

基于健康特征参数的锂离子电池 SOH 和 RUL 联合估计方法

王萍, 范凌峰, 程泽*

(天津大学电气自动化与信息工程学院, 天津市 南开区 300072)

A Joint State of Health and Remaining Useful Life Estimation Approach for Lithium-ion Batteries Based on Health Factor Parameter

WANG Ping, FAN Lingfeng, CHENG Ze*

(School of Electrical and Information Engineering, Tianjin University, Nankai District, Tianjin 300072, China)

ABSTRACT: Accurate estimation of state of health (SOH) and remaining useful life (RUL) of lithium batteries is crucial to ensure the safe and stable operation of batteries. However, both of them are difficult to be directly measured. A SOH and RUL joint estimation approach based on gaussian process regression (GPR) was proposed in this paper. Health factor (HF) was extracted from the charging curve and indirect health factor (IHF) was obtained through principal component analysis (PCA). Then, an aging battery model based on GPR was established to estimate SOH. Furthermore, the least squares support vector machine (LS-SVM) was used to predict IHF in the future cycles, and the IHF obtained were combined with the established battery aging model to realize RUL estimation. Two battery data sets at different temperatures were utilized to verify the accuracy and adaptability of the algorithm. The results show high accuracy and robustness of the proposed method.

KEY WORDS: lithium-ion battery; state of health; remaining useful life; principle component analysis; Gaussian process regression; least squares support vector machine

摘要: 锂电池健康状态(state of health, SOH)和剩余使用寿命(remaining useful life, RUL)的准确估计对保证电池的安全稳定运行至关重要,然而两者都难以被直接测量。该文提出一种基于高斯过程回归(gaussian process regression, GPR)的SOH和RUL联合估计方法。该方法从充电曲线中提取健康特征(health factor, HF),并通过主成分分析(principle component analysis, PCA)进行降维处理得到间接健康特征(indirect health factor, IHF),然后利用GPR建立电池老化

模型进行SOH估计。在此基础上,采用最小二乘支持向量机(least squares support vector machine, LS-SVM)对IHF随循环次数增加的变化趋势进行预测,将其结果与所建立的电池老化模型结合,实现RUL估计。2组不同温度下的电池数据被用来验证算法的准确性和适应性,实验结果表明所提出的算法具有较高的精度和可靠性。

关键词: 锂离子电池; 电池健康状态; 剩余使用寿命; 主成分分析; 高斯过程回归; 最小二乘支持向量机

0 引言

随着全球科技的不断进步,能源和环境危机日益加剧。锂电池作为一种清洁能源,以其输出电压高,寿命长,能量密度高等优点,被广泛应用于多个领域^[1]。但是电池自身老化和操作不当会导致性能下降,从而易出现漏液和部分短路等问题,甚至会引起灾难性的事故^[2-3]。电池管理系统(battery management system, BMS)可以对电池状态进行评估,给出风险预警,并执行维护或更换工作,可保证电池的长期稳定运行^[4-5]。其中,准确的电池状态估计是BMS的关键环节。电池健康状态(state of health, SOH)和剩余寿命(remaining useful life, RUL)都是表征电池老化程度的重要指标^[6]。SOH一般表示为电池当前可用最大容量与初始容量之间的比值^[7]。RUL定义为电池从当前状态衰减至寿命终止(end of life, EOL)所需的循环次数, EOL可以根据实际应用情况进行选取,通常设置为电池SOH降为80%时刻^[8]。

锂电池老化的影响因素可分为外部因素和内部因素。外部因素包括电池的运行环境和运行模

基金项目: 国家自然科学基金项目(61873180)。

Project Supported by National Natural Science Foundation of China (61873180).

式, 诸如温度, 充放电率和放电深度等^[9]。内部因素主要指影响锂电池性能的 3 个机制: 锂离子损失^[10]、活性物质损失^[11]和电导率损失^[12]。

近年来, 针对 SOH 和 RUL 估计, 研究人员进行了大量的研究, 其主要方法有基于模型的方法和数据驱动的方法, 基于模型的方法根据建模机理不同又可分为等效电路模型和电化学模型。等效电路模型忽略电池内部复杂的物理化学过程, 通过基本电子元器件来模拟电池的输出效应^[13]。Tong^[14]等人二阶等效电路模型基础上, 提出一种新型的 SOC-SOH 关系函数, 可用于 SOC 估计中的容量更新。Cheng^[15]等人为克服电池在不同动态机制下, 参数估计会出现精度不高的问题, 提出解耦加权递归最小二乘法来对等效模型参数进行参数估计。Li^[16]等人提出一种采用离散时间非线性观测器来对 SOC 进行估计的方法。基于等效电路模型的方法往往计算量小, 但模型参数往往在固定工况下确定, 导致其仅适用于有限的运行状态。进行补偿又势必会增加模型复杂度^[17-19]。

电化学模型根据电池内部的物理和化学反应, 从而推导出的与物质特性相关的电池性能衰退机制^[9]。基于多孔电极理论搭建的准二维多孔电极模型(pseudo two-dimensional model, P2D model)^[20]通过一系列偏微分方程(partial differential equation, PDE)来描述锂离子电池内部动态机制, 可以更为精确的进行状态估计, 并且通过调整参数可以适应不同电极材料的锂电池, 但 PDE 存在求解困难的问题^[21]。为减小计算量和降低模型复杂度, 一般可采用 2 种模型简化方案: 1) 单粒子模型(single particle model, SPM); 2) 将 PDE 降阶为常微分方程进行求解。但简化模型会在不同程度上降低模型精度和缩小应用范围, 对于计算量与模型精度的权衡还需要进一步研究^[22-25]。

数据驱动方法无须分析电池内部机理, 可以直接通过历史数据来建立输入特征与电池容量之间的联系。近年来, 数据驱动方法被广泛应用于电池的状态估计, 其可分为概率方法和非概率方法。前者是通过建立输入与输出之间确定关系进行的点估计, 诸如人工神经网络(artificial neural network, ANN)^[26-29]、支持向量机(support vector machine, SVM)^[30-32]以及自回归模型(autoregressive model, AR model)^[33-35]等。然而, 这类方法不能建立潜在的概率模型, 无法给出估计值的不确定性表达。但

对于 RUL 估计很重要的一点就是不仅要预测 RUL 值, 还须给出预测的不确定程度^[36]。有鉴于此, 基于贝叶斯框架衍生出的高斯过程回归(gaussian process regression, GPR)因其具有非参数化和不确定性表达的特性而得到广泛关注。另外, GPR 是一种基于核函数的机器学习方法, 其可以结合基于贝叶斯框架的先验知识来实现预测, 并通过提供预测值的置信区间来描述相关的不确定性^[37]。

对于 SOH 和 RUL 的准确估计, 除了选择较好的建模方法, 对于能够表征电池老化程度的健康特征(health factor, HF)的选取也相当重要。Liu^[38]等人通过提取恒流充电过程中和电压从 3.9V 到 1000 秒后电压差值, 以及恒压充电阶段从开始到 1000 秒内电流差值作为 HF。Zhou^[39]等人从放电曲线中提取一段时间内电压波动的均值作为 HF 来进行 RUL 估计。Xiong^[40]等人提取恒流充电阶段中电压从 3.6V 变化至 4.2V 期间的充电容量作为 SOH 和 RUL 估计的 HF。Guo^[41]等人通过从电压、电流和温度曲线中提取了 8 种 HF 来进行电池 SOH 估计。对于 HF 的合理选取有助于对电池老化的精确建模, 相比复杂多变的放电曲线, 充电曲线相对来说较为平稳, 易于提取特征, 且基于放电曲线提取的特征往往仅适用于固定的恒流放电工况。此外, 温度变化对于电池老化也有着不可忽视的影响。

另外, 图 1 为 NASA 数据集^[42-43]中 B0005 电池容量退化曲线, 从中可看出电池在老化过程中会出现容量再生现象, 如电池在 B 点容量陡增, 若此时仅采用 SOH 对电池健康程度进行评估, A 点和 B 点剩余可用容量相同, 即 SOH 相同, 则两点健康程度相同, 但 B 点剩余循环次数远低于 A 点循环次数, 即 RUL_B 远小于 RUL_A , 说明 B 点老化程度远高于 A 点。容量再生会在一定程度上延长电池的使用寿命, 但并不能代表其可以完全恢复到之前时刻相应 SOH 时的健康程度。因此, 对于电池的健康

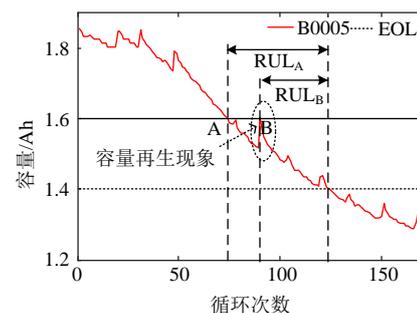


图1 锂离子电池容量退化曲线

Fig. 1 Capacity degradation curve of lithium-ion battery

评估，仅凭 SOH 难以得到全面准确的评价，需要结合当前电池 SOH 和 RUL 来进行综合诊断，但常用方法往往仅对其中之一进行估计，而分别对两者进行估计则必然会增加计算量和算法复杂度。

基于上述原因，本文从电池的充电曲线和充电过程温度曲线中提取 HF，采用 Pearson 和 Spearman 相关系数来给出 HF 与容量相关性评价，进行 HF 选择。为减小计算复杂度，采用主成分分析对所选取 HF 进行降维处理，得到间接健康特征(indirect health factor, IHF)。此外，本文提出一种基于 GPR 模型的 SOH 和 RUL 联合估计方法。将 IHF 作为高斯过程回归模型的输入，容量作为输出，建立电池老化模型。并在此基础上，通过最小二乘支持向量机(least square support vector machine, LS-SVM)对老化过程中 IHF 变化趋势进行建模，并与所建立的电池老化模型结合，进行 SOH 的多步预测，从而实现 RUL 的准确估计。

本文第一部分介绍健康特征的提取与优化过程；第二部分说明 SOH 和 RUL 估计的整体流程；第三部分描述实验验证结果；第四部分阐述结论。

1 健康特征选取与优化

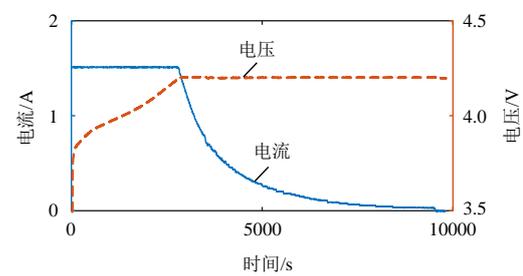
1.1 健康特征提取

本文所用电池老化数据来自 NASA 的锂电池循环测试数据集。表 1 为所选 4 块电池参数以及运行工况等基本信息。如前所述，本文是从电池充电过程中的电流、电压以及温度曲线中提取 HF。电池充电过程包括恒流充电和恒压充电两个阶段，首先，电池以 1.5A 电流恒流充电至电压上升至 4.2V，然后，进行恒压充电至电流降至 20mA。在恒流充电阶段，电池温度会不断上升并达到峰值，然后在恒压阶段开始下降。在电老化过程中，容量可以直接地表明电池老化程度，但其不易直接测量，而从电压、电流和温度变化曲线中提取的 HF 可以间接反应电池的老化情况^[33]。如图 2 所示，因此，本文从充电电流、电压及温度曲线中选取了 12 个健康特征，可分为 3 类：1) 不同充电阶段的时间及其比值：恒流充电阶段时间 L_1 ，恒压充电阶段时间 L_2 ，两者比值 L_1/L_2 ，以及充电阶段总时间 L ；2) 不同阶段电流和温度曲线在时间上的积分： C_1 为恒流充电阶段电流曲线， C_2 为恒压充电阶段电流曲线， C 为总充电阶段的电流曲线， T_1 为恒流充电阶段温度曲线， T_2 为恒压充电阶段温度曲线， T 为总充电

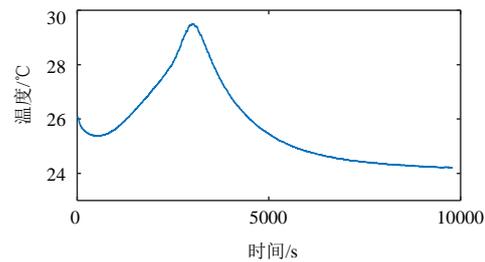
阶段温度曲线；3) 充电电压曲线的最大斜率 K_1 和充电电流曲线的最大斜率 K_2 。充电阶段电流、电压和温度曲线如图 2 所示，经标准化处理后的 HF 如图 3 所示。

表 1 所选电池参数与运行工况
Table 1 Parameters and operating conditions of selected batteries

电池编号	放电 电流/A	截止 电压/V	环境 温度/°C	额定 容量/Ah	EOL/Ah
B0005	2	2.7	24	2	1.40
B0007	2	2.2	24	2	1.45
B0029	4	2.0	43	-	1.65
B0031	4	2.5	43	-	1.70



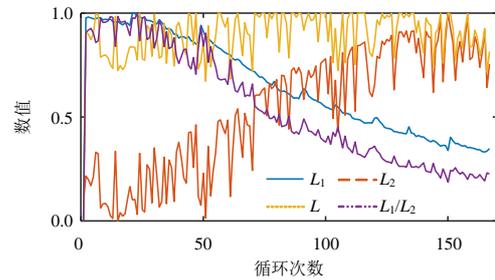
(a) 充电电流和电压曲线



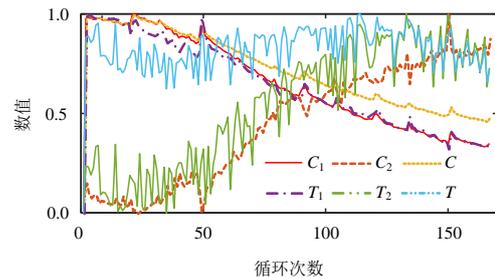
(b) 充电阶段温度曲线

图 2 锂离子电池充电曲线

Fig. 2 Charging curve of Lithium-ion battery



(a) 第一类健康特征



(b) 第二类健康特征

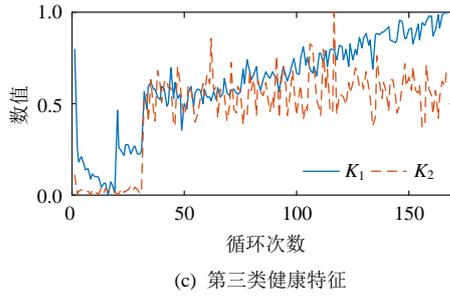


图3 B0005 标准化健康特征

Fig. 3 Normalized health indexes of B0005

1.2 健康特征选取

如图3所示,各HF变化趋势不一,难以直接判断其与容量之间的相关程度。为了进一步量化健康特征与容量之间相关程度,本文采用 Pearson 和 Spearman 相关系数来对 HF 与容量相关程度进行衡量。其计算公式为

$$Pearson = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)}\sqrt{E(Y^2) - E^2(Y)}} \quad (1)$$

表2 HF 的 Pearson 相关系数

Table 2 Pearson correlation coefficient of HF

	L_1	L_2	L	L_1/L_2	C_1	C_2	C	T_1	T_2	T	K_1	K_2
B0005	0.9960	-0.9105	-0.2669	0.9826	0.9960	-0.9860	0.9961	0.9897	-0.9149	-0.3108	-0.8954	-0.6170
B0007	0.9915	-0.8782	-0.2770	0.9773	0.9914	-0.9349	0.9926	0.9787	-0.8818	-0.2883	-0.6945	-0.6346
B0029	0.9760	0.1917	0.8680	0.8258	0.9760	-0.2755	0.9805	0.8955	0.1946	0.8969	0.5467	0.8082
B0031	0.9616	0.4401	0.8186	0.5881	0.9608	0.2846	0.9714	0.7764	0.4522	0.8654	0.9104	0.9279

表3 HF 的 Spearman 相关系数

Table 3 Spearman correlation coefficient of HF

	L_1	L_2	L	L_1/L_2	C_1	C_2	C	T_1	T_2	T	K_1	K_2
B0005	0.9902	-0.8868	-0.2259	0.9785	0.9901	-0.9744	0.9918	0.9860	-0.8678	-0.2372	-0.9476	-0.5094
B0007	0.9881	-0.8522	-0.2264	0.9696	0.9880	-0.9131	0.9909	0.9811	-0.8293	-0.2115	-0.7410	-0.4464
B0029	0.9743	0.1221	0.8822	0.8346	0.9743	-0.2885	0.9769	0.8976	0.1249	0.9415	0.3931	0.8170
B0031	0.9628	0.3435	0.8399	0.6241	0.9628	0.3059	0.9684	0.8172	0.3650	0.9024	0.9516	0.9419

1.3 健康特征优化

所提取的 HF 与容量之间都具有较高的相关性,则彼此之间必然存在重叠的信息,考虑将重叠信息与多余信息分离以减小计算复杂度,本文采用主成分分析(principal component analysis, PCA)来对所选取的 HF 进行优化。PCA 能够在尽可能保持原有信息的同时,将原来较多的变量重新组成几个较少的互相无关的综合变量。其具体步骤如下:

将4个健康特征构成的矩阵设为一个 $n \times m$ 的矩阵 \mathbf{X} , n 为样本个数,此处 $m=4$ 。将 \mathbf{X} 进行标准化处理后得到 \mathbf{X}^* ,再计算其协方差矩阵 \mathbf{S} :

$$\mathbf{S} = \frac{1}{m-1} \mathbf{X}^{*T} \mathbf{X}^* \quad (3)$$

$$Spearman = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2} \sqrt{\sum_i (y_i - \bar{y})^2}} \quad (2)$$

式中: \mathbf{X} 和 \mathbf{Y} 分别代表健康特征和容量样本总体; x_i 和 y_i 分别代表样本。

Pearson 和 Spearman 相关系数可用于评价2个变量之间的相关性。其绝对值越大,则表明相关程度越高。若其绝对值等于1,代表2个变量完全相关。需要注意的是,当变量为连续数据,服从正态分布,且具有一定线性关系时,采用 Pearson 相关系数最为恰当,但若上述任一条件不满足,采用 Spearman 相关系数效率更高。故此处采用两者来对健康特征进行综合筛选。各健康特征与容量的相关系数如表2和表3所示,为保证所提取的 HF 能适应不同电池与工况,从中选取4个电池的 Pearson 和 Spearman 相关系数均在0.7以上的 HF(L_1, C_1, C, T_1)来作为本文采用的 HF。

\mathbf{X}^* 的特征向量 \mathbf{u}_i 和特征值 $\lambda_i, i=1,2, \dots, k$, 由式(4)计算可得:

$$\mathbf{S} \mathbf{u}_i = \lambda_i \mathbf{u}_i \quad (4)$$

式中: \mathbf{S} 为 $n \times n$ 矩阵; \mathbf{u}_i 为 $n \times 1$ 向量; λ_i 为一个标量。

由此可得降维后的矩阵 \mathbf{Z} :

$$\mathbf{Z} = \mathbf{X}^* \times \mathbf{U} \quad (5)$$

式中 $\mathbf{U}=[\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_k]$, 各主成分的贡献率可通过式(6)计算得出:

$$r_i = \lambda_i / \sum_{i=1}^k \lambda_i \times 100\% \quad (6)$$

表4列出了各电池降维后各主成分的贡献率,

表 4 主成分贡献率

Table 4 Contribution rate of components

主成分 1	主成分 2	主成分 3	主成分 4	
B0005	0.9999995	5.397608×10 ⁻⁷	1.279433×10 ⁻¹⁰	8.802619×10 ⁻¹⁴
B0007	0.9999986	1.431438×10 ⁻⁶	4.992601×10 ⁻¹⁰	1.700081×10 ⁻¹³
B0029	0.9999879	1.209873×10 ⁻⁵	5.686634×10 ⁻¹⁰	9.936861×10 ⁻¹³
B0031	0.9999516	4.838193×10 ⁻⁵	3.487932×10 ⁻¹⁰	1.530937×10 ⁻¹¹

从中可以看出各电池的主成分 1 均超过 99%，因此，本文选取降维处理后的主成分 1 作为 IHF 来进行 SOH 和 RUL 估计。

2 SOH 和 RUL 估计方法

2.1 GPR

对于 GPR 模型，可以从权重空间和函数空间 2 方面进行介绍。从便于理解的角度考虑，本文选择从函数空间角度进行阐述。

GPR 模型可完全由其均值函数 $m(x)$ 和协方差函数 $k(x,x')$ 决定：

$$m(x) = E(f(x)) \quad (7)$$

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x'))^T] \quad (8)$$

式中： $f(x)$ 为目标输出； x 为输入向量。

高斯过程可写为

$$f(x) \sim GP(m(x), k(x, x')) \quad (9)$$

一般可通过数据预处理使均值函数为 0，协方差函数则采用核函数方式来进行设置，本文选取常用的 SE 核函数，具体形式为

$$k_f(x, x') = \delta_f^2 \exp\left(-\frac{1}{2l}(x - x')^2\right) \quad (10)$$

式中： δ_f^2 为信号方差； l 为特征长度尺度。

模型观测值不可避免会受到噪声影响，因此在模型中加入独立同分布的高斯噪声，具体形式为

$$y = f(x) + \varepsilon \quad (11)$$

式中： $\varepsilon \sim N(0, \delta_n^2)$ ； y 为考虑噪声影响的输出观测值。

模型的先验分布可表示为

$$y \sim N(0, K_f(x, x) + \delta_n^2 I_n) \quad (12)$$

$$\begin{cases} K_f(x, x) = (k_{ij})_{n \times n} \\ k_{ij} = \delta_f^2 \exp\left(-\frac{1}{2l}(x_i - x_j)^2\right) \end{cases} \quad (13)$$

式中 $K_f(x, x)$ 是一个 n 维对称的正定矩阵。

$\delta_n^2 I_n$ 定义为噪声协方差矩阵。 I_n 是一个 n 维单位矩阵。 k_{ij} 用来描述变量 x_i 与 x_j 之间的相似程度，

相似程度越高， k_{ij} 值越大。

高斯过程是一个随机过程，其中任一随机变量的有限维子集都服从联合正态分布，所以训练集 (x, y) 和测试集 x^* 以及其对应的观测值 y^* 的联合先验分布为

$$\begin{bmatrix} y \\ y^* \end{bmatrix} \sim N\left(0, \begin{bmatrix} K_f(x, x) + \delta_n^2 I_n & K_f(x, x^*) \\ K_f(x, x^*)^T & K_f(x^*, x^*) \end{bmatrix}\right) \quad (14)$$

观测值 y^* 的后验分布为

$$y^* | x, y, x^* \sim N(\bar{y}^*, \delta^2(y^*)) \quad (15)$$

式中： \bar{y}^* 为预测均值； $\delta^2(y^*)$ 为预测方差。

两者具体表达式为

$$\bar{y}^* = K_f(x, x^*)^T [K_f(x, x) + \delta_n^2 I_n]^{-1} y \quad (16)$$

$$\begin{aligned} \delta^2(y^*) &= K_f(x^*, x^*) - K_f(x, x^*)^T \\ &\quad [K_f(x, x) + \delta_n^2 I_n]^{-1} K_f(x, x^*) \end{aligned} \quad (17)$$

式中超参数 $\theta = [\delta_f, l, \delta_n]$ ，可通过最小化负对数似然 (negative log marginal likelihood, NLML)函数来求解，具体形式为

$$\theta_{opt} = \arg \min_{\theta} NLML \quad (18)$$

$$\begin{aligned} NLML &= -\log p(y | x, \theta) = \frac{1}{2} y^T [K_f(x, x) + \delta_n^2 I_n]^{-1} y + \\ &\quad \frac{1}{2} \log(\det(K_f(x, x) + \delta_n^2 I_n)) + \frac{n}{2} \log 2\pi \end{aligned} \quad (19)$$

一般可通过对似然函数求偏导，再采用共轭梯度法来对进行求解。具体形式为

$$\begin{cases} \frac{\partial}{\partial \theta_i} \log p(y | x, \theta) = \frac{1}{2} \{[\alpha \alpha^T - (K_f(x, x) + \delta_n^2 I_n)^{-1} \frac{\partial (K_f(x, x) + \delta_n^2 I_n)}{\partial \theta_i}]\} \\ \alpha = (K_f(x, x) + \delta_n^2 I_n)^{-1} y \end{cases} \quad (20)$$

当超参数确定，即可得到 GPR 模型，然后可根据均值函数和方差来对于测试数据进行估计。另外，预测结果的 95%置信区间为

$$[\bar{y}^* - 1.96 \times \sqrt{\delta^2(y^*)}, \bar{y}^* + 1.96 \times \sqrt{\delta^2(y^*)}] \quad (21)$$

2.2 LS-SVM

LS-SVM 是对 SVM 的一种改进，其在继承 SVM 优点的同时，用误差的二范数来代替 SVM 的不敏感函数，并用等式约束条件来代替不等式约束，从而降低了计算复杂度。

设训练样本集为 $(x_i, y_i), i=1, 2, \dots, n$ ，将样本的输入空间映射到特征空间：

$$\psi(x) = [\varphi(x_1), \varphi(x_2), \dots, \varphi(x_n)] \quad (22)$$

并在高维空间内构造最优回归函数：

$$f(x) = w^T \cdot \psi(x) + b \quad (23)$$

式中 w 和 b 为模型参数，可通过结构风险 R 最小化原则进行确定，即：

$$\min\{R = c \sum_{i=1}^n e_i^2 + \frac{1}{2} \|w\|^2\} \quad (24)$$

$$\text{s.t. } y_i = w^T \cdot \varphi(x_i) + b + e_i, i=1, 2, \dots, n \quad (25)$$

式中： c 为正规化参数； e_i 为模型对训练样本的预测误差。

可通过拉格朗日方法进行求解：

$$L(w, b, e_i, \alpha) = c \sum_{i=1}^n e_i^2 + \frac{1}{2} \|w\|^2 - \sum_{i=1}^n (\alpha_i (w^T \cdot \varphi(x_i) + b + e_i - y_i)) \quad (26)$$

式中 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]$ 为拉格朗日乘子，对各参数求偏导可得到：

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^n \alpha_i \varphi(x_i) = 0 \quad (27)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^n \alpha_i = 0 \quad (28)$$

$$\frac{\partial L}{\partial e_i} = ce_i - \alpha_i = 0 \quad (29)$$

$$\frac{\partial L}{\partial \alpha_i} = w^T \cdot \varphi(x_i) + b + e_i - y_i = 0 \quad (30)$$

通过求解上式可得最优回归函数：

$$f(x) = \sum_{i=1}^n (\alpha_i \cdot \langle \varphi(x), \varphi(x_i) \rangle) + b \quad (31)$$

式中 $\langle \varphi(x_i), \varphi(x_j) \rangle$ 为高维特征空间的内积。

若定义核函数 $K(x_i, x_j) = \langle \varphi(x_i), \varphi(x_j) \rangle$ ，根据泛函相关理论，满足 Mercer 条件的函数皆可作为核函数，本文选取常用的径向基核函数(RBF)，其具体形式为

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (32)$$

则最终的 LS-SVM 模型为

$$f(x) = \sum_{i=1}^n (\alpha_i \cdot K(x, x_i)) + b \quad (33)$$

2.3 SOH 和 RUL 预测框架

SOH 和 RUL 都可以对电池老化程度进行评价，但是两者对电池老化程度的评价所基于的原则和适用范围皆有不同。考虑到两者之间的联系与区别，本文提出一种耦合框架来对 SOH 和 RUL 进行联合估计。整体框架如图 4 所示。通过从充电电流、电压和温度曲线中提取 HF，对选取的 HF，采用 PCA 进行优化，并将得到的 IHF 作为输入，容量作为输出，建立基于 GPR 的电池老化模型。然后，通过 LS-SVM 对经过 IHF 的整体变化趋势进行建模，并将其与所建立的电池老化模型结合进行非线性多步 SOH 预测，从而实现电池的 RUL 估计。

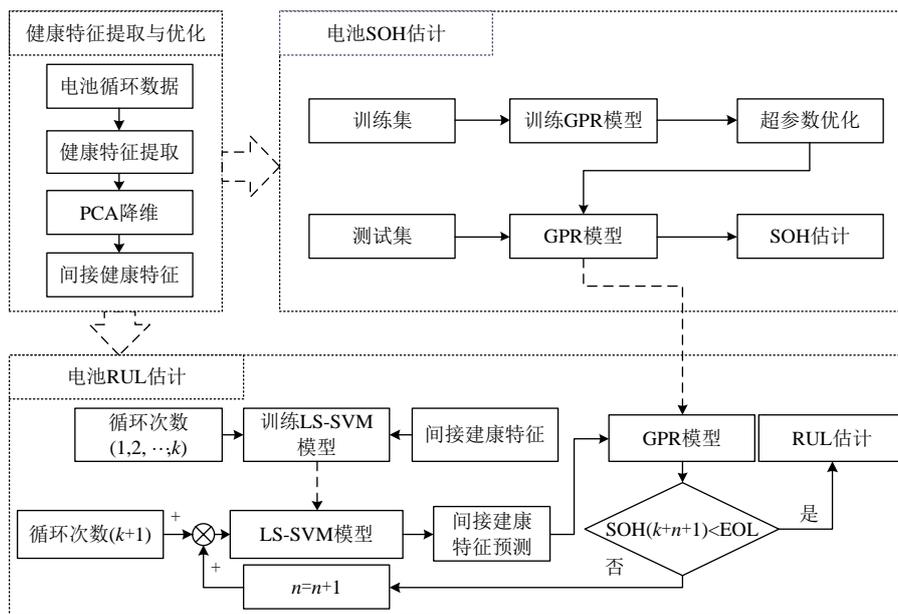


图 4 SOH 和 RUL 估计整体流程图

Fig. 4 Flowchart of SOH and RUL estimation

3 估计结果与分析

为验证所提出算法在不同温度和工况下的预测精度和可靠性,本文使用表 1 中的 4 块电池数据来对进行验证。2 组不同温度下的电池数据(B0005 和 B0007、B0029 和 B0031)被用于验证算法的精度和可靠性,其中 B0005 和 B0007 共 168 个循环, B0029 和 B0031 共 39 个循环。另外,采用平均绝对误差(mean absolute error, MAE)和均方根误差(root mean squared error, RMSE)来作为算法性能的评估指标。

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - \hat{x}_i| \quad (34)$$

$$RMSE = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N (x_i - \hat{x}_i)^2 \right)} \quad (35)$$

3.1 SOH 估计结果

为验证所建立的电池老化模型的准确度和可靠性,将 4 个电池数据的前 60%作为训练集,后 40%作为测试集,即 B0005 和 B0007 的前 100 个循环为训练集,后 68 个循环为训练集, B0029 和 B0031 的前 23 个循环为训练集,后 16 个循环为测试集。在每次循环中,从充电电流、电压和温度曲线中提取所选取的 4 个 HF,并利用 PCA 进行优化得到 IHF,将其结果作为 GPR 模型输入,即可得到相应的 SOH 估计值。图 5 为使用测试集所得到的估计值与真实值,其中黑线为真实值,容量真实值通过对充满电的电池进行恒流放电至截止电压测得,红线为估计值,从中可以看出估计值不仅可以很好的捕捉容量衰退趋势,对老化过程中的容量再生现象也可以很好地适应,而且在数据量较小情况下(如 B0029 和 B0031),也能够得到较为准确的 SOH 估计。另外,4 个电池数据的估计值与真实值最大相对误差不超过 2%,表明所提出 GPR 模型不仅可以适应不同温度和工况,而且精度较高。GPR 模型不仅能够给出 SOH 的估计值,而且可以计算 SOH 估计值的置信区间,图 5 中虚线为 SOH 估计值的 95% 置信区间上下界,表示真实值有 95% 可能会出现在此区间,一般置信区间越窄,代表模型可靠性越高,从图中可看出 GPR 模型所得到的置信区间宽度较窄,且真实值均落在置信区间范围内,表明所提出老化模型具有较高的可靠性。表 5 列出了 MAE 和 RMSE 计算结果,4 个电池数据的 MAE 和 RMSE 计算结果均小于 1%,其中 B0005 电池误差计算的

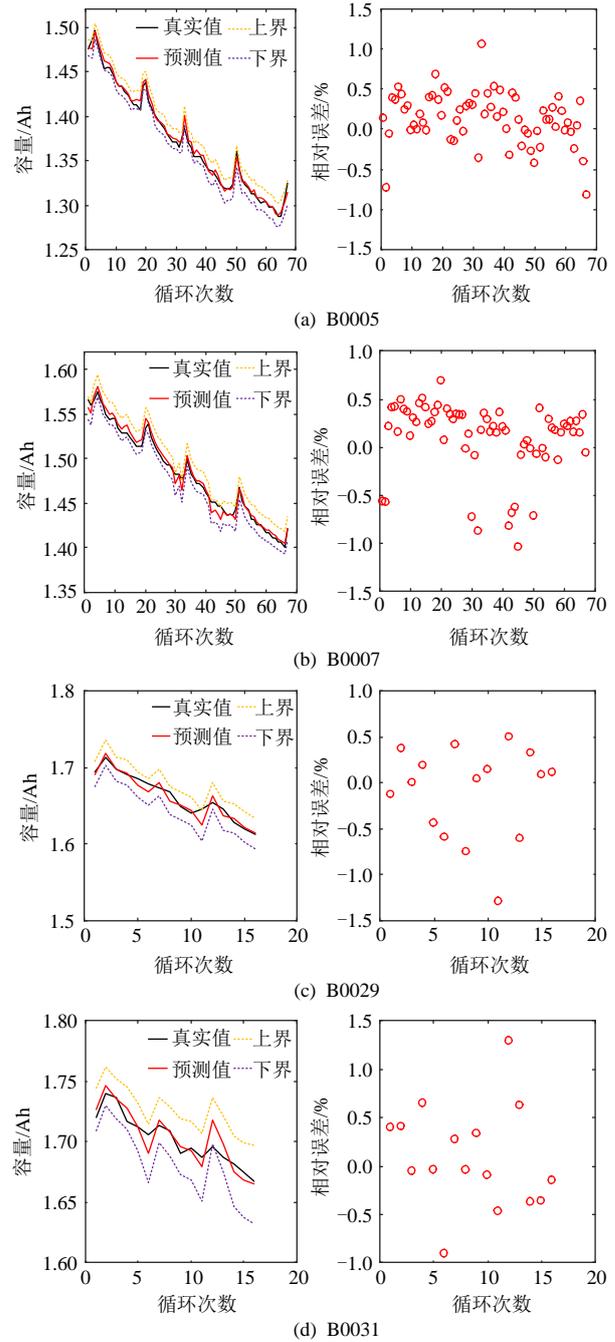


图 5 SOH 估计结果

Fig. 5 Results of SOH estimation

表 5 SOH 估计误差结果

Table 5 Results of SOH estimation error

算法	B0005	B0007	B0029	B0031
MAE	0.0037	0.0047	0.0062	0.0069
RMSE	0.0047	0.0057	0.0082	0.0088

RMSE 为 0.0047,而文献[33]将 B0005 数据集分为 10 份,每次取 1 份数据作为测试集,其余 9 份作为训练集,一共进行 10 次试验,得到估计结果的 RMSE 为 0.0153。由此可见,本文所提出的 SOH 估计方法估计精度较高,而且本文仅利用前 60%数据进行

训练,说明本文方法预测性能较好。文献[33]仅从充电电压和电流曲线中提取特征,未考虑温度因素,可能无法更加全面地对电池健康状态进行反映,因而导致估计精度不佳。这也进一步说明本文所提出 SOH 估计方法具有较高的准确性和可靠性。

3.2 RUL 估计结果

对 RUL 的估计需要在离线 GPR 模型基础上进行,然后通过预测未来循环次数的 IHF,并将其作为 GPR 模型输入,从而估计电池容量衰退情况,计算从当前时刻至 EOL 之间循环次数,即可得到 RUL 估计。由此可知,RUL 估计是针对容量衰减到 EOL 所需的循环次数的估计,则对未来 SOH 估计时应更多考虑其衰退趋势的预测,因此,为保证在对 IHF 变化趋势进行准确预测的同时尽可能降低计算复杂度,本文采用 LS-SVM 模型来对建立 IHF 与循环次数之间的映射关系,将其结果与 GPR 模型相结合进行多步 SOH 预测,从而实现 RUL 估计。为验证所提出 RUL 估计方法的精度和可靠性,利用 SOH 估计中得到的 GPR 模型,其训练集为电池数据的前 60%,故以此为起点对 RUL 进行估计。图 6 为 RUL 真实值与估计值,其中黑线为真实值,RUL 真实值通过计算当前循环周期距离 EOL 的循环次数获得,红线为估计值,从中可以看出 4 个电池的估计值与真实值都相当接近,最大绝对误差为 2,表明所提出的 RUL 估计方法精度高且适应性强。需要注意的是,一般随着循环次数增加,IHF 的预测会越来越准确,相应的 RUL 估计误差也会越小,本文总体误差都很小主要是因为 LS-SVM 仅通过小样本就可以较好地对 IHF 变化趋势进行预测,这也进一步说明所提出 RUL 估计方法适应性强。另外,图 6 中虚线为 RUL 估计值的置信区间,可以看出 B0005 和 B0007 电池的真实值均落在置信区间范围内,B0029 和 B0031 电池的真实值有一点超出界限,其主要是因为数据量过少而导致的效果不佳,但其他点均在置信区间范围内,表明即便在数据量很小情况下,所提出 RUL 估计方法也可以实现较为可靠的估计。表 6 为 MAE 和 RMSE 计算结果,各电池 MAE 均小于 1, RMSE 最大值为 1.1450,其中 B0005 电池以第 100 个循环为起始点,直至电池到达 EOL,对其中 25 个循环点进行 RUL 估计,估计误差的 RMSE 为 0.7746, MAE 为 0.6000。文献[33]通过预测 3 个健康特征的未来趋势,对 B0005 数据集 EOL 前 40 个循环点进行 RUL 估计,估计结果

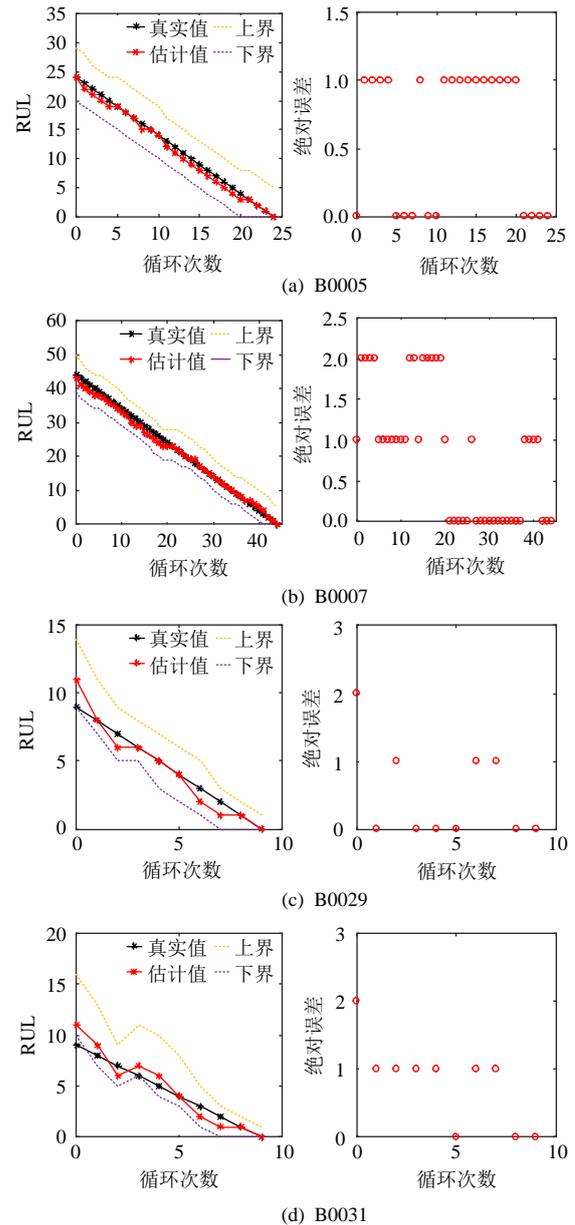


图 6 RUL 估计结果

Fig. 6 Results of RUL estimation

表 6 RUL 估计误差结果

Table 6 Results of RUL estimation error

算法	B0005	B0007	B0029	B0031
MAE	0.6000	0.8222	0.5000	0.8000
RMSE	0.7746	1.1450	0.8367	1.0000

的 RMSE 为 3.2122, MAE 为 2.5333,可以看出本文所提出的 RUL 估计方法具有较高的精度。而且本文通过 PCA 对输入特征进行降维处理,因而只需对一维 IHF 的变化趋势进行预测,大大降低计算复杂度,更有利于实际应用。

3.3 SOH 和 RUL 联合评估结果

SOH 和 RUL 都可以当前电池进行健康评估,但 SOH 是基于当前电池的容量状态进行评价,而

RUL 是通过电池的剩余循环次数进行评价。另外, 由于电池在使用过程中存在容量再生现象, 则会导致电池可能会在不同时刻出现 SOH 相同的情况, 但此时并不能说明电池恢复到与之前相应的 SOH 时的健康程度, 还需要进行进一步的判断。考虑到 B0005 和 B0007 的容量再生现象较为明显, 选取 B0005 和 B0007 中 SOH 相同而 RUL 不同的 2 点进行比较分析, 如表 7 所示, B0005 电池在第 110 次循环和第 120 次循环的剩余可用容量相当, 但两者 RUL 相差 10 个循环; B0007 电池在第 111 次循环和第 120 次循环的剩余可用容量相当, 但两者 RUL

相差 9 个循环。由此可见, 尽管 SOH 可以反映当前电池的容量状态, 但仅通过 SOH 不足对电池老化程度进行全面准确的评估。本文所提出的联合估计方法可以对当前时刻电池的 SOH 和 RUL 进行同时预测, 并且给出预测值的 95% 的置信区间, 从表中可以看出 SOH 点估计最大误差为 0.0105Ah, RUL 点估计最大误差为 2 个循环, 都能够很好地贴近真实值, 而且估计值均落在预测区间范围内, 预测精度和可靠性都较高, 通过结合 SOH 和 RUL 估计, 就可以对电池健康程度进行更加全面准确的评价。

表 7 SOH 和 RUL 联合估计结果

Table 7 Results of SOH and RUL estimations

电池编号	当前循环次数	真实容量/Ah	估计容量/Ah	估计区间/Ah	估计误差/Ah	真实 RUL	预测 RUL	预测区间	预测误差
B0005	110	1.4387	1.4384	[1.4286,1.4483]	0.0003	15	15	[11,20]	0
	120	1.4383	1.4406	[1.4308,1.4504]	0.0023	5	4	[1,9]	1
B0007	111	15343	15390	[1.5265,1.5514]	0.0047	34	33	[29,39]	1
	120	1.5340	15445	[1.5321,1.5570]	0.0105	25	23	[19,28]	2

4 结论

本文提出一种基于 GPR 的 SOH 和 RUL 联合估计方法。通过从充电电流、电压和温度曲线中提取 12 个 HF, 并采用 Pearson 和 Spearman 相关系数进行筛选以及 PCA 进一步优化得到的 IHF 作为 GPR 模型的输入, 容量作为输出, 建立基于 GPR 的电池老化模型。在此基础上, 采用 LS-SVM 模型对健康特征的变化趋势进行预测, 并与电池老化模型相结合, 进行 SOH 的多步预测, 从而实现 RUL 估计。为验证算法精度和可靠性, 采用 NASA 数据集中不同放电电流和不同温度下的 4 个电池数据进行验证, 结果表明所提出的 SOH 和 RUL 估计算法精度较高和适应性强。然而, 该方法尚未在其他电池或更为复杂工况下进行验证, 因而在进一步应用中还需要进行优化。如三元类电池在寿命末期可能出现容量跳水现象, 为提高对电池健康评估的可靠性和准确性, 在以后的工作中将从以下 3 点进行改进: 1) 选取能够反映容量跳水现象的健康特征; 2) 将电池电化学或经验知识与核函数结合来进行建模; 3) 采用性能更优算法对模型参数进行求解。

参考文献

[1] SARMAH S B, KALITA P, GARG A, et al. A review of state of health estimation of energy storage systems: challenges and possible solutions for futuristic

applications of Li-ion battery packs in electric vehicles[J]. Journal of Electrochemical Energy Conversion and Storage, 2019, 16(4): 040801.

- [2] TIAN Huixin, QIN Pengliang, LI Kun, et al. A review of the state of health for lithium-ion batteries: Research status and suggestions[J]. Journal of Cleaner Production, 2020, 261: 120813.
- [3] 闫士杰, 沈千翔, 李相俊. 大功率模块化储能系统 SOC 优化均衡控制[J]. 电网技术, 2021, 45(1): 49-56.
- YAN Shijie, SHEN Qianxiang, LI Xiangjun. Optimized SOC balancing control for high power modular energy storage system[J]. Power Grid Technology, 201, 45(1): 49-56(in Chinese).
- [4] HANNAN M A, LIPU M S H, HUSSAIN A, et al. A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations[J]. Renewable and Sustainable Energy Reviews, 2017, 78: 834-854.
- [5] 李相俊, 马锐. 考虑电池组健康状态的储能系统能量管理方法[J]. 电网技术, 2020, 44(11): 4210-4217.
- LI Xiangjun, MA Rui. Energy management method of energy storage system considering the SOH of battery pack[J]. Power grid technology, 2020, 44(11): 4210-4217(in Chinese).
- [6] LIPU M S H, HANNAN M A, HUSSAIN A, et al. A review of state of health and remaining useful life estimation methods for lithium-ion battery in electric vehicles: Challenges and recommendations[J]. Journal of Cleaner Production, 2018, 205: 115-133.
- [7] 刘昊天, 王萍, 程泽. 一种编解码器模型的锂离子电池

- 健康状态估算[J]. 中国电机工程学报, 2021, 41(5): 1851-1860.
- Liu Haotian, Wang Ping, Cheng Ze. A novel method based on encoder-decoder framework for li-ion battery state of health estimation[J]. Proceedings of the CSEE, 2021, 41(5): 1851-1860(in Chinese).
- [8] LIN Chunpang, CABRERA J, YANG Fangfang, et al. Battery state of health modeling and remaining useful life prediction through time series model[J]. Applied Energy, 2020, 275: 115338.
- [9] BARRÉ A, DEGUILHEM B, GROLEAU S, et al. A review on lithium-ion battery ageing mechanisms and estimations for automotive applications[J]. Journal of Power Sources, 2013, 241: 680-689.
- [10] JIANG Jiuchun, GAO Yang, ZHANG Caiping, et al. Lifetime rapid evaluation method for lithium-ion battery with Li(NiMnCo)O₂ cathode[J]. Journal of the Electrochemical Society, 2019, 166(6): A1070-A1081.
- [11] CHEMELEWSKI K R, LEE E S, LI Wei, et al. Factors influencing the electrochemical properties of high-voltage spinel cathodes: relative impact of morphology and cation ordering[J]. Chemistry of Materials, 2013, 25(14): 2890-2897.
- [12] ALIAS N, MOHAMAD A A. Advances of aqueous rechargeable lithium-ion battery: a review[J]. Journal of Power Sources, 2015, 274: 237-251.
- [13] 严干贵, 李洪波, 段双明, 等. 基于模型参数辨识的储能电池状态估算[J]. 中国电机工程学报, 2020, 40(24): 8145-8154.
- YAN Gangui, LI Hongbo, DUAN Shuangming, et al. Energy storage battery state estimation based on model parameter identification[J]. Proceedings of the csee, 2020, 40(24): 8145-8154(in Chinese).
- [14] TONG Shijie, KLEIN M P, PARK J W. On-line optimization of battery open circuit voltage for improved state-of-charge and state-of-health estimation[J]. Journal of Power Sources, 2015, 293: 416-428.
- [15] ZHANG Cheng, ALLAFI W, DINH Q, et al. Online estimation of battery equivalent circuit model parameters and state of charge using decoupled least squares technique[J]. Energy, 2018, 142: 678-688.
- [16] LI Weilin, LIANG Liliyuan, LIU Wenjie, et al. State of charge estimation of lithium-ion batteries using a discrete-time nonlinear observer[J]. IEEE Transactions on Industrial Electronics, 2017, 64(11): 8557-8565.
- [17] FOTOUHI A, AUGER D J, PROPP K, et al. A review on electric vehicle battery modelling: from Lithium-ion toward lithium-sulphur[J]. Renewable and Sustainable Energy Reviews, 2016, 56: 1008-1021.
- [18] SEAMAN A, DAO T S, MCPHEE J. A survey of mathematics-based equivalent-circuit and electrochemical battery models for hybrid and electric vehicle simulation [J]. Journal of Power Sources, 2014, 256: 410-423.
- [19] LIU Huaqiang, WEI Zhongbao, HE Weidong, et al. Thermal issues about Li-ion batteries and recent progress in battery thermal management systems: a review[J]. Energy Conversion and Management, 2017, 150: 304-330.
- [20] DOYLE M, FULLER T F, NEWMAN J. Modeling of galvanostatic charge and discharge of the lithium/polymer/insertion cell[J]. Journal of the Electrochemical Society, 1993, 140(6): 1526-1533.
- [21] ABADA S, MARLAIR G, LECOCQ A, et al. Safety focused modeling of lithium-ion batteries: a review[J]. Journal of Power Sources, 2016, 306: 178-192.
- [22] JOKAR A, RAJABLOO B, DÉSILETS M, et al. Review of simplified Pseudo-two-Dimensional models of lithium-ion batteries[J]. Journal of Power Sources, 2016, 327: 44-55.
- [23] DOYLE M, FULLER T F, NEWMAN J. Modeling of galvanostatic charge and discharge of the lithium/polymer/insertion cell[J]. Journal of the Electrochemical Society, 1993, 140(6): 1526-1533.
- [24] ABADA S, MARLAIR G, LECOCQ A, et al. Safety focused modeling of lithium-ion batteries: a review[J]. Journal of Power Sources, 2016, 306: 178-192.
- [25] JOKAR A, RAJABLOO B, DÉSILETS M, et al. Review of simplified Pseudo-two-Dimensional models of lithium-ion batteries[J]. Journal of Power Sources, 2016, 327: 44-55.
- [26] HUSSEIN A A. Capacity fade estimation in electric vehicles li-ion batteries using artificial neural networks[C]//IEEE Energy Conversion Congress and Exposition(ECCE). Denver: IEEE, 2013: 677-681.
- [27] WU Ji, ZHANG Chenbin, CHEN Zonghai. An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks[J]. Applied Energy, 2016, 173: 134-140.
- [28] CHAOUI H, IBE-EKEOCHA C C. State of charge and state of health estimation for lithium batteries using recurrent neural networks[J]. IEEE Transactions on Vehicular Technology, 2017, 66(10): 8773-8783
- [29] 李超然, 肖飞, 樊亚翔, 唐欣, 杨国润. 基于深度学习的锂离子电池 SOC 和 SOH 联合估算[J]. 中国电机工程学报, 2021, 41(2): 681-692.
- LI Chaoran, XIAO Fei, FAN Yaxiang, et al. Joint estimation of the state of charge and the state of health based on deep learning for lithium-ion batteries[J]. Proceedings of the CSEE, 201, 41(2): 681-692(in Chinese).

- [30] KHELIF R, CHEBEL-MORELLO B, MALINOWSKI S, et al. Direct remaining useful life estimation based on support vector regression[J]. IEEE Transactions on Industrial Electronics, 2017, 64(3): 2276-2285.
- [31] WEI Jingwen, DONG Guangzhong, CHEN Zonghai. Remaining useful life prediction and state of health diagnosis for lithium-ion batteries using particle filter and support vector regression[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5634-5643.
- [32] YANG Duo, WANG Yujie, PAN Rui, et al. State-of-health estimation for the lithium-ion battery based on support vector regression[J]. Applied Energy, 2018, 227: 273-283.
- [33] LONG Bing, XIAN Weiming, JIANG Lin, et al. An improved autoregressive model by particle swarm optimization for prognostics of lithium-ion batteries[J]. Microelectronics Reliability, 2013, 53(6): 821-831.
- [34] SONG Yuchen, LIU Datong, YANG Chen, et al. Data-driven hybrid remaining useful life estimation approach for spacecraft lithium-ion battery[J]. Microelectronics Reliability, 2017, 75: 142-153.
- [35] ZHOU Daming, AL-DURRA A, ZHANG Ke, et al. Online remaining useful lifetime prediction of proton exchange membrane fuel cells using a novel robust methodology[J]. Journal of Power Sources, 2018, 399: 314-328.
- [36] WU Lifeng, FU Xiaohui, GUAN Yong. Review of the remaining useful life prognostics of vehicle lithium-ion batteries using data-driven methodologies[J]. Applied Sciences, 2016, 6(6): 166.
- [37] LI Yi, LIU Kailong, FOLEY A M, et al. Data-driven health estimation and lifetime prediction of lithium-ion batteries: a review[J]. Renewable and Sustainable Energy Reviews, 2019, 113: 109254.
- [38] LIU Jian, CHEN Ziqiang. Remaining useful life prediction of lithium-ion batteries based on health indicator and Gaussian process regression model[J]. IEEE Access, 2019, 7: 39474-39484.
- [39] ZHOU Yapeng, HUANG Miaohua, CHEN Yupu, et al. A novel health indicator for on-line lithium-ion batteries remaining useful life prediction[J]. Journal of Power Sources, 2016, 321: 1-10.
- [40] XIONG Rui, ZHANG Yongzhi, WANG Ju, et al. Lithium-ion battery health prognosis based on a real battery management system used in electric vehicles[J]. IEEE Transactions on Vehicular Technology, 2019, 68(5): 4110-4121.
- [41] GUO Peiyao, ZE Cheng, YANG Lei. A data-driven remaining capacity estimation approach for lithium-ion batteries based on charging health feature extraction[J]. Journal of Power Sources, 2019, 412: 442-450.
- [42] SAHA B, GOEBEL K, POLL S, et al. Prognostics methods for battery health monitoring using a Bayesian framework[J]. IEEE Transactions on Instrumentation and Measurement, 2009, 58(2): 291-296.
- [43] SAHA B, GOEBEL K, CHRISTOPHERSEN J. Comparison of prognostic algorithms for estimating remaining useful life of batteries[J]. Transactions of the Institute of Measurement and Control, 2009, 31(3-4): 293-308.



王萍

在线出版日期: 2021-06-22。

收稿日期: 2020-12-09。

作者简介:

王萍(1959), 女, 教授, 博士生导师, 主要研究方向为电力电子技术与装置等, pingw@tju.edu.cn;

范凌峰(1995), 男, 硕士研究生, 主要研究方向为锂离子电池管理系统, fanlingfeng@tju.edu.cn;

*通信作者: 程泽(1959), 男, 教授, 主要研究方向为动力电池安全评估与故障诊断, chengze@tju.edu.cn。

(编辑 刘雪莹, 李新洁)

A Joint State of Health and Remaining Useful Life Estimation Approach for Lithium-ion Batteries Based on Health Factor Parameter

WANG Ping, FAN Lingfeng, CHENG Ze*

(School of Electrical and Information Engineering, Tianjin University)

KEY WORDS: lithium-ion battery; state of health; remaining useful life; principle component analysis; Gaussian process regression; least squares support vector machine

Accurate estimations of state of health (SOH) and remaining useful life (RUL) of lithium batteries are crucial to ensure the safe and stable operation of batteries. However, both of them are difficult to be directly measured. A SOH and RUL joint estimation approach based on gaussian process regression (GPR) is proposed in this paper. Health factor (HF) is extracted from the charging curve and Indirect Health Factor (IHF) is obtained through principal component analysis (PCA). Then, an aging battery model based on GPR is established to estimate SOH. Furthermore, the least squares support vector machine(LS-SVM) is used to predict IHF in the future cycles, and the IHF obtained are combined with the established battery aging model to realize RUL estimation.

The whole framework of the proposed method shown in Fig. 1 can be divided into three parts: HF extraction and optimization, battery SOH estimation and battery RUL estimation. In the first part, in order to adapt to different batteries and operating conditions, the HFs with high relevance are selected from 12 HFs extracted from charge current, voltage and temperature curve through Pearson and Spearman correlation coefficients. Furthermore, PCA is utilized to reduce data dimensionality and then the IHF obtained is employed to serve as the input of the aging model. In the second part, the hyper-parameters of the GPR-based aging model are optimized by conjugate gradient method. In the final part, the IHF data of previous k cycles is used to train the LS-SVM model and then IHF in the future cycle can be predicted. Next, the corresponding SOH prediction in the future cycle can be obtained by the GPR-based model. The degradation of IHF is continually updated through the LS-SVM model until the capacity estimation reaches the end of life (EOL). Then, the number of updates is regarded as the RUL.

The battery aging data of NASA database are applied to analyze the performance of proposed approach. For battery SOH estimation, the battery cycle data of B0005 are divided into 60% training set and 40% testing set. The comparison of estimated capacity with the testing set and the estimation error are shown in Fig. 2. It can be observed that the relative errors are all less than

1.5% and the RMSE and MAE are less than 0.5%, which indicates that the proposed method can provide accurate and robust capacity estimation. For battery RUL prediction, the result of the prediction and the absolute error is described in Fig. 3. The RUL prediction starts from cycle 100 to EOL. The maximum absolute errors are 1 and the RMSE and MAE are all less than 1. The result shows that the proposed method has good accuracy and robustness. The joint estimation approach can achieve reliable SOH and RUL estimation and then the comprehensive battery health diagnosis can be conducted with the current battery SOH and RUL.

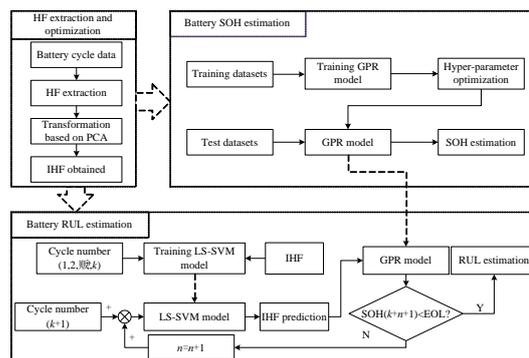


Fig. 1 Flowchart of SOH and RUL estimation

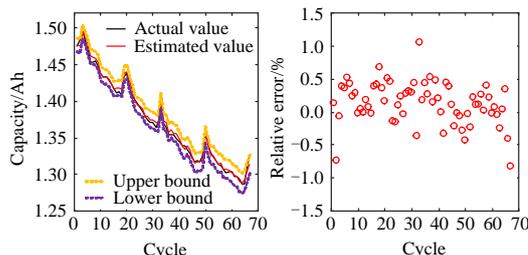


Fig. 2 Result of SOH estimation for B0005
RMSE=0.0047, MAE=0.0037

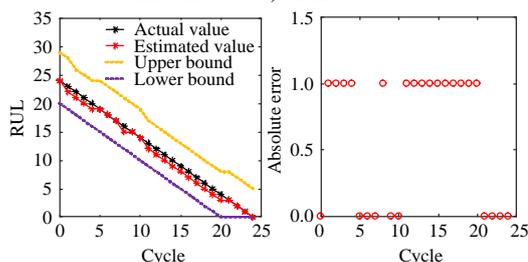


Fig. 3 Result of RUL estimation for B0005
RMSE=0.7746, MAE=0.6000