

海洋工程装备

基于 KCC-PF 的锂离子电池剩余使用寿命预测

崔显¹, 陈自强¹, 卢地华¹, 蓝建宇², 董梦雪²

(1.上海交通大学 海洋工程国家重点实验室, 上海 200240;

2.中国航天科技集团有限公司 上海空间电源研究所, 上海 200245)

摘要: **目的** 针对传统粒子滤波 (PF) 算法应用于锂电池剩余使用寿命 (RUL) 预测时准确性低的问题, 将肯德尔秩次相关系数 (KCC) 引入传统 PF 的重采样过程, 改善粒子匮乏问题, 提出一种基于 KCC-PF 的锂电池 RUL 预测方法。**方法** 首先建立电池容量衰减模型, 验证模型的准确性和有效性, 并确定模型初始参数, 利用 KCC-PF 算法循环更新模型参数, 逐步计算出容量的预测序列, 然后根据失效阈值获得锂电池 RUL 的预测结果及其不确定性表达。利用 NASA PCoE 的电池老化试验数据, 进行基于 PF 和 KCC-PF 的锂电池 RUL 预测试验。**结果** 预测起点为第 60 次循环时, 基于 KCC-PF 的锂电池 RUL 预测相对误差在 10% 以内。随着预测起点后移, 相对误差可降低至 3% 以内。**结论** KCC-PF 算法解决了传统 PF 粒子匮乏的问题, 应用于锂电池 RUL 预测时, 具有较高的预测准确性和鲁棒性。

关键词: 锂离子电池; 健康状态; 寿命预测; 粒子滤波; 相关系数

中图分类号: TM912

文献标识码: A

文章编号: 1672-9242(2022)04-0086-09

DOI: 10.7643/issn.1672-9242.2022.04.014

Remaining Useful Life Prediction of Lithium-ion Battery Based on Kendall Rank Correlation Coefficient Particle Filter

CUI Xian¹, CHEN Zi-qiang¹, LU Di-hua¹, LAN Jian-yu², DONG Meng-xue²

(1. State Key Laboratory of Ocean Engineering Shanghai Jiao Tong University, Shanghai 200240, China; 2. China Aerospace Science and Technology Corporation Shanghai Institute Space Power-Sources, Shanghai 200245, China)

ABSTRACT: Aiming at the problem of low accuracy when the traditional particle filter (PF) algorithm is applied to the prediction of remaining useful life (RUL) of the lithium-ion battery, Kendall rank correlation coefficient (KCC) is introduced into the resampling process of traditional PF to solve the problem of particle shortage, and a method of RUL prediction of the lithium-ion battery based on KCC-PF is proposed. Firstly, the battery capacity degradation model was established to verify the accuracy and effectiveness of the model and determine the model's initial parameters. KCC-PF algorithm was used to update the model parameters, and the prediction sequence of capacity was calculated step by step. Finally, the prediction results and uncer-

收稿日期: 2021-01-15; 修订日期: 2021-03-11

Received: 2021-01-15; Revised: 2021-03-11

基金项目: 国家自然科学基金 (51677119)

Fund: The National Natural Science Foundation of China (51677119)

作者简介: 崔显 (1997—), 男, 硕士研究生, 主要研究方向为锂电池健康状态管理。

Biography: CUI Xian (1997—), Male, Postgraduate, Research focus: health management and life prediction of lithium-ion battery.

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

Corresponding author: CHEN Zi-qiang (1967—), Male, Doctor, Researcher, Research focus: battery system identification and fault diagnosis.

引文格式: 崔显, 陈自强, 卢地华, 等. 基于 KCC-PF 的锂离子电池剩余使用寿命预测[J]. 装备环境工程, 2022, 19(4): 086-094.

CUI Xian, CHEN Zi-qiang, LU Di-hua, et al. Remaining Useful Life Prediction of Lithium-ion Battery Based on Kendall Rank Correlation Coefficient Particle Filter[J]. Equipment Environmental Engineering, 2022, 19(4): 086-094.

tainty expression of RUL of the lithium-ion batteries were obtained according to the failure threshold. Based on the data of the NASA PCoE battery aging test, the RUL prediction test of the lithium-ion batteries based on PF and KCC-PF was carried out. The calculation results show that: when the prediction starting point is the 60th cycle, the relative error of RUL prediction based on KCC-PF is less than 10%, and with the prediction starting point moving backward, the relative error can be reduced to less than 3%. KCC-PF algorithm solves the problem of traditional PF particle shortage, and has high prediction accuracy and robustness when applied to the remaining useful life of the lithium-ion battery.

KEY WORDS: lithium-ion battery; state of health; life prediction; particle filter; correlation coefficient

锂离子电池具有温度适应性好、体积小、循环寿命长、能量密度高以及电压可变范围大等优点, 目前已开始成为航空领域的储能设备。随着充放电循环的不断进行, 锂电池性能会逐渐下降, 其中容量的衰减最为致命。锂电池系统是卫星在阴影期间的唯一能量来源, 如果由于电池老化导致卫星无法正常工作, 将导致严重的安全事故和巨大的经济损失^[1]。电池剩余使用寿命 (Remaining Useful Life, RUL) 是对电池历史工作表现的归纳总结, 综合反映着电池的健康状态 (State of Health, SOH), 准确的 RUL 预测可以帮助卫星管理人员更清楚地掌握卫星锂电池的工作状况, 大大提高卫星储能系统的可靠性, 因此开展锂电池 RUL 预测技术研究具有重要意义。

目前锂离子电池 RUL 预测方法可分为基于数据驱动预测和基于模型预测^[2]。数据驱动法将电池的老化过程看作黑盒, 利用智能学习算法, 深入挖掘电池历史数据中的隐含信息, 并根据各种输入数据来预测 RUL。目前已有神经网络^[3]、支持向量回归^[4]以及高斯过程回归^[5]等多种算法成功用于锂电池 RUL 预测。Wu 等^[6]从锂电池在不同循环次数下的充电电压曲线中提取能反映 RUL 的外部特征参数, 提出了一种基于神经网络和信息系统的锂电池 RUL 估计方法。基于锂电池充放电循环历史数据, 建立以容量为输出的支持向量回归 (SVR) 模型是当前十分流行的 RUL 预测方法。Qin 等^[7]和 Wang 等^[8]分别采用粒子群优化 (PSO) 和人工蜂群算法 (ABC) 选择和优化 SVR 的内核参数, 实现了锂电池 RUL 预测。Liu 等^[5]提取 3 种有效的健康因子, 并分别将其作为预测对象, 通过迭代更新 GPR 模型, 结合广义线性回归推算出预测容量序列。但是数据驱动预测法必需大量的数据才能保证预测的准确性和稳定性, 且一般不具有确定表达能力, 鲁棒性及适应性都有待提高。

基于模型预测法, 根据物理化学原理或通过统计分析的方式建立电池的经验退化模型, 利用滤波算法实时获取模型输出, 推断其性能衰减趋势, 进而完成 RUL 预测。目前文献中使用的数学模型包括单指数^[9]、双指数^[10]和多项式模型^[11]等, 滤波算法以粒子滤波 (Particle Filter, PF) 应用最广^[12]。但是传统 PF 算法运行时, 不可避免地存在权值退化和粒子匮乏问题, 应用于锂电池 RUL 的预测时, 严重影响预测结

果的准确性和可靠性。一种改进方案是选择具有自适应能力的模型, 构建可变的的状态空间方程, 以弥补 PF 算法自身的缺陷。刘新天等^[13]从退化经验模型入手, 融合多项式模型、双指数模型和集成模型, 提出了一种融合交互模型 (IMM), 在不同的老化阶段, 使用不同的退化模型, 利用无迹粒子滤波 (Unscented Particle Filter, UPF) 实现 SOH 预测。另一种更为常用的方法是改进算法本身。Miao 等^[14]利用容量衰退的双指数退化模型, 结合 UPF 算法推算 RUL。结果表明, UPF 可以用于锂电池寿命预测, 但其稳定性还需提高。Xie 等^[15]采用正则化粒子滤波 (RPF) 初步预测电池容量, 然后用 EFIR 滤波器诊断并修正误差较大的初步预测值, 最后根据失效阈值获得 RUL 的优化预测结果。

以上研究从状态空间方程和重要性概率密度函数入手改进算法, 不同程度地延缓或弱化了粒子匮乏, 并取得了不错的效果。然而这些研究都忽视了重采样算法是导致粒子匮乏的根源, 通过改进重采样算法优化权值分布, 能更好地解决粒子匮乏问题。另外, 上述基于 PF 的锂电池 RUL 预测方法仅仅根据当前循环的粒子集合对容量进行估计, 使得算法的 RUL 预测精度极为依赖容量退化模型的准确性, 而没有考虑历史真实数据对估计当前状态变量的指导价值。针对以上 2 个问题, 本文采用一种基于肯德尔秩次相关系数 (Kendall Rank Correlation Coefficient, KCC) 的重采样改进 PF 算法^[16-17], 一方面很好地解决了粒子匮乏问题; 另一方面, 将容量的历史数据引入当前循环的计算, 用于指导粒子权重分配, 获得更准确的容量预测值, 从而提高了锂电池 RUL 的预测精度。

1 锂电池容量衰减模型

本文使用的锂电池老化试验数据来自 NASA 的艾姆斯预测中心 (PCoE), 试验对象为市场上常见的 18650 Li-ion 二次电池, 单节标称电压为 3.7 V, 最高限制充电电压为 4.2 V, 额定容量为 2 Ah。老化试验方法为在恒定的环境温度下对各组电池循环进行充电、放电及阻抗测量操作, 试验过程中记录电池电压、电流及阻抗等数据^[18]。本文选用编号为 B5、B6、B7

和 B18 的 4 组电池数据进行验证计算, 使用如式 (1) 所示的数学模型描述电池容量的衰减过程^[19]。

$$C_{k+1} = \mu_{C,k} C_k + \beta_{1,k} \exp\left(-\frac{\beta_{2,k}}{\Delta t_k}\right) \quad (1)$$

式中: k 表示充放电循环次数; C_k 表示第 k 个充放电周期的充电容量; Δt_k 表示第 k 个周期到第 $k+1$ 个周期的时间间隔。该模型建立在如图 1 所示的集总参数模型上, 图 1 中模型参数包括双电层电容 C_{DL} 、电荷转移电阻 R_{CT} 、Warburg 阻抗 R_W 和电解质电阻 R_E 。从传感器测得的数据 (如电压、电流、功率、频率、温度和电化学阻抗谱) 中提取特征值, 并用于辨识上述各项参数。随着电池的老化, C_{DL} 和 R_W 变化甚微, 而 $R_{CT}+R_E$ 与电池容量有着较强的线性相关性。充放电循环过程中, 电池内部的锂金属可能与电解液发生副反应, 其生成物一方面使得电荷转移电阻和电解质电阻增大; 另一方面, 消耗活性锂离子, 使得电池容量衰减, 从而决定了电池容量衰减的总体趋势。式 (1) 使用库伦效率 $\mu_{C,k}$ 综合描述此衰减趋势。

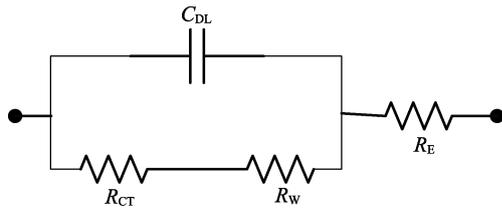


图 1 锂离子电池的集总参数模型

Fig.1 Lumped parameter model of lithium-ion battery

无论何种锂离子电池, 搁置时副反应产物都会在电极周围积聚, 一方面减缓了电池内部锂离子的消耗; 另一方面, 副反应产物在此期间有所消散, 从而增加了下一个循环的可用容量, 即所谓的容量再生现象。该现象由式 (1) 中的指数项描述。式 (1) 中, Δt_k 为关于锂电池实际充放电频率的参数, 并且在模型中可视作 $\beta_{2,k}$ 的系数。在实验室稳定的充放电频率下, 取 Δt_k 为恒定值 1。在计算中, 将 Δt_k 的变化纳入到 $\beta_{2,k}$ 的调整中, 不会影响计算结果。

式 (1) 所示的模型不直接包含循环次数 k , 而是利用递推项和动态常数项表示容量的衰减过程, 与另一种常用的双指数模型 $C_k = a \cdot \exp(b \cdot k) + c \cdot \exp(d \cdot k)$ 相比, 本文所用模型的泛化能力更强。不同组电池数据训练得到的模型之间可以进行良好的参数交互, 因而可以方便地确定预测模型的初始参数。

模型初始参数无法由历史数据直接拟合得到, 但 3 个参数都有其经验范围。对于 NASA PCoE 的试验数据集, $\mu_{C,k}$ 可取 0.997 附近值, $\beta_{1,k} \in [0.3, 1]$, $\beta_{2,k} \in [1, 10]$ 。不同电池老化试验初始阶段的容量数据常常差异很大, 而对于锂电池的 RUL 预测而言, 往往更为关心预测起点以后的容量衰减情况。基于这种考

虑, 本文在对 3 个参数进行不同组合的寻优测试时, 以预测起点后的样本点拟合的均方根误差 (η_{RMSE}) 作为模型准确性的指标, 见式 (2)。

$$\eta_{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (C_k - \hat{C}_k)^2} \quad (2)$$

式中: n 表示预测起点后的样本容量; C_k 和 \hat{C}_k 分别表示第 k 次循环电池容量的真实值和拟合值。 η_{RMSE} 可以反映拟合误差的大小, 其值越接近 0, 说明拟合误差越小, 拟合质量越高。将 3 组数据作为训练数据, 获得各自的拟合模型参数, 再将各参数的平均值作为预测模型的初始参数, 剩余 1 组数据用于预测锂电池的剩余使用寿命。最终确定各模型的参数见表 1。

表 1 模型参数

Tab.1 Model parameter

电池编号	μ_C	β_1	β_2	η_{RMSE}/Ah
B5	0.996 8	0.484	6.70	0.022 3
B6	0.996 5	0.468	6.660	0.034 6
B7	0.996 9	0.484	5.860	0.025 2
B18	0.996 6	0.493	5.997	0.039 1
B6、B7、B18 的平均值	0.996 7	0.481 7	6.172 3	0.027 1
B5、B7、B18 的平均值	0.996 8	0.487 0	6.185 7	0.052 3
B5、B6、B18 的平均值	0.996 7	0.481 7	6.452 3	0.067 3
B5、B6、B7 的平均值	0.996 8	0.478 7	6.406 7	0.041 6

4 组电池数据的拟合结果及初始预测模型曲线如图 2 所示。4 组电池拟合模型的 η_{RMSE} 均在 0.04 Ah 以下, 将 3 个拟合模型的参数平均值作为预测模型的初始参数时, η_{RMSE} 有所增大, 但仍保持在 0.07 Ah 以下。可见由多个电池共同确定的容量退化模型, 与新的电池样本的拟合误差依然可以保持在较低水平, 这说明了模型具有较好的泛化能力。依靠模型的泛化能力, 在实际使用中可由锂电池老化数据集建立统一的初始预测模型, 用于同型号电池的 RUL 预测。

2 基于 KCC-PF 的锂电池 RUL 预测

2.1 建立状态空间方程

将锂电池容量退化模型的动态参数写为三维状态向量 $z_k = [\mu_{C,k}, \beta_{1,k}, \beta_{2,k}]^T$, 建立状态空间方程, 见式 (3) 和式 (4)。

$$z_{k+1} = z_k + \varepsilon_k \quad (3)$$

$$C_{k+1} = \mu_{C,k} C_k + \beta_{1,k} \exp\left(-\frac{\beta_{2,k}}{\Delta t_k}\right) + \delta_k \quad (4)$$

式 (3) 中: ε_k 为过程噪声, $\varepsilon_k = [\varepsilon_{\mu,k}, \varepsilon_{\beta_{1,k}}, \varepsilon_{\beta_{2,k}}]^T$,

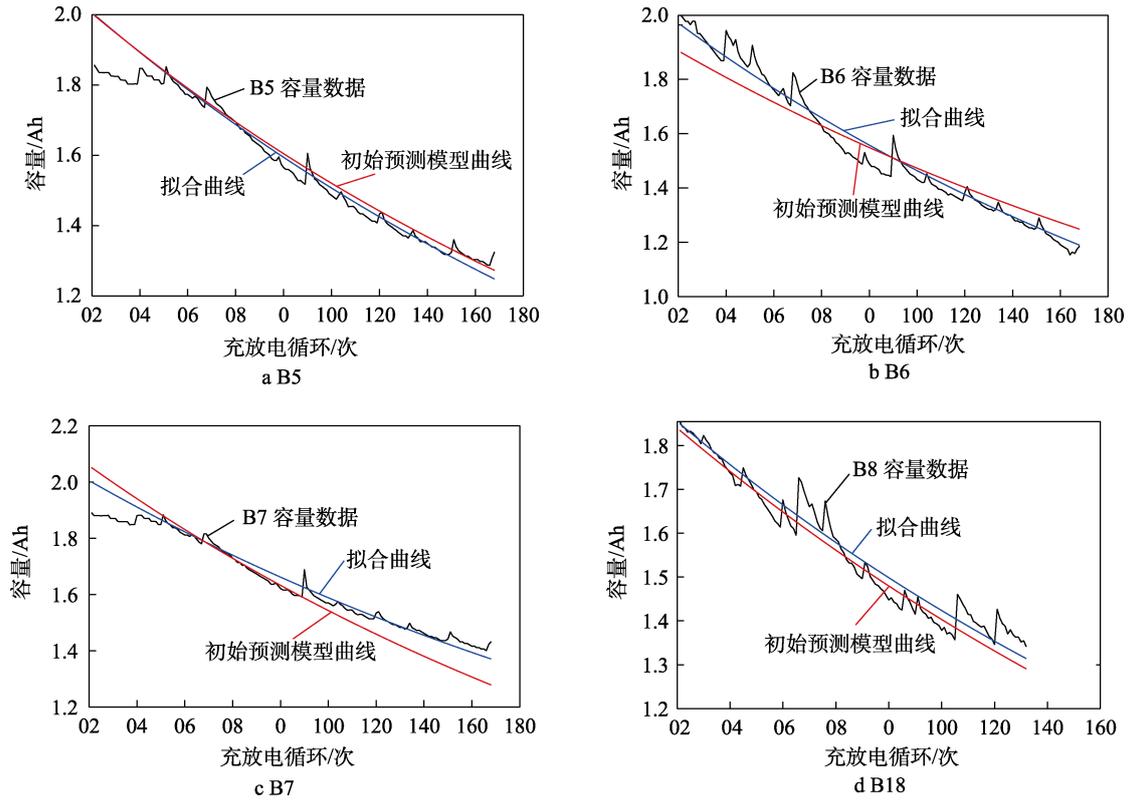


图 2 拟合模型及初始预测模型
Fig.2 Fitting model and initial prediction model

其协方差矩阵为 $\Sigma = \begin{bmatrix} \sigma_{\mu}^2 & 0 & 0 \\ 0 & \sigma_{\beta 1}^2 & 0 \\ 0 & 0 & \sigma_{\beta 2}^2 \end{bmatrix}$ 。式 (4) 中:

δ_k 为观测噪声, 方差为 τ^2 , 所有噪声均为高斯白噪声。式 (3) 为状态传递方程, 式 (4) 为观测方程, 取 $\Delta t_k=1$ 。

2.2 标准粒子滤波原理

粒子滤波 (PF) 算法的核心思想是寻找一组与状态变量服从相同分布的随机样本, 以求和计算代替积分运算, 以加权和近似期望值, 对状态变量的后验概率密度函数进行逼近, 然后利用贝叶斯理论框架推断出状态变量的期望和方差的次优解。将式 (3)、(4) 组成的状态空间方程简写成式 (5) 的形式, 作为 PF 的研究对象。

$$\begin{cases} \mathbf{z}_k = f(\mathbf{z}_{k-1}) + \boldsymbol{\varepsilon} \\ \mathbf{x}_k = h(\mathbf{z}_{k-1}) + \boldsymbol{\delta} \end{cases} \quad (5)$$

式中: \mathbf{z} 为状态变量; \mathbf{x} 为观测变量; $\boldsymbol{\varepsilon}$ 和 $\boldsymbol{\delta}$ 仍表示过程噪声和观测噪声。记 $\mathbf{Z}_k = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_k\}$ 和 $\mathbf{X}_k = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_k\}$ 表示历史信息的集合。PF 的目标是根据已知的历史观测数据 \mathbf{X}_k , 估计当前未知 \mathbf{z}_k 的后验概率分布 $p(\mathbf{z}_k | \mathbf{X}_k)$ 。蒙特卡洛方法利用粒子集近似表示状态变量的概率分布, 由于后验概率分布未

知, 故引入重要性密度函数 $q(\mathbf{z})$, 从中采样得到 N 个粒子 $\{\mathbf{z}^{(i)}, i=1, 2, \dots, N\}$, 状态变量的期望公式为:

$$E_{\mathbf{z}|\mathbf{X}}(\mathbf{z}_k) \approx \frac{1}{N} \sum_{i=1}^N \mathbf{z}_k^{(i)} q(\mathbf{z}_k^{(i)} | \mathbf{X}_k) \frac{p(\mathbf{z}_k^{(i)} | \mathbf{X}_k)}{q(\mathbf{z}_k^{(i)} | \mathbf{X}_k)} \quad (6)$$

一般取重要性密度函数 $q(\mathbf{z})$ 为状态变量的状态转移密度函数, 即 $q(\mathbf{z}_k) = p(\mathbf{z}_k | \mathbf{z}_{k-1})$, 于是权重公式为:

$$w_k^{(i)} = \frac{p(\mathbf{z}_k^{(i)} | \mathbf{X}_k)}{q(\mathbf{z}_k^{(i)} | \mathbf{X}_k)} \propto w_{k-1}^{(i)} \cdot p(\mathbf{x}_k | \mathbf{z}_k) \quad (7)$$

利用省略了归一化常数的高斯概率密度函数作为状态转移密度函数, 权值计算公式可写为:

$$w_k^{(i)} = w_{k-1}^{(i)} \cdot e^{-\frac{(\mathbf{x}_k - h(\mathbf{z}_{k-1}^{(i)}) - \boldsymbol{\delta}_k)^2}{2\tau^2}} \quad (8)$$

归一化权重为:

$$\hat{w}_k^{(i)} = w_k^{(i)} / \sum_{i=1}^N w_k^{(i)} \quad (9)$$

计算有效样本量 N_{eff} 及阈值 N_{th} 来决定是否进行重采样, 以避免权值退化, 见式 (10)。

$$N_{\text{eff}} = \frac{1}{\sum_{i=1}^N (\hat{w}_k^{(i)})^2} \quad (10)$$

若 $N_{\text{eff}} < N_{\text{th}} = \frac{2}{3} N$, 则进行重采样, 否则不进行重采样。

进行状态估计, 并实现容量的一步预测:

$$\hat{z}_k = \sum_{i=1}^N w_k^{(i)} z_k^{(i)} = [\hat{\mu}_k, \hat{\beta}_{1,k}, \hat{\beta}_{2,k}]^T \quad (11)$$

$$\hat{C}_{k+1} = \hat{\mu}_{C,k} \hat{C}_k + \hat{\beta}_{1,k} \exp\left(-\frac{\hat{\beta}_{2,k}}{\Delta t_k}\right) \quad (12)$$

2.3 基于肯德尔秩次相关系数 (KCC) 的重采样算法

粒子集在多步迭代以后, 误差不断累积, 很多粒子严重偏离真实值, 它们的权重变得很小, 这些粒子几乎不会对后验概率分布的估计产生任何作用, 却给计算机带来大量的无效计算, 严重影响估计效率。传统重采样算法可以有效解决权值退化问题, 其基本思想是剔除权重较小的粒子, 保留并复制权重较大的粒子, 使权值分布变得均匀。PF 多步迭代以后, 传统重采样算法使得很多权重较小的粒子被丢弃, 一些权值较大的粒子则大量重复, 导致粒子匮乏。另一方面, 由于训练数据的稀疏性, 初始预测模型不可避免地带有一定的误差, 这也会增大 RUL 预测误差。

针对上述 2 个问题, 本文采用基于肯德尔秩次相关系数 (KCC) 的重采样方法, 考察当前粒子与历史真实数据的一致性, 降低与历史变化趋势一致性较低的粒子权重, 增大与历史变化趋势一致性较高的粒子权重, 使容量的一步预测值更具合理性, 实现方法如下。

1) 准备观测变量真实值序列和估计值矩阵。对于实际值, 取长度为 L 的实际观测值序列 $\mathbf{X}_k = \{\mathbf{x}_j\}_{j=k-L+1}^k$; 对于由状态变量粒子集通过式 (4) 计算得到的观测变量估计值, 取长度为 L 的估计值矩阵:

$$\hat{\mathbf{X}}_k = \begin{bmatrix} \hat{X}_k^{(1)} \\ \hat{X}_k^{(2)} \\ \dots \\ \hat{X}_k^{(N)} \end{bmatrix} = \begin{bmatrix} \hat{x}_{k-L+1}^{(1)} \dots \hat{x}_k^{(1)} \\ \hat{x}_{k-L+1}^{(2)} \dots \hat{x}_k^{(2)} \\ \dots \\ \hat{x}_{k-L+1}^{(N)} \dots \hat{x}_k^{(N)} \end{bmatrix}_{N \times L} \quad (13)$$

2) 计算肯德尔秩次相关系数 (KCC)。将实际观测值和估计观测值按时间序列两两组合成对:

$$\{\mathbf{x}_j, \hat{\mathbf{x}}_j^{(i)}\}_{j=k-L+1}^L, \text{ 其中 } i \text{ 代表粒子序号, } N \text{ 为粒子总数。}$$

对于 2 组数据对 $(\mathbf{x}_s, \hat{\mathbf{x}}_s)$ 和 $(\mathbf{x}_t, \hat{\mathbf{x}}_t)$, 当 $s < t$ 时, 若满足 $\mathbf{x}_s < \mathbf{x}_t$ 且 $\hat{\mathbf{x}}_s < \hat{\mathbf{x}}_t$, 或 $\mathbf{x}_s > \mathbf{x}_t$ 且 $\hat{\mathbf{x}}_s > \hat{\mathbf{x}}_t$, 则称这 2 个数据对一致性相同; 若满足 $\mathbf{x}_s < \mathbf{x}_t$ 且 $\hat{\mathbf{x}}_s > \hat{\mathbf{x}}_t$, 或 $\mathbf{x}_s > \mathbf{x}_t$ 且 $\hat{\mathbf{x}}_s < \hat{\mathbf{x}}_t$, 则称这 2 个数据对一致性不同; 若满足 $\mathbf{x}_s = \mathbf{x}_t$ 或 $\hat{\mathbf{x}}_s = \hat{\mathbf{x}}_t$, 则称这 2 个数据对不具有 consistency。粒子滤波中的 KCC 值定义为所有数据对的各种组合中, 一致性相同的数据对个数 P 和一致性不同的数据对个数 Q 之差与总组合数目 $L(L-1)/2$ 的比值, 计算公式为:

$$K_{\text{KCC}k}^{(i)} = \frac{2(P-Q)}{L(L-1)} \quad (i=1, 2, \dots, N) \quad (14)$$

3) 重新计算权重。若没有不具有一致性的数据对, 则有 $P+Q=L(L-1)/2$, 结合式 (14) 知 KCC 的取值范围为 $[-1, 1]$ 。为了将 KCC 值变换到正数范围内, 取一个带参数的指数函数对 KCC 值进行处理, 见式 (15)。

$$\gamma_k^{(i)} = e^{\alpha \cdot K_{\text{KCC}k}^{(i)}} \quad (15)$$

参数 α 的作用是调整粒子权重的离散程度, 当 $0 < \alpha < 1$ 时, $\alpha \cdot K_{\text{KCC}k}$ 向原点集中, 参数 γ_k 的取值范围趋向缩小, 对应的粒子权重较为集中; 当 $\alpha > 1$ 时, $\alpha \cdot K_{\text{KCC}k}$ 以原点为中心向两端发散, 参数 γ_k 的取值范围趋向扩大, 对应的粒子权重较为分散。参数 α 的取值不能太大, 否则经过指数函数的计算会造成参数取值过小或过大, 从而产生样本匮乏现象, 本文采用文献[14]的提议值, 设置 $\alpha=10$ 。结合式 (8) 得到重新分配的粒子权重为:

$$w_k^{(i)} = \gamma_k^{(i)} \cdot e^{-\frac{(z_k - h(z_{k-1}) - \delta_k)^2}{2\sigma^2}} \quad (16)$$

2.4 基于 KCC-PF 的锂电池 RUL 预测步骤

1) 初始化参数。以式 (3)、(4) 为 KCC-PF 的状态空间方程, 将训练数据拟合模型参数的平均值作为初始状态变量。设定预测起点, 取粒子数 $N=500$, 所有噪声的方差均为 0.000 1。电池老化过程中存在容量再生现象, 在容量衰减曲线中表现为局部的回升, 应尽可能使长度为 L 的真实容量值序列仅包含 1 次容量回复。观察到所用训练数据容量回升大约每 20 次充放电循环发生 1 次。同时, 要截取尽可能多的历史数据用于计算 KCC 值, 因此设定 $L=18$ 较为合理。

2) PF 状态跟踪。利用 PF 算法跟踪预测起点之前的真实容量变化, 构建初始粒子集, 为预测起点后执行 KCC-PF 算法做准备。

3) KCC-PF 更新模型参数, 计算容量的一步预测值。根据状态空间方程更新粒子 (即模型参数), 将当前粒子集与步骤 2) 构建的初始粒子集组合, 计算每个粒子与历史数据之间的 KCC 值, 利用式 (16) 计算当前粒子权重。计算状态变量的期望值, 利用观测方程得到容量的一步预测值, 根据粒子分布给出预测容量的近似分布。

4) RUL 预测信息输出。1 次完整的 KCC-PF 可视为 1 次充放电循环, 每一次循环的输出为该次充放电循环的容量预测值。如果容量期望值达到失效阈值, 则输出当前的迭代步数作为 RUL 的预测值, 并根据容量分布求出 RUL 的预测分布; 如果未达到失效阈值, 则返回步骤 3) 进行下一步的容量预测。

本文提出的 RUL 预测算法需要基于锂电池老化数据确定容量衰减模型的初始参数, 且比较适合每个循

环的放电深度差异不大的情形。卫星锂离子电池依靠太阳能充电, 卫星光照期和阴影期十分固定, 因而电池长期处于稳定的循环充放电工作状态, 放电深度基本恒定^[20]。因此, 本文提出的 RUL 预测算法十分适用于卫星锂离子电池的 RUL 估算。

3 预测结果与分析

3.1 基于 KCC-PF 算法的 RUL 预测准确性

B5、B6 及 B18 的失效阈值设置为 1.38 Ah, B7 由于容量衰减幅度较小, 其失效阈值设置为 1.42 Ah。B5、B6 和 B7 共进行了 168 次充放电循环, 设置其预测起点为第 60 次循环。B18 共进行了 132 次循环, 为保证足够的迭代步数, 设置其预测起点为第 30 次循环。

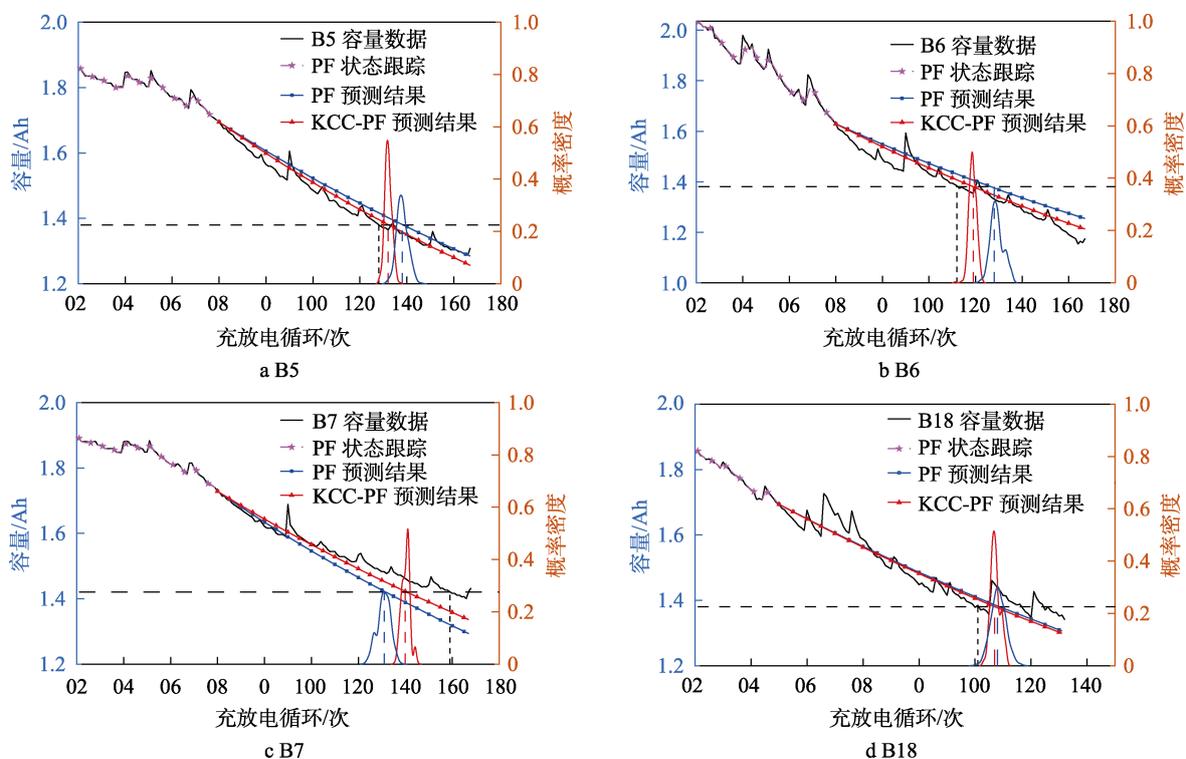


图 3 4 组电池的容量及 RUL 的计算结果

Fig.3 Calculation results of capacity and RUL of the four batteries

4 组电池的容量及 RUL 预测结果见表 2, 表中 PRUL 表示锂电池剩余寿命的预测值。以 B5 为例, KCC-PF 算法迭代过程中的最大容量预测误差为 0.047 9 Ah, 低于 PF 的 0.057 1 Ah, 均方根误差为 0.024 8 Ah, 同样低于 PF 的 0.032 6 Ah。考察 2 种算法的 RUL 预测结果, 以 B5 为例, 预测起点为第 60 次循环时, 基于 PF 算法的 RUL 预测绝对误差和相对误差分别达到了 10 次和 7.81%, 而基于 KCC-PF 算法的 RUL 预测的绝对误差降低至 4 次, 相对误差降低至 3.13%。KCC-PF 算法可以以概率密度分布的形式给出 RUL 预测的不确定性表达, 概率密度分布曲线的高度

为验证本文所提方法是否提高了原有算法的预测精度, 同时进行了基于标准 PF 和 KCC-PF 的锂电池 RUL 预测试验。4 组电池基于 2 种算法的容量及 RUL 预测结果如图 3 所示, 同时给出了 2 种算法的 RUL 预测值的概率密度分布 (Probability Density Function, PDF) 曲线。2 种算法的容量预测序列都与真实容量的衰减趋势相吻合, 这说明本文所用模型可以很好地适应粒子滤波框架。考察 2 种算法容量预测的迭代过程, 相比于 PF, 基于 KCC-PF 的容量预测序列更贴近真实容量。这是由于 KCC-PF 算法充分考虑了预测起点之前历史容量的变化情况对当前粒子权重分配的指导价值, 一定程度上削减了初始预测模型本身带有的误差, 使得容量预测序列的变化趋势与预测起点之前的历史数据变化趋势更具一致性。

越高, 分布区间宽度越窄, 说明粒子分布越集中, RUL 预测的不确定性越小, 预测结果的精度和可信度越高。结合图 3 和表 2 可以看出, 基于 KCC-PF 的 RUL 预测结果的概率密度分布普遍比 PF 更高, 区间宽度更窄, 说明 KCC-PF 具有更高的 RUL 预测精度和可信度。

3.2 预测起点对 RUL 预测精度的影响

将预测起点后移, 为算法提供更多训练数据, 同时更好地控制预测起点后的拟合误差, 构建出更为准确的初始预测模型, 并减少迭代步数, 从而提高预测精度。B5 和 B6 分别以第 60、80、100 次循环为预测

表 2 PF 和 KCC-PF 预测结果对比
Tab.2 Comparison of prediction results of PF and KCC-PF

电池	算法	最大误差/Ah	RMSE/Ah	RUL/循环	PRUL/循环	绝对误差/次	相对误差/%	PDF 区间宽度
B5	PF	0.057 1	0.032 6	68	78	10	7.81	13
	KCC-PF	0.047 9	0.024 8					
B6	PF	0.102 3	0.0563	52	67	15	13.39	14
	KCC-PF	0.063 4	0.037 3					
B7	PF	0.129 1	0.078 9	99	72	27	16.98	18
	KCC-PF	0.095 6	0.054 2					
B18	PF	0.099 2	0.048 7	71	79	8	7.92	16
	KCC-PF	0.097 6	0.044 2					

起点时的 RUL 预测结果如图 4 所示。

4 组电池在不同预测起点下的 RUL 预测结果见表 3。以第 60、80、100 次循环为预测起点时，B5 的 RUL 预测绝对误差分别为 4、2、1 次，PDF 区间分别为[127,136]、[125,134]、[124,132]；B6 的 RUL 预测绝对误差分别为 8、6、1 次，PDF 区间分别为 [115,125]、[102,112]、[107,116]，区间宽度均在 10

以内。整体上看，随着预测起点后移，迭代步数减少，KCC-PF 的 RUL 预测结果的相对误差呈 10%到 5%再到 3%的阶梯型下降，RUL 概率密度分布的形状和区间宽度总体稳定，说明 KCC-PF 算法在多步迭代以后粒子多样性没有发生明显降低，粒子匮乏问题得以改善，算法的多步迭代稳定性和 RUL 预测结果的可信度得到有效提高。

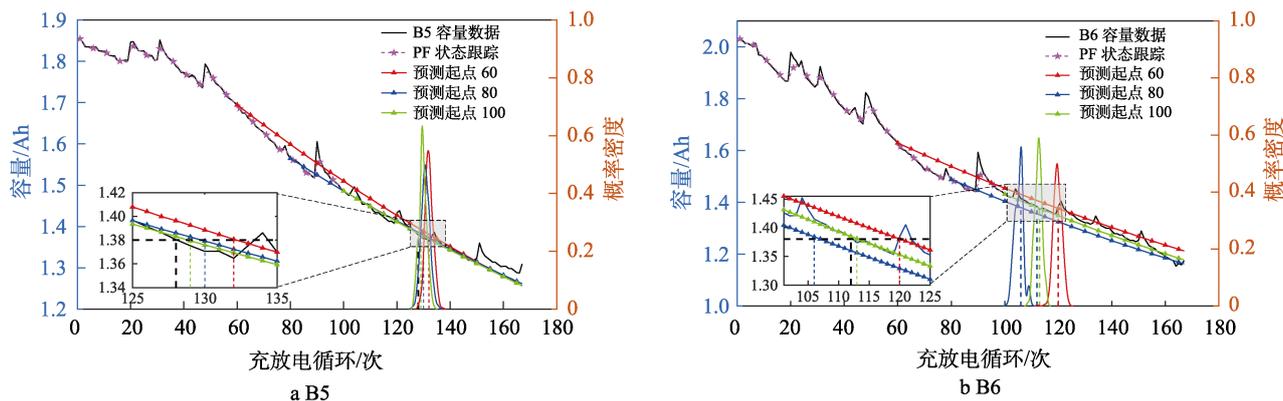


图 4 不同预测起点下的 RUL 预测结果

Fig.4 RUL prediction results at different prediction starting points

表 3 不同预测起点下的 RUL 预测结果

Tab.3 RUL prediction results at different prediction starting points

电池	预测起点	RUL/循环	PRUL/循环	绝对误差/循环	相对误差/%	PDF 区间	PDF 区间宽度
B5	60	68	72	4	3.13	[127,136]	10
	80	48	50	2	1.56	[125,134]	10
	100	28	29	1	0.78	[124,132]	9
B6	60	52	60	8	7.14	[115,125]	11
	80	32	26	6	5.36	[102,112]	11
	100	12	13	1	0.89	[107,116]	10
B7	60	99	81	18	11.32	[131,144]	14
	80	79	66	13	8.18	[141,150]	10
	100	59	50	9	5.66	[146,154]	9
B18	30	71	78	7	6.93	[104,114]	11
	50	51	60	5	4.95	[106,116]	11
	70	321	32	2	1.98	[97,101]	5

4 结论

采用递推项和动态指数项组合的容量衰退模型, 并将其 3 个参数作为状态变量。在 3 个参数的经验取值范围内进行不同的组合测试, 确定各组电池的拟合模型, 以参数平均值作为预测模型的初始参数, 根据拟合结果的 RMSE 评价模型准确性。结果表明, 拟合模型和初始预测模型的 RMSE 分别在 0.03 Ah 和 0.05 Ah 左右, 验证了本文提出的建模方法具有一定的准确性和较好的泛化能力。

在 PF 的重采样阶段, 利用肯德尔秩次相关系数将容量的历史数据引入粒子权重分配过程, 提出一种基于 KCC-PF 的锂电池 RUL 预测方法, 一方面解决了传统 PF 粒子匮乏的问题, 另一方面提高了容量预测序列与真实序列的一致性, 最终提高了 RUL 的预测精度。计算结果表明, 预测起点为第 60 次循环时, 基于 KCC-PF 的锂电池 RUL 预测相对误差基本在 10% 以内, 随着预测起点后移, 相对误差可降低至 3% 以下, 原有算法的 RUL 预测精度和鲁棒性得到有效提高。

参考文献:

- [1] 王红. 卫星锂离子电池剩余寿命预测方法及应用研究[D]. 哈尔滨: 哈尔滨工业大学, 2013.
WANG Hong. Research on Remaining Useful Life Prediction for Satellite Lithium-Ion Battery[D]. Harbin: Harbin Institute of Technology, 2013.
- [2] 戴海峰, 张艳伟, 魏学哲, 等. 锂离子电池剩余寿命预测研究[J]. 电源技术, 2019, 43(12): 2029-2035.
DAI Hai-feng, ZHANG Yan-wei, WEI Xue-zhe, et al. Review of Remaining Useful Life Prediction for Lithium Ion Battery[J]. Chinese Journal of Power Sources, 2019, 43(12): 2029-2035.
- [3] LI Peng-hua, ZHANG Zi-jian, XIONG Qing-yu, et al. State-of-Health Estimation and Remaining Useful Life Prediction for the Lithium-Ion Battery Based on a Variant Long Short Term Memory Neural Network[J]. Journal of Power Sources, 2020, 459: 228069.
- [4] 王瀛洲, 倪裕隆, 郑宇清, 等. 基于 ALO-SVR 的锂离子电池剩余使用寿命预测[J]. 中国电机工程学报, 2021, 41(4): 1445-1457.
WANG Ying-zhou, NI Yu-long, ZHENG Yu-qing, et al. Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Support Vector Regression Optimized and Ant Lion Optimizations[J]. Proceedings of the CSEE, 2021, 41(4): 1445-1457.
- [5] LIU Jian, CHEN Zi-qiang. Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Health Indicator and Gaussian Process Regression Model[J]. IEEE Access, 2019, 7: 39474-39484.
- [6] WU Ji, ZHANG Chen-bin, CHEN Zong-hai. An Online Method for Lithium-Ion Battery Remaining Useful Life Estimation Using Importance Sampling and Neural Networks[J]. Applied Energy, 2016, 173: 134-140.
- [7] QIN Tai-chun, ZENG Sheng-kui, GUO Jian-bin. Robust Prognostics for State of Health Estimation of Lithium-Ion Batteries Based on an Improved PSO-SVR Model[J]. Microelectronics Reliability, 2015, 55(9-10): 1280-1284.
- [8] WANG Ying-zhou, NI Yu-long, LU Shuai, et al. Remaining Useful Life Prediction of Lithium-Ion Batteries Using Support Vector Regression Optimized by Artificial Bee Colony[J]. IEEE Transactions on Vehicular Technology, 2019, 68(10): 9543-9553.
- [9] LYU Chao, LAI Qing-zhi, GE Teng-fei, et al. A Lead-Acid Battery's Remaining Useful Life Prediction by Using Electrochemical Model in the Particle Filtering Framework[J]. Energy, 2017, 120: 975-984.
- [10] DUONG P L T, RAGHAVAN N. Heuristic Kalman Optimized Particle Filter for Remaining Useful Life Prediction of Lithium-Ion Battery[J]. Microelectronics Reliability, 2018, 81: 232-243.
- [11] 马彦, 陈阳, 张帆, 等. 基于扩展 H_∞ 粒子滤波算法的动力电池寿命预测方法[J]. 机械工程学报, 2019, 55(20): 36-43.
MA Yan, CHEN Yang, ZHANG Fan, et al. Remaining Useful Life Prediction of Power Battery Based on Extend H_∞ Particle Filter Algorithm[J]. Journal of Mechanical Engineering, 2019, 55(20): 36-43.
- [12] 王帅. 数据驱动的锂离子电池剩余寿命预测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
WANG Shuai. Research on Data-Driven-Based Remaining Useful Life Prediction of Lithium-Ion Battery[D]. Harbin: Harbin Institute of Technology, 2017.
- [13] 刘新天, 张恒, 何耀, 等. 基于 IMM-UPF 的锂电池寿命估计[J]. 湖南大学学报(自然科学版), 2020, 47(2): 102-109.
LIU Xin-tian, ZHANG Heng, HE Yao, et al. Prognostics of Lithium-Ion Batteries Based on IMM-UPF[J]. Journal of Hunan University (Natural Sciences), 2020, 47(2): 102-109.
- [14] MIAO Qiang, XIE Lei, CUI Heng-juan, et al. Remaining Useful Life Prediction of Lithium-Ion Battery with Unscented Particle Filter Technique[J]. Microelectronics Reliability, 2013, 53(6): 805-810.
- [15] XIE Guo, PENG Xi, LI Xin, et al. Remaining Useful Life Prediction of Lithium-Ion Battery Based on an Improved Particle Filter Algorithm[J]. The Canadian Journal of

- Chemical Engineering, 2020, 98(6): 1365-1376.
- [16] MENG Qing-xu, LI Kai-cheng, ZHAO Chen. An Improved Particle Filtering Algorithm Using Different Correlation Coefficients for Nonlinear System State Estimation[J]. Big Data, 2019, 7(2): 114-120.
- [17] GAO Di-ju, ZHOU Yong, WANG Tian-zhen, et al. A Method for Predicting the Remaining Useful Life of Lithium-Ion Batteries Based on Particle Filter Using Kendall Rank Correlation Coefficient[J]. Energies, 2020, 13(16): 4183.
- [18] SAHA B, GOEBEL K. Battery Data Set, NASA Ames Prognostics Data Repository[DB/OL]. (2007) [2021-01-15]. <http://ti.arc.nasa.gov/project/prognostic-datarepository>.
- [19] SAHA B, GOEBEL K. Modeling Li-Ion Battery Capacity Depletion in a Particle Filtering Framework[C]// Proceedings of the Annual Conference of the Prognostics and Health Management Society. [s.l.]: Prognostics and Health Management Society, 2009.
- [20] YANG Jie, DU Chun-yu, LIU Wen, et al. State-of-Health Estimation for Satellite Batteries Based on the Actual Operating Parameters-Health Indicator Extraction from the Discharge Curves and State Estimation[J]. Journal of Energy Storage, 2020, 31: 101490.

责任编辑：刘世忠