

DOI: 10.13382/j.jemi.B1902099

基于能量加权高斯过程回归的 锂离子电池健康状态预测*

郑雪莹 邓晓刚 曹玉苹

(中国石油大学(华东)信息与控制工程学院 青岛 266000)

摘要:针对容量再生现象影响锂离子电池健康状态预测(SOH)建模精度的问题,提出一种经验模态分解(EMD)的能量加权高斯过程回归(EWGPR)方法。该方法将容量再生现象看作是锂离子电池容量衰减过程的能量凸现,利用EMD分解获得样本的能量分布情况,根据能量情况计算每个样本的权重,进而建立基于能量加权高斯过程回归的锂离子电池SOH预测模型。基于NASA锂电池数据集的仿真实验结果表明,EWGPR方法比基本GPR算法具有更高的精度和适应性,单步预测和多步预测的均方根误差(RMSE)分别减少了3%和10%。

关键词:高斯过程回归;经验模态分解;容量再生现象;锂离子电池;健康状态

中图分类号: TP206.3; TN081 **文献标识码:** A **国家标准学科分类代码:** 120.30

State of health prediction of lithium-ion batteries based on energy-weighted Gaussian process regression

Zheng Xueying Deng Xiaogang Cao Yuping

(College of Information and Control Engineering, China University of Petroleum (East China), Qingdao 266000, China)

Abstract: Aiming at the problem that the capacity regeneration phenomenon affects the state of health (SOH) prediction accuracy of lithium-ion batteries, an energy-weighted Gaussian process regression (EWGPR) of empirical mode decomposition (EMD) method is proposed. This method regards the capacity recovery phenomenon as the energy projection of the capacity decay process of lithium-ion battery. The energy distribution is obtained by EMD decomposition and the sample weights are calculated according to the energy distributions. Then the SOH prediction model of lithium-ion battery based on EWGPR is established. The experimental simulation results on the NASA lithium-ion battery datasets show that the EWGPR algorithm has higher accuracy and adaptability than the basic GPR algorithm, and the root mean square error (RMES) for single-step and multi-step predictions are decreased by more than 3% and 10%, respectively.

Keywords: Gaussian process regression; empirical mode decomposition; capacity recovery phenomena; lithium-ion battery; state of health

0 引言

锂离子电池以其单体电压高,循环寿命长,能量密度大等优点广泛应用于电动汽车,通信储能基站等领域,并逐渐扩展至航空、航天等军事领域^[1]。作为各类系统的核心部件,电池故障可能会导致用电设备性能下降或完全失效,产生巨大的危害。因此,配置智能、高

效的电池管理系统(battery management system, BMS)对监控电池的安全性、可靠性和可用性尤为重要^[2]。其中,锂离子电池健康预测问题是BMS的关键,主要包括充电状态^[3](state of charge, SOC),健康状态^[4](state of health, SOH),和剩余寿命(remaining useful life, RUL)^[5]。健康状态预测(SOH)在锂离子的运行过程中起到至关重要的作用,用于定量测量锂离子电池系统储存和输送能量的能力,以跟踪电池的劣化趋势,近

收稿日期: 2019-04-04 Received Date: 2019-04-04

*基金项目: 国家自然科学基金(61403418, 21606256)、中央高校基本科研业务费专项资金(17CX02054)、山东省重点研发计划(2018GGX101025)、山东省自然科学基金(ZR2016FQ21, ZR2016BQ14)资助项目

些年成为人们关注的重点。

锂离子电池的 SOH 预测主要分为基于模型的方法和基于数据驱动的方法^[6]。基于模型的方法需要大量的先验知识来描述系统的退化过程和故障模式。文献[7]提出基于电池等效电路模型修正参数并利用 EKF 预测锂离子电池 SOH。文献[8]提出基于量子粒子群优化(QPSO)的粒子滤波器(PF)的锂离子电池 SOH 和 RUL 预测方法。而基于数据驱动的方法直接从电池性能测试数据中挖掘隐含的电池健康状态信息及其演变规律,实现电池健康预测。在一定程度上,克服了基于模型方法需要精确的物理模型、适应性较差及动态精度较差的问题。文献[9]提出基于多项式核和径向基核函数的新型多核 SVM 方法的锂离子电池 SOH 和 RUL 进行预测。文献[10]提出基于多隐态非线性漂移布朗运动的锂离子电池剩余寿命和 SOH 预测方法。

高斯过程(Gaussian process, GP)作为一种非参数概率模型,已经成为重要的数据驱动方法之一,它相对于神经网络和支持向量机的优点在于既能给出模型的响应输出,又能给出输出的不确定度。高斯回归方法已被用于锂离子电池的 SOH 和 RUL 中。文献[11]提出基本高斯过程回归(GPR)的锂离子电池 SOH 预测,但强调了系统地选择正确的内核函数和使用复合内核函数的优势的重要性。文献[12]提出用高斯过程辨别模型参数,用粒子滤波预测粒子电池剩余寿命。文献[13]提出增量容量分析提取峰值和位置作为 GPR 输入预测锂离子电池 SOH。

然而,上述 GPR 模型的缺点是没有考虑到电池容量信号中的容量再生现象,从而影响退化建模过程,降低预测器的性能。已有一些文献在锂离子电池的预测中考虑容量再生现象,并取得一定的效果。文献[14]考虑容量再生现象引起退化过程速率和状态的变化,提出基于多阶段维纳过程的锂离子电池退化模型。文献[15]提出利用双态半马尔可夫模型建立考虑容量在生现象的切换衰减模型。文献[16]实现了基于粒子滤波的预测模型,该模型包括容量再生现象的统计特性和基于 PF 的在线监测模块。因此,将容量再生现象考虑到锂离子电池的健康状态预测和剩余寿命预测过程中尤为重要。

针对传统高斯过程回归模型未考虑容量再生现象影响锂离子电池退化建模效果的问题,本文提出一种基于能量加权高斯过程回归的健康状态预测方法。具有容量再生现象的样本是锂离子电池退化过程中的能量凸显,利用经验模态分解(empirical mode decomposition, EMD)对数据进行能量分解,计算权重,为每一个样本赋予不同的权重,来减小容量再生现象对退化建模的影响。实验结果验证了该方法在电池健康预测中的可行性和有效性。

1 问题描述

1.1 容量再生现象

锂离子电池的老化是一种非常复杂的现象,电池内部发生电化学反应,从而导致电池容量损失和阻抗增加。其中,石墨阳极和阴极材料的结构组成变化、电解质的分解、固体电解质膜(solid electrolyte interphase, SEI)生成和持续增加,是大多数锂离子电池老化衰减的原因^[17]。

容量再生现象,又称容量自恢复现象,表现为电池容量在衰减过程中突然呈现恢复的现象,如图 1 所示。锂离子电池内部发生电化学反应,在使用过程中呈现出容量衰减趋势。然而,当电池在充电和放电期间存在休息过程时,反应物可能会消失,电荷出现再分配现象^[18]。因此,可能会出现现在衰减过程中,电化学性能相比前一循环周期恢复的现象。




图 1 锂离子电池容量再生现象

Fig. 1 Capacity recovery phenomena of lithium-ion battery

1.2 SOH 预测

SOH 用来描述电池的健康状态,反映电池当前的额定容量,即为当前额定容量和初始额定容量的比值,表示为:

$$SOH = \frac{C_t}{C_0} \times 100\% \quad (1)$$

式中: C_t 为第 t 个周期的容量; C_0 为初始容量。除了电池额定容量之外,电池内阻、循环次数等参数也可以用来作为 SOH 的表征参数。

给定 SOH 的历史观察值 y_1, y_2, \dots, y_n 和对应的循环周期 $1, 2, \dots, n$, 则 SOH 的未来 h 步预测 \hat{y}_{n+h} :

$$\hat{y}_{n+h} = \varphi(\hat{y}_{n+h-1}, \hat{y}_{n+h-2}, \dots, \hat{y}_{n+h-d}) \quad (2)$$

式中: d 为历史数据的个数。

对于多步提前预测,递归方法是最直观、简单的方法。在这种方法下,它重复执行多步预测,直到达到所需

的范围。随着预测步骤的进行,多步预测通常会受到累积误差和不确定性增加的影响,特别是局部的再生容量现象。

由于局部容量再生现象干扰锂离子电池的真实退化趋势,SOH 时间序列的直接建模可能会受到锂电池不正常退化趋势的影响,导致退化模型建立失败,预测误差增大。因此,在退化建模过程中考虑这种由化学反应突变所产生的异方差现象的影响尤为重要。

2 基于能量加权高斯过程回归方法

考虑锂离子电池的容量再生问题,本文提出基于能量加权高斯过程回归的锂离子电池健康状态预测。首先利用 EMD 方法对当前 SOH 数据进行分解,得到每一循环时刻所对应的能量,根据每一时刻的能量不同对每一时刻的数据进行加权。最后利用加权后的数据进行高斯过程回归的模型训练,在进行 SOH 的未来多步预测,如图 2 所示。




图 2 锂离子电池 SOH 预测框架

Fig. 2 The framework for SOH prediction of lithium-ion battery

2.1 EMD

EMD 是用于非线性和非平稳信号的时频工具,可以自适应地表示信号的局部特征,本质是将信号分解为不同振动函数或趋势,振动函数也称为固有模态函数 (intrinsic mode function, IMF), IMF 分量必须满足以下两个条件:1) 其极点数和零点数相同 (或最多相差一个); 2) 是其上下包络线关于时间轴局部对称。

本文,假设 SOH 信号的局部再生现象具有高频率,即高能量,而全局退化趋势在 SOH 的低频信号中,即低能量。对于给定 SOH 历史观察值 y_i , 其中 $i = 1, \dots, n$, 定义为信号 y 的能量分解,步骤如下。

1) 确定信号 y 的所有局部极值点,将所有极大值点用三次样条线连接起来形成上包络线,将所有极小值点用三次样条线连接起来形成下包络线。

2) 求出两条包络线的均值 μ_1 , 得到:

$$s_1 = y - \mu_1 \quad (3)$$

3) 判断 s_1 是否满足 IMF 条件,若不满足,则将 s_1 作为原始数据,重复步骤 1)~2), 直到 s_1 满足 IMF 条件,并记 $s_1 = p_1$ 为信号 y 的第 1 个 IMF 分量,它代表信号 y 中最

高频率的分量。

4) 将 p_1 从 y 中分离出来,得到一个去掉高频分量的差值信号 r_1 , 则有:

$$r_1 = y - p_1 \quad (4)$$

将 r_1 作为原始数据,重复步骤 1)~3), 得到第 2 个 IMF 分量 p_2 , 重复 m 次,得到 m 个 IMF 分量。则有:

$$\begin{cases} r_1 - p_2 = r_2 \\ \vdots \\ r_{m-1} - p_m = r_m \end{cases} \quad (5)$$

当 p_m 或 r_m 满足给定的终止条件 (例如使 r_m 成为一个单调函数) 时,循环结束,可以得到:

$$y = \sum_{j=1}^m p_j + r_m \quad (6)$$

式中 r_m 为残余函数,代表信号的平均趋势。而各 IMF 分量 p_1, p_2, \dots, p_m 分别包含了信号从高到低不同频率段的成分。对于每一个时刻的 SOH 可以表示为:

$$y_i = \sum_{j=1}^m p_j(i) + r_m(i) \quad (7)$$

式中: $p_j(i)$ 为第 j 个 IMF 分量的第 i 个时刻值; $r_m(i)$ 为 r_m 的第 i 个时刻值。

由 EMD 分解得到的 IMF 分量代表了 SOH 衰减过程的能量不同,则利用 IMF 计算权重

$$w_i = e^{-\sum_{j=1}^m p_j(i)/g} \quad (8)$$

其中, w_i 为 i 时刻的权重, g 为权重参数。

2.2 加权高斯过程回归

在传统数据建模当中,默认所有的数据都有相同分布的噪声,忽略数据测量误差以及内部化学反应突变所产生的异方差现象的影响。本文提出加权高斯过程回归的方法,对每个样本赋予不同的权重,来减小由异方差性引起的模型偏差的影响。

定义训练样本 $D = \{(x_i, y_i)\}$, 其中 $i = 1, \dots, n$ 为样本个数, x_i 为输入数据,即充放电循环次数, y_i 为模型输出,即锂离子电池 SOH。对每个样本赋予不同的权重,则第 i 个样本的权重为 w_i , 计算出的权重则权重矩阵 φ 为 n 阶对角矩阵:

$$\varphi = \begin{bmatrix} w_1 & 0 & \cdots & 0 \\ 0 & w_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & w_n \end{bmatrix} \quad (9)$$

高斯过程是一个随机变量的集合,集合中任意有限个随机变量都服从联合高斯分布。加权高斯过程可以从权重空间和函数空间的角度来验证模型的有效性,本文从函数空间进行推导。对于基本高斯过程回归预测模型为:

$$y_i = f(x_i) + \epsilon_i \quad (10)$$

式中: f 为非线性映射; $\varepsilon_i \sim N(0, \sigma_n^2)$ 为独立同分布的高斯噪声。

考虑权重的加权高斯过程数学模型为:

$$w_i y_i = w_i f(x_i) + \varepsilon_i \quad (11)$$

也可表示为:

$$y_i = f(x_i) + \varepsilon_i / w_i \quad (12)$$

将高斯过程视为有关函数的分布,用均值函数 $m(x)$ 和协方差函数 $K(x, x^T)$ 进行定义,其中:

$$m(x) = E[f(x)] \quad (13)$$

$$K(x, x^T) = E[(f(x) - m(x))(f(x^T) - m(x^T))]$$

假设 \mathbf{X} 为 n 个输入数据 x_i 组成的输入向量, \mathbf{y} 为 \mathbf{X} 对应的输出向量。通常假设均值函数为 $0^{[19]}$, 则 \mathbf{y} 的先验分布为:

$$\mathbf{y} \sim N(\mathbf{0}, K(\mathbf{X}, \mathbf{X}) + \varphi^{-2} \sigma_n^2 \mathbf{I}) \quad (15)$$

可得到训练样本输出值 \mathbf{y} 和估计值 f^* 的联合概率分布为:

$$\begin{bmatrix} \mathbf{y} \\ f^* \end{bmatrix} \sim N \left[\begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \begin{bmatrix} K(\mathbf{X}, \mathbf{X}) + \varphi^{-2} \sigma_n^2 \mathbf{I} & K(\mathbf{X}, x^*) \\ K(x^*, \mathbf{X}) & K(x^*, x^*) \end{bmatrix} \right] \quad (16)$$

其中, $K(\mathbf{X}, x^*)$ 、 $K(\mathbf{X}, x^*)$ 和 $K(x^*, x^*)$ 表示各个样本之间的协方差矩阵。

上述推导结果可以得到预测分布为:

$$P(f^* | \mathbf{X}, \mathbf{y}, x^*) = N(\tilde{\mu}, \tilde{\Sigma}) \quad (17)$$

$$\tilde{\mu} = K(x^*, \mathbf{X})^T \mathbf{C}^{-1} \mathbf{y} \quad (18)$$

$$\tilde{\Sigma} = K(x^*, x^*) - K(x^*, \mathbf{X}) \mathbf{C}^{-1} K(\mathbf{X}, x^*) \quad (19)$$

其中, $\mathbf{C} = K(\mathbf{X}, \mathbf{X}) + \varphi^{-2} \sigma_n^2 \mathbf{I}$ 。

对锂离子电池 SOH 预测采用平均指数协方差函数:

$$k(x_i, x_j) = \sigma_f^2 \exp\left(-\frac{(x_i - x_j)^2}{2l^2}\right) \quad (20)$$

式中: l 为长度尺度参数; σ_f 为输出规模参数。

高斯过程回归对训练数据集的训练过程即为超参数的学习过程,超参数可通过高斯模型的对数似然函数极大化得到,即:

$$\log p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}) = -\frac{1}{2} \mathbf{y}^T \mathbf{C}^{-1} \mathbf{y} - \frac{1}{2} \log |\mathbf{C}| - \frac{N}{2} \log 2\pi \quad (21)$$

对超参数向量初始化,使用共轭梯度优化方法求解,搜索最优超参数,需要对式(20)求取对超参数矢量 $\boldsymbol{\theta}$ 的偏导数,即:

$$\frac{\partial}{\partial \theta_i} \log p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}) = \frac{1}{2} \mathbf{y}^T \mathbf{C}^{-1} \frac{\partial \mathbf{C}}{\partial \theta_i} \mathbf{C}^{-1} \mathbf{y} - \frac{1}{2} \text{tr} \left(\mathbf{C}^{-1} \frac{\partial \mathbf{C}}{\partial \theta_i} \right) \quad (22)$$

式中: tr 表示矩阵的迹。

3 仿真研究

本文所用的锂离子电池相关实验数据来自美国 NASA PCOE 公开数据库。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 3 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^[20]。在该研究中使用经典的 3 个电池, B5 号电池、B6 号电池、B18 号电池。

该模型的关键是获得加权高斯过程的权重。利用 EMD 将 SOH 时间序列进行分解,得到全局趋势和各 IMF 分量,如图 3 所示。利用各 IMF 分量所表现的能量不同,计算得到相应的权重,从而进行加权高斯过程回归的锂离子电池 SOH 预测。

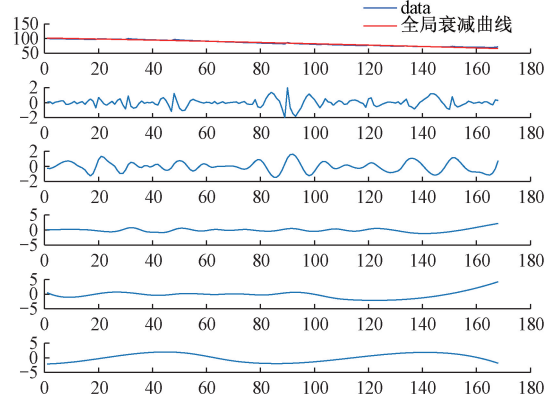


图 3 EMD 分解

Fig. 3 EMD decomposition

3.1 SOH 预测

锂离子电池 SOH 时间序列未来的 1 步预测对于进行 SOC 估计非常重要。而电池 RUL 预测需要在长预测范围内准确估计健康退化状态,需要进一步测试长期预测的效果。因此,对锂离子电池 SOH 预测为从 60 时刻开始的未来 1 步预测和 5 步预测,历史数据个数为 $d = 60$,实验采用零均值函数和 SE 核函数,超参数初始值为 $[l; \sigma_f] = [1; 1]$ 噪声为 $sn = 0.1$,权重参数为 $g = 700$ 。

锂离子电池 SOH 估计结果误差和准确性用均方根误差 (RMSE) 和绝对误差百分比 (MAPE) 来表示。RMSE 计算公式为:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (23)$$

MAPE 计算公式为:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (24)$$

式中: y_i 为真实值; \hat{y}_i 为估计值; n 为样本个数。

B5 号、B6 号、B18 号锂电池的 1 步和 5 步预测结果分别如图 4~6 所示,预测结果的 RMSE 和 MAPE 如表 1 所示。对于锂离子电池 SOH 的 1 步预测来说, B5 号电池预测结果如图 4(a) 所示, EWGPR 方法和 GPR 方法都可以达到很好的跟踪和预测能力,而 EWGPR 方法比 GPR 方法的 RMSE 减少了 12.5%,同时,MAPE 减少了 11.9%,证明了本文所提出的 EWGPR 方法可以达到更加精准的预测效果,减少容量再生现象的影响。同一模型对不同电池的预测能力不同,具有相同充放电循环次数的 B5 号和 B6 号电池两种方法都可以达到同样的跟踪和预测能力,而对于循环次数不同的 B18 电池,整体预测精度下降,但 EWGPR 仍比 GPR 拥有更高的预测精度,具有更强的适应能力。

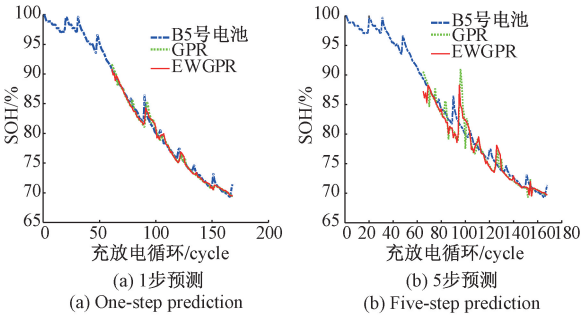


图 4 B5 号电池 SOH 预测

Fig. 4 SOH prediction of B5 battery

表 1 锂离子电池 SOH 预测结果

Table 1 SOH prediction results of lithium ion battery

SOH 预测		RMSE		MAPE	
		GPR	W-GPR	GPR	W-GPR
B5	1 步	0.757 6	0.663 1	0.927 7	0.817 4
	5 步	2.031 6	1.817 6	1.707 8	1.622 3
B6	1 步	0.926 1	0.864 3	1.048 2	0.986 6
	5 步	3.095 0	2.212 6	3.098 5	2.383 6
B18	1 步	1.454 8	1.405 8	1.508 6	1.496 3
	5 步	4.737 5	4.235 3	4.785 7	4.212 4

随着预测步数的增加,EWGPR 方法和 GPR 方法的预测能力都有所降低。对于锂离子电池 SOH 的 5 步预测来说,B6 号电池预测结果如图 5(b) 所示, EWGPR 方法和 GPR 方法都可以达到较好的跟踪和预测能力,而 EWGPR 方法比 GPR 方法的 RMSE 减少了 28.5%,MAPE 减少了 23.1%。由于容量再生现象的影响,GPR 方法在 110 时刻和 111 时刻的预测有明显的预测误差,而 WGPR 方法减少了容量再生现象的影响,具有更加准确的预测结果。对于 B5 号、B18 号电池的 5 步预测,EWGPR 方法

也具有较好的跟踪能力,可以看出 EWGPR 方法比基本 GPR 具有更高的适应性,减少容量再生现象对数据建模的影响,验证了方法的有效性。证明了,本文所提出的基于能量加权高斯过程回归方法能更好的捕捉 SOH 时间序列。

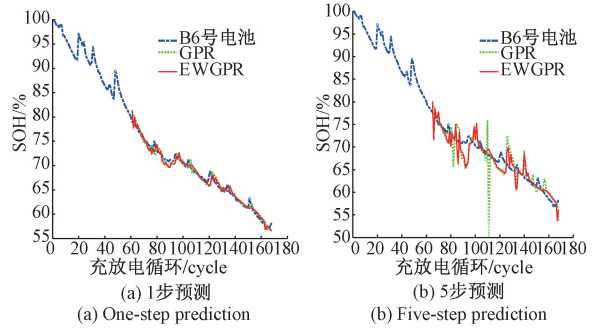


图 5 B6 号电池 SOH 预测

Fig. 5 SOH prediction of B6 battery

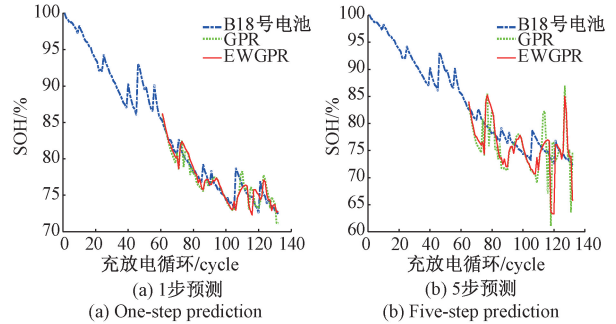


图 6 B18 号电池 SOH 预测

Fig. 6 SOH prediction of B18 battery

3.2 RUL 预测

随着预测步骤的增加,多步预测通常会受到累积误差和不确定性增加的影响,导致预测精度的降低。而电池的 RUL 预测就是要在长期预测范围内准确估计健康退化状态。因此,锂离子电池的剩余寿命预测对模型有更高的要求 and 适应能力。RUL 预测建模时,均值函数选择为 $m(x) = ax + b$, 协方差函数^[21]为:

$$k(x_i, x_j) = \sigma_{f_1}^2 \exp\left(-\frac{(x_i - x_j)^2}{2l_1^2}\right) + \sigma_{f_2}^2 \exp\left(-\frac{2}{l_2^2} \sin^2\left(\frac{w}{2\pi}(x_i - x_j)\right)\right)$$

超参数为 $[a; b; \sigma_{f_1}; l_1; \sigma_{f_2}; l_2; w] = [0, 0, 0.1, 1, 0.2, 1.5]$ 。锂离子的剩余寿命预测包括 95% 的置信区间。

对 B5 号电池进行从 80 时刻、100 时刻开始的剩余寿命预测,如图 7 所示。电池充电容量降至额定容量约 70% 时,为电池的寿命终止时刻,则 B5 号电池的寿命终

止时刻为 127 时刻。从 80 时刻开始的 RUL 预测,如图 7(a)所示。基本 GPR 算法的 RUL 预测为 102 时刻,预测误差为 25 个时刻,而 EWGPR 算法的寿命终止时刻为 125 时刻,预测误差为 2 个时刻。因此,EWGPR 预测结果更加准确,减少了容量再生现象对数据建模的影响。而从 100 时刻开始的 RUL 预测,如图 7(b)所示。基本 GPR 的 RUL 预测为 112 时刻,预测误差为 15 个时刻,而 EWGPR 算法的 RUL 预测为 127 时刻,没有预测误差。EWGPR 方法具有很好的预测能力。而在剩余寿命预测中,越靠近循环终止时刻开始的 RUL 预测精度越高。因此,本文所提出的基于能量加权高斯过程回归的方法比基本的高斯过程回归方法具有更高的预测精度和跟踪能力,减少容量再生现象的影响,验证了模型的有效性。

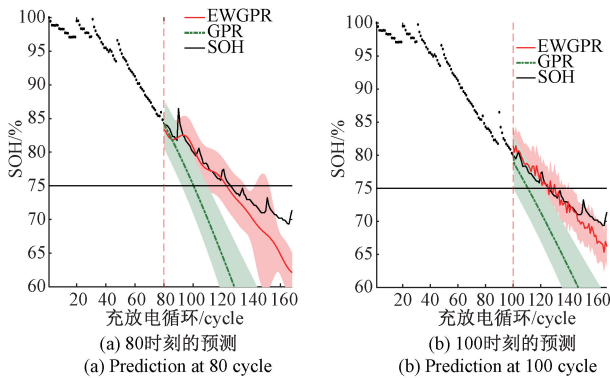


图 7 B5 号电池 RUL 预测结果

Fig. 7 RUL prediction of B5 battery

4 结 论

针对锂离子电池容量再生现象影响建立退化模型的问题,提出了一种基于能量加权高斯过程回归算法,并应用于锂离子电池的健康状态预测。所提出的方法利用 EMD 算法获得模型权值,对每个样本进行加权,再进行高斯过程回归算法的 SOH 预测。实验结果表明,所提出的方法比基本 GPR 方法有更高的预测精度,减少容量再生现象对锂离子电池 SOH 预测的影响。在未来工作中,可以考虑利用其他传感器数据来建立模型,例如各种电压、温度等,实现锂电池 SOH 在线预测方法。

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] 年夫顺. 关于故障预测与健康管理的几点认识[J].

仪器仪表学报, 2018, 39(8): 1-14.

NIAN F SH. Viewpoints about the prognostic and health management [J]. Chinese Journal of Scientific Instrument, 2018, 39(8): 1-14.

[3] 张利,刘帅帅,刘征宇,等. 锂离子电池自适应参数辨识与 SOC 估算研究[J]. 电子测量与仪器学报, 2016, 30(1): 45-51.

ZHANG L, LIU SH SH, LIU ZH Y, et al. Equalization strategy for lithium battery pack based on the state of charge [J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(1): 45-51.

[4] 包塔拉,马剑,甘祖旺. 基于几何特征与流形距离的锂电池健康评估[J]. 山东大学学报(工学版), 2017, 47(5): 157-165.

BAO T L, MA J, GAN Z W, et al. Performance assessment of lithium-ion battery based on geometric features and manifold distance [J]. Journal of Shandong University (Engineering Science), 2017, 47(5): 157-165.

[5] 王竹晴,庞晓琼,黄蕊,等. 基于 KPCA-ANFIS 的锂离子电池 RUL 预测[J]. 电子测量与仪器学报, 2018, 32(10): 26-32.

WANG ZH Q, PANG X Q, HUANG R, et al. KPCA-ANFIS based remaining useful life prediction of lithium-ion battery [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(10): 26-32.

[6] 林娅,陈则王. 锂离子电池剩余寿命预测研究综述[J]. 电子测量技术, 2018, 41(4): 29-35.

LIN Y, CHEN Z W. Review of remaining life prediction for lithium-ion batteries [J]. Electronic Measurement Technology, 2018, 41(4): 29-35.

[7] 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.

[8] YU J, MO B, TANG D, et al. Remaining useful life prediction for lithium-ion batteries using a quantum particle swarm optimization-based particle filter [J]. Quality Engineering, 2017, 29(5): 536-546.

[9] GAO D, HUANG M. Prediction of remaining useful life of lithium-ion battery based on multi-kernel support vector machine with particle swarm optimization [J]. Journal of Power Electronics, 2017, 17(5): 1288-1297.

[10] WANG D, ZHAO Y, YANG F, et al. Nonlinear-drifted brownian motion with multiple hidden states for remaining useful life prediction of rechargeable batteries [J]. Mechanical Systems & Signal Processing, 2017(93):

- 531-544.
- [11] RICHARDSON R, OSBRNE M, HOWEY D. Gaussian process regression for forecasting battery state of health [J]. *Journal of Power Sources*, 2017(357): 209-219.
- [12] LI F, XU J. A new prognostics method for state of health estimation of lithium-ion batteries based on a mixture of gaussian process models and particle filter [J]. *Microelectronics Reliability*, 2015, 55(7): 1035-1045.
- [13] WANG Z, MA J, ZHANG L. State-of-health estimation for Lithium-Ion batteries based on the multi-island genetic algorithm and the gaussian process regression [J]. *IEEE Access*, 2017(5): 21286-21295.
- [14] ZHANG J X, HE X, SI X S, et al. A novel multi-phase stochastic model for Lithium-Ion batteries' degradation with regeneration phenomena [J]. *Energies*, 2017, 10(11): 1687.
- [15] ZHNAG Z X, SI X S, HU C H, et al. A prognostic model for stochastic degrading systems with state recovery: Application to li-ion batteries [J]. *IEEE Transactions on Reliability*, 2017, 66(4): 1293-1308.
- [16] OLIVARES, B E, CERDA M, et al. Particle-filtering-based prognosis framework for energy storage devices with a statistical characterization of State-of-Health regeneration phenomena [J]. *IEEE Transactions on Instrumentation and Measurement*, 2013, 62(2): 364-376.
- [17] NAGPURE S C, Downing R G, BHUSHAN B, et al. Neutron depth profiling technique for studying aging in li-ion batteries [J]. *Electrochimica Acta*, 2011, 56(13): 4735-4743.
- [18] EDDAHECHA, BRIST O, VINASSA J M. Lithium-ion battery performance improvement based on capacity recovery exploitation [J]. *Electrochimica Acta*, 2013(114): 750-757.
- [19] CHEN Z X, WANG B. How priors of initial hyperparameters affect Gaussian process regression models [J]. *Neurocomputing*, 2018(275): 1702-1701.
- [20] LIU D T, ZHOU J B, Pan D W, et al. Lithium-ion battery remaining useful life estimation with an optimized relevance vector machine algorithm with incremental learning [J]. *Measurement*, 2015(63): 143-151.
- [21] LIU D T, PANG J Y, ZHOU J B, et al. Prognostics for state of health estimation of lithium-ion batteries based on combination Gaussian process functional regression [J]. *Microelectronics Reliability*, 2013, 53(6): 832-839.

作者简介



郑雪莹, 2016年于辽宁石油化工大学获得学士学位, 现为中国石油大学(华东)硕士研究生, 主要研究方向为机器学习和工业数据挖掘。

E-mail: zhnegxueying0307@163.com

Zheng Xueying received B. Sc. degree from Liaoning Shihua University in 2016. She is currently a M. Sc. candidate at China University of Petroleum, Qingdao. Her main research interests include machine learning and industrial data mining.