状态估计,通过共轭参数法优化超参数。健康因子作为模型输入,输出相 应的电池健康状态,并选取 NASA 不同实验条件下 6 个电池的实验数据验证该算法。结果 所选 6 个电池估 计结果的 MAPE 与 RMSE 值均低于 0.02。结论 选取的健康因子可以较好地表征电池的健康状态,验证了 基于健康因子的 SOH 估计方法的可行性。该方法可以对不同温度、放电倍率、放电深度下的电池进行准确 的 SOH 估计,具有较强的适用性。 关键词:锂离子电池;健康状态估计;高斯过程回归;健康因子 DOI: 10.7643/issn.1672-9242.2018.12.012

中图分类号: TM912 文献标识码: A

文章编号: 1672-9242(2018)12-0065-05

## Health State Estimation of Lithium-Ion Battery Based on Equal Time Interval Charging

LIN Tian-tian, CHEN Zi-qiang, LIU Jian

(Collaborative Innovation Center for Advanced Ship and Deep-Sea Exploration, Key Laboratory of Ocean Engineering of Shanghai Jiao Tong University, Shanghai 200240, China)

**ABSTRACT: Objective** To put forward a kind of SOH estimation method based on the health factors, to accurately estimate the health status of lithium ion batteries. **Methods** The time interval between two constant voltages during the constant current charging process was selected as the health indicator to estimate SOH. The Gaussian process regression method was used to estimate SOH. The hyper-parameter was optimized by the conjugate gradient method. The health indicator was taken as the input of the model to output the corresponding SOH. The experimental data of six batteries under different experimental conditions from NASA was selected to verify the method. **Results** The MAPE and RMSE values of the estimated results of the 6 batteries selected were all below 0.02. **Conclusions** The health indicator selected can better characterize the SOH of the battery. It verifies the feasibility of the SOH estimation method based on health indicator. The method can accurately estimate the SOH of batteries under different temperatures, discharge rates and depths of discharge, and has strong applicability.

KEY WORDS: lithium-ion battery; state-of-health; Gaussian process regression; health indicator

通讯作者:陈自强(1967-),男,河南人,博士,研究员,主要研究方向为电池系统辨识与故障诊断。

收稿日期: 2018-08-04;修订日期: 2018-09-25

**基金项目:**国家自然科学基金项目(51677119)

作者简介:林甜甜(1993-),女,河南人,博士研究生,主要研究方向为电池健康管理与离散事件系统。

近年来,海洋工程的重要性日益凸显,而锂离子 电池凭借其长寿命、高能量密度等优势在海洋平台不 间断电源(Uninterruptible Power System, UPS)领域 得到了广泛应用。但充放电循环次数、充放电程度、 外部工作环境温度、盐度等严重影响了电池性能,高 温环境下电池性能急剧衰减。准确估计及预测电池的 健康状态(State-of-Health, SOH)可以极大地提高 UPS 的可靠性,对于锂离子电池在海洋平台 UPS 领 域更广泛的应用至关重要。

常用的电池 SOH 估计方法主要有模型法、数据 驱动法、直接放电法等。直接放电法仅适用于实验室 条件,而很难在实际中得到应用。SOH 估计模型法 主要包括电化学模型方法、等效电路方法以及经验模 型方法。模型法容易出现模型适应性差、在线应用能 力差的问题<sup>[1]</sup>。

冯能莲等根据恒流充电阶段电池电压曲线,同时 结合二阶 RC 等效电路模型估计电池 SOH<sup>[2]</sup>。Liaw 等基于大量实验数据,定量分析了内部因素以及外 部因素对容量衰退的影响,得出预测容量衰退的经 验模型<sup>[3]</sup>。Ning 等通过建立电池内部的热力学和动力 学相关方程来进行电池的 SOH 估计<sup>[4]</sup>。Kim 等通过 扩展卡尔曼滤波方法来预测电池的 SOH<sup>[5]</sup>。Weng 等 通过支持向量机来进行电池的 SOH 估计<sup>[6]</sup>。Lin 等利 用概率神经网络来进行锂离子电池的 SOH 估计<sup>[7]</sup>。 Remmlinger 等通过在线估计内阻来估计锂离子电池 的 SOH<sup>[8]</sup>。

文中采用高斯过程回归方法来进行锂离子电池 的 SOH 预测,该方法基于数据驱动,且可以输出均 值以及置信区间,具有不确定表达能力。提取恒流充 电过程中两确定电压差下的时间间隔当作健康因子 (health indicator, HI),通过高斯过程回归预测电池 健康状态,向模型中输入时间间隔,得到相应的 SOH 输出,该方法可以较为精确地估计海洋平台 UPS 中 锂离子电池的健康状态。

## 1 锂离子电池老化试验

文中所用的锂离子电池相关的实验数据来自美国 NASA Ames 公开数据库<sup>[9]</sup>。实验选用额定容量为2 Ah 的 18650 型锂离子电池,实验过程分为充电、放电和阻抗测量三步进行,具体实现过程如下所述。

1)充电过程。1.5 A 恒流充电至截止电压 (4.2 V),之后恒压充电至截止电流 20 mA。

2)放电过程。恒流放电至截止电压。

3)阻抗测试。对 0.1 Hz~5 kHz 的频率范围进行 扫描,计算得到电池阻抗、校准及平滑后的电池阻抗、 电解质电阻与电荷转移电阻的估计。

容量反应出电池的健康状态,文中选用容量来表 征锂离子电池的 SOH, SOH 计算公式<sup>[10]</sup>为:

$$\eta_{\rm SOH} = \frac{C_i}{C_0} \times 100\% \tag{1}$$

式中:  $C_i$ 表示第 i 次循环的电池放电容量;  $C_0$ 表示电池初始容量。

电池老化过程中,内阻不断增大、而容量不断减 小,电池的 SOH 也不断减小。电池的工作环境及工 作状况对电池老化过程的影响不容忽视,过充过放、 大倍率放电、极端温度都会加速电池的老化过程,严 重影响电池的健康状态。

锂离子电池 SOH 估计大多基于室温条件, 但是 赤道附近海域环境温度较高,导致电池温度也较高, 室温条件不再适用,且不同情况下放电深度也有变 化。故文中除选取 24 ℃条件下不同放电深度的两组 电池(B5、B6、B33、B34)的实验数据外,又选取 了 43 ℃条件下的一组电池(B31、B32)的数据,以 验证算法在不同的温度、放电深度条件下的适用性。 文中是在实验室条件下模拟具有热管理功能的电池 管理系统实际运行情况所选取的温度范围,考虑并实 施了恒流充电过程与热管理结合的措施,以消除温度 对 SOH 的影响。各电池的实验条件参数见表 1,其 SOH 随循环次数的变化情况如图 1 所示。可以发现, 不同实验条件下电池性能衰减速度也不相同。锂离子 电池在充放电循环中会存在容量再次增加的现象,导 致电池 SOH 衰减曲线伴随着局部波动,具有明显的 非线性特征。由于实验条件不同,每组电池进行的电 池充放电循环次数不同, B5 与 B6 进行了 168 次充放



_		衣   0个电池的老化头验梦数		
	电池	放电电流/A	温度/℃	放电截止电压/V
	B5	2	24	2.7
	B6	2	24	2.5
	B31	4	43	2.5
	B32	4	43	2.7
	B33	4	24	2.0
	B34	4	24	2.2

冰战大化南水分类

电循环, B31 与 B32 进行了 40 次循环, B33 与 B34 进行了 197 次循环。

## 2 电池 SOH 建模与估计结果

### 2.1 健康因子提取

内部老化机理以及外部使用环境同时影响锂离 子电池的健康状态。在实际应用中,无法轻易获取电 池内阻等参数,可以通过测得的电流、电压、温度等 参数来估计电池的 SOH。

由于在实际应用中很少存在恒流放电的情况,利用该过程来进行电池的 SOH 预测存在很大的困难, 而充电过程大多为恒流过程,受外界环境影响较小, 故选取恒流充电过程来进行电池 SOH 的预测。图 2 显示了 B5 电池不同循环的充电电压变化曲线,可以 发现,随着循环次数的增加,初始充电电压越来越大, 且电池恒流充电持续时间越来越短。实际应用过程 中,充电过程不一定是满充满放的,故选取 3.9~4.2 V 的时间间隔而不是整个恒流充电时间作为健康因子, 如图 3 所示。由于实验温度和放电倍率的影响,B31 和 B32 电压范围取为 4.0~4.2 V。文中所选 6 个电池 的健康因子如图 4 所示,对比图 1 可以发现,所选的 HI 可以较好地表征电池的健康状态。

为了进一步验证所选的健康因子的有效性,基于 Pearson 指数与 Spearman 指数计算了电池 SOH 与健 康因子之间的相关性,计算公式见式(2)。Pearson





指数与 Spearman 指数越接近于 1,两变量之间的相关性越强,关联性越大,反之则越小。所选 6 个电池的计算结果见表 2,除 B31 电池的两个指标低于 0.9 外,其余电池都大于 0.9,接近于 1。表明选取的健康因子可以较好地表征电池的健康状态,验证了基于健康因子的 SOH 预测方法的可行性。

表 2	6个电池的	Pearson	和 Spearman	结果

电池	Pearson	Spearman
B5	0.993 116	0.990 922
B6	0.985 163	0.991 107
B31	0.837 547	0.831 332
B32	0.923 906	0.920 263
B33	0.946 496	0.950 324
B34	0.944 424	0.954 509

$$\begin{cases} r_{\rm p} = \frac{E(xy) - E(x)E(y)}{\sqrt{E(x^2) - E(y^2)}\sqrt{E(y^2) - E^2(y)}} \\ r_{\rm s} = \frac{\sum_i (x_i - \overline{x})(y_i - \overline{y})}{\sqrt{\sum_i (x_i - \overline{x})^2}\sqrt{\sum_i (y_i - \overline{y})^2}} \end{cases}$$
(2)

### 2.2 高斯过程回归

考虑噪声影响,讨论以下回归问题:

 $y = f(x) + \varepsilon \tag{3}$ 

式中:  $\varepsilon$  为高斯白噪声,满足  $\varepsilon$ ~  $N(0, \sigma_n^2)$ ; y为 观测值; f(x) 为函数值。

得到 y 的先验分布为:

$$y \sim N\left(0, \boldsymbol{K}(x, x) + \sigma_n^2 \boldsymbol{I}_n\right) \tag{4}$$

式中: y 为观测值向量,  $y = [y_1, y_2, ..., y_n]$ ; x 为 输入向量  $x = [x_1, x_2, ..., x_n]$ ;  $K(x, x) \in n \times n$  阶协方差 矩阵, 且其具有对称正定性, 其每个元素  $k_{ij}$  反应  $x_i$  与  $x_i$ 之间的相关程度。

$$k_{ij} = \sigma_f^2 \exp\left(-\frac{\left(x_i - x_j\right)^2}{2l^2}\right)$$
(5)

式中: $\sigma_f^2$ 为信号的方差;l为方差的尺度。文中 选用共轭梯度法进行超参数 $\theta = [\sigma_n \ \sigma_f \ l]$ 的优 化,其基本思想是通过对对数似然函数求导来求解目 标函数的最大值,见式(6)。

$$\begin{cases} \frac{\partial}{\partial \theta_{i}} \lg p(y | x, \theta) = \\ \frac{1}{2} tr \left\{ \left[ \alpha \alpha^{T} - \left( \mathbf{K}(x, x) + \sigma_{n}^{2} I_{n} \right)^{-1} \frac{\partial \left( \mathbf{K}(x, x) + \sigma_{n}^{2} I_{n} \right)}{\partial \theta_{i}} \right] \right\} \\ \alpha = \left( \mathbf{K}(x, x) + \sigma_{n}^{2} I_{n} \right)^{-1} y \end{cases}$$
(6)

$$\begin{bmatrix} y \\ y^* \end{bmatrix} \sim N \left( 0, \begin{bmatrix} \mathbf{K}(x,x) + \sigma_n^2 I_n & \mathbf{K}(x,x^*) \\ \mathbf{K}(x,x^*)^T & \mathbf{K}(x^*,x^*) \end{bmatrix} \right)$$
(7)  

$$\vec{x} \oplus : \quad y^* \to \mathfrak{M}$$

$$\vec{y} = \begin{bmatrix} y_1^*, y_2^*, \dots, y_n^* \end{bmatrix}$$

$$\vec{m}$$

$$\vec{y} = \begin{bmatrix} y^* \\ x, y, x^* \sim N \\ (\overline{y}^*, \operatorname{cov} \\ (y^*) \end{bmatrix}$$
(8)  

$$\vec{x} \oplus :$$

$$\vec{y}^* = E[y^* | x, y, x^*] = \mathbf{K}(x, x^*)^T [\mathbf{K}(x, x) + \sigma_n^2 I_n]^{-1} y$$

$$y = E[y | x, y, x] = \mathbf{K}(x, x) [\mathbf{K}(x, x) + \partial_n I_n] y$$
  

$$cov(y^*) = \mathbf{K}(x^*, x^*) - \mathbf{K}(x, x^*)^T [\mathbf{K}(x, x) + \sigma_n^2 I_n]^{-1} \mathbf{K}(x, x^*)$$

基于高斯过程回归模型,选定均值核函数与协方 差核函数,并且设定超参数初始值后,以 HI 值为输 入,SOH 值为输出,通过训练 GPR 模型,利用共轭 梯度法优化超参数,得到高斯过程回归-SOH 估计模 型。在线获得 HI 数据并输入模型后,得到电池 SOH 估计均值与方差。当进行第 *k*+1 次充放电循环的电池 SOH 估计时,将 1 至 *k* 次循环的 HI 值与 SOH 值作 为训练数据,得到 SOH 估计模型后,输入第 *k*+1 次 循环的 HI 值,得到相应的 SOH 估计结果,不断重复 该过程直至循环结束。文中从第 11 次充放电循环开 始进行电池 SOH 估计。

以 MAPE 和 RMSE 作为指标,表征 SOH 估计结 果的误差大小以及准确性,计算公式如式(9)所示。 MAPE 和 RMSE 值越小,表明 SOH 估计结果误差越 小,结果越准确。

$$\begin{cases}
MAPE = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \\
RMSE = \sqrt{\frac{\sum_{i=1}^{n} (y_i - \hat{y}_i)^2}{n}}
\end{cases}$$
(9)

#### 2.4 实验结果与讨论

图 5 展示了 B5、B32、B34 电池的 SOH 估计图 与误差,其中灰色区域表示估计结果的 95%置信区间,95%置信区间为:

$$\left[\overline{f}^* - 1.96\sqrt{\operatorname{cov}(f^*)}, \ \overline{f}^* + 1.96\sqrt{\operatorname{cov}(f^*)}\right]$$
(10)

从图 5 中可发现,绝对误差大多小于 0.03, 波动 较小,且估计值均在置信区间内,估计值与真实值吻 合较好。6 个电池估计结果的 MAPE 与 RMSE 见表 3, 可以发现 6 个电池估计结果的 MAPE 与 RMSE 值均 低于 0.02,估计结果准确性高。故文中方法可以对不 同的放电深度、温度条件下海洋平台 UPS 的锂离子 电池进行准确的 SOH 估计,具有较强的适用性。

与其他数据驱动的方法相比,高斯过程回归方法 可以同时输出估计值均值以及置信区间,具有不确定 表达的能力,为电池系统的应用推广提供了理论支 撑,具有较强的实用性。

## 3 结语

文中提取恒流充电过程中相同压差下的时间间 隔作为健康因子,采用高斯过程回归方法,基于健康 因子估计电池 SOH,并验证了该方法的可行性。选 用 3 组 NASA 不同实验条件下的 6 个电池的实验数 据进行验证,估计误差大多小于 0.03,估计结果的 MAPE 和 RMSE 值均低于 0.02。结果表明,该方法



图 5 B5、B32、B34 电池 SOH 估计结果及误差

表 3	6 个电池的	MAPE 和	RMSE	结果
-----	--------	--------	------	----

电池	MAPE	RMSE
B5	0.008	0.0086
B6	0.0151	0.0169
B31	0.0119	0.0155
B32	0.0128	0.0155
B33	0.0148	0.0177
B34	0.0135	0.0117

可以对不同放电深度、温度下海洋平台 UPS 的锂离 子电池进行准确的 SOH 估计,具有较强的适用性。

#### 参考文献:

- REZVANIZANIANI S M, LIU Z, CHEN Y, et al. Review and Recent Advances in Battery Health Monitoring and Prognostics Technologies for Electric Vehicle (EV) Safety and Mobility[J]. Journal of Power Sources, 2014, 256(12): 110-124.
- [2] 冯能莲,陈龙科,汤杰. 锂离子电池健康状态估计方法 [J]. 北京工业大学学报,2016,42(11):1750-1755.
- [3] LIAW B Y, JUNGST R G, NAGASUBRAMANIAN G, et al. Modeling Capacity Fade in Lithium-ion Cells[J]. Journal of Power Sources, 2003, 140(1): 157-161.
- [4] NING G, WHITE R E, POPOV B N. A Generalized Cycle Life Model of Rechargeable Li-ion Batteries[J]. Electrochimica Acta, 2006, 51(10): 2012-2022.
- [5] KIM J, CHO B H. State-of-Charge Estimation and State-of-Health Prediction of a Li-ion Degraded Battery Based on an EKF Combined With a Per-Unit System[J]. IEEE Transactions on Vehicular Technology, 2011, 60(9): 4249-4260.
- [6] WENG C, CUI Y, SUN J, et al. On-board State of Health Monitoring of Lithium-ion Batteries Using Incremental Capacity Analysis with Support Vector Regression[J]. Journal of Power Sources, 2013, 235(4): 36-44.
- [7] LIN H T, LIANG T J, CHEN S M. Estimation of Battery State of Health Using Probabilistic Neural Network[J].
   IEEE Transactions on Industrial Informatics, 2013, 9(2): 679-685.
- [8] REMMLINGER J, BUCHHOLZ M, MEILER M, et al. State-of-health Monitoring of Lithium-ion Batteries in Electric Vehicles by On-board Internal Resistance Estimation[J]. Journal of Power Sources, 2011, 196(12): 5357-5363.
- [9] SAHA B, GOEBEL K. "Battery Data Set", NASA Ames Prognostics Data Repository[R]. Moffett Field, CA: NASA Ames Research Center, 2007.
- [10] OKOSHI T, YAMADA K, HIRASAWA T, et al. Battery Condition Monitoring (BCM) Technologies about Lead-acid Batteries[J]. Journal of Power Sources, 2006, 158(2): 874-878.