

DOI: 10.13382/j.jemi.B2407375

基于 BNN-PF 的卫星锂离子电池多工况 SOH 估计*

潘大为¹ 师杰¹ 杜宇航² 宋宇晨²

(1. 哈尔滨工程大学信息与通信工程学院 哈尔滨 150001; 2. 哈尔滨工业大学电子与信息工程学院 哈尔滨 150080)

摘要: 利用在轨可测参数准确估计卫星锂离子电池的健康状态,对卫星的安全可靠运行至关重要。对于卫星锂离子电池的健康状态估计,性能退化表征和评估都需要适应多种工况。针对卫星锂离子电池在多种工况下,模型和数据中的不确定性带来的表征参数的有效性和评估结果的可靠性不足的问题,本文提出了一种基于 BNN-PF 的概率性健康状态估计方法。从卫星锂离子电池充电过程的可测参数中提取不同的健康因子来表征性能退化,将排列熵与主成分分析法相结合,提高特征对不同任务的适应能力。在此基础上,采用贝叶斯神经网络估计锂离子电池的健康状态并量化不确定性,基于粒子滤波算法融合经验模型得到的不确定性,进一步增强了所提方法对多工况的适应性。实验结果表明,本文所提方法对多工况下的卫星锂离子电池健康状态估计具有良好的适应性和通用性。交叉验证试验结果显示,最大估计误差小于 0.01,且多数结果的估计区间覆盖率大于 0.95,表明方法在空间应用场景下具有良好的前景。

关键词: 卫星锂离子电池;健康状态估计;多工况;不确定性量化和融合;贝叶斯神经网络

中图分类号: TM912; TN86 **文献标识码:** A **国家标准学科分类代码:** 120.30

BNN-PF-based SOH estimation of satellite lithium-ion batteries under different operating conditions

Pan Dawei¹ Shi Jie¹ Du Yuhang² Song Yuchen²

(1. School of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China;

2. School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150080, China)

Abstract: Accurately estimation of the state of health (SOH) of satellite lithium-ion batteries using in orbit measurable parameters is crucial for the safe and reliable operation of satellites. For the SOH estimation of satellite lithium-ion batteries, both performance degradation characterization and assessment should be self-adaptive to different operating conditions. Therefore, to address the insufficient validity of characterization parameters and the reliability of assessment results caused by uncertainty in the model and data for satellite lithium-ion batteries under different operating conditions, this paper proposes a probabilistic SOH estimation method based on BNN-PF. Extracting different health indicators (HI) from measurable parameters during satellite lithium-ion batteries charging process to characterize performance degradation, combining Permutation Entropy with principal component analysis to improve feature recognition ability for different tasks. Furthermore, a Bayesian neural network (BNN) is applied to infer the SOH of lithium-ion batteries and quantify uncertainty. The uncertainty obtained by integrating empirical model with particle filter (PF) algorithms further enhances the adaptability of the proposed method to different operating conditions. The experimental results illustrate that the method proposed in this paper demonstrates good adaptability and universality for SOH estimation of satellite lithium-ion batteries under different operating conditions. The cross-validation test results show that the maximum estimation error is less than 0.01, and the estimation interval coverage of most results is higher than 0.95, indicating that the method has good prospects in spatial application scenarios.

Keywords: satellite lithium-ion battery; state-of-health estimation; different operating conditions; uncertainty quantization and fusion; Bayesian neural network

0 引言

锂离子电池以高能量密度^[1]、低自放电率^[2]、充放电控制方便^[3]、循环寿命长^[4]等优点,在航空航天领域中发挥了至关重要的作用。在对负载效率十分敏感的航天器系统中,锂离子电池已成为第三代空间储能电源。然而,随着充放电的不断进行,卫星锂离子电池内部会发生不可逆的电化学反应,导致可用容量下降和功率衰减^[5]。可用容量决定了卫星的任务周期和在轨寿命,功率决定了卫星的载荷质量和变轨效率。这两个参数可用于定义电池的健康状态(state of health, SOH),直接表征卫星锂离子电池的退化程度,并最终影响卫星运行的稳定性和可靠性^[6]。由于导电循环、搁置时间以及电化学—机械耦合等多个相互交织的过程的影响,多工况下卫星锂离子电池的健康管理变得复杂^[7]。一旦电池出现异常情况,卫星将无法在阴影区域工作。因此,评估多工况下卫星锂离子电池的 SOH 对于在轨卫星平台的维护策略和安全管理至关重要。

在空间应用场景下,受限于卫星在轨运行可靠性以及轨道周期、任务模式的约束,可直接表征电池性能退化的参数难以在线测量^[8]。基于数据驱动的方法从在轨可测参数中提取健康因子(health indicator, HI)^[9-11],采用有时序分析能力的浅层机器学习模型^[12-13]或深度学习模型^[14-16]来构建 HI 与 SOH 间的映射模型,是实现卫星锂离子电池 SOH 估计的一种主要方法。然而,忽略估计中的不确定性,仅基于确定性点估计结果的决策是有风险的^[17]。在空间应用场景下,宇宙辐射、卫星任务、有效载荷和轨道参数变化等环境和运行条件的变化使得卫星锂离子电池的运行工况存在可变性。多工况问题将导致数据采集和退化评估建模中的不确定性增加:如测量系统的噪声和误差增大导致的随机不确定性增加^[18]、以及数据分布差异增大、模型不确定性和近似不确定性增大导致的认知不确定性增加^[19],最终导致多工况下电池性能退化演变趋势存在较大差异,SOH 估计结果的可靠性降低。

为避免 SOH 估计的可信度不足或过高,相关向量机(relevance vector machine, RVM)、高斯过程回归(Gaussian process regression, GPR)等具有不确定性表达能力的浅层机器学习方法得到了广泛应用。Song 等^[20]以等时间间隔放电电压差、等充电电压间隔时间差为 HI,基于 RVM 模型实现了锂离子电池 SOH 的在线估计,并提供了结果中的不确定性,使估计结果包含更多的信息。Liu 等^[21]考虑全局容量退化和局部再生,采用 GPR 模型估计 SOH,并给出了估计和预测中的不确定性。然而,由于卫星在轨数据具有动态特性,因此很难确保满足

RVM 和 GPR 方法需要的高斯分布假设。此外,退化评估模型的建立对数据依赖性较强,在轨运行过程中积累的电池数据较少,且地面测试与在轨运行的电池数据之间存在较大的分布差异,这些都可能使得理论估计区间表现不佳。估计区间的下限决定了卫星锂离子电池的最小供电容量,一旦下限低于预警阈值,地面操作人员通常需要及时调整卫星工作状态。贝叶斯神经网络(bayesian neural network, BNN)将深度学习的非线性处理能力和时序表达能力引入贝叶斯方法,同时考虑了可用数据的有限性和多工况下的数据分布差异,通过对模型和数据引起的不确定性进行建模,提供可靠的概率性 SOH 估计结果。Zhang 等^[22]从时间循环放电曲线中提取了 2 种 HI,通过格拉姆角场实现 HI 的信息增强,提出了一种由贝叶斯卷积神经网络、贝叶斯长短期记忆和贝叶斯全连接层组成的模型并最终实现多工况下的电池 SOH 估计。Ke 等^[23]从充电过程中提取了 21 种 HI,采用递归特征消除和交叉验证法实现 HI 的自动选取,利用 BNN 模型实现了多工况下的电池 SOH 估计和不确定性量化。然而,由于模型的偏差,贝叶斯神经网络不能完全捕获实际数据分布,实际 SOH 结果可能不包括在 SOH 估计区间覆盖范围内^[24]。因此,量化模型和数据带来的不确定性,同时确保多工况下 SOH 估计的准确性和可靠性已经成为性能退化评估过程中的一个挑战。此外,上述研究方法大多直接从锂离子电池充放电过程的特定阶段提取一种或多种 HI,前者导致了退化信息挖掘的局限性,后者忽略了不同 HI 间的复杂耦合关系,这些都将导致 HI 在多工况下的有效性和通用性不足,最终影响 SOH 估计结果的精度。因此,提取不同种类的 HI 并进行选取和优化以提高其在多工况下的适应性已成为性能退化表征过程中的一个挑战。

综上所述,在卫星锂离子电池 SOH 估计中,迫切需要克服以下两个挑战:

1) 多工况下 HI 的选取与优化。

多工况下卫星锂离子电池的退化机理具有随机性。基于在轨可测参数提取的 HI 在多工况下表征电池退化的能力具有较大差异,且各 HI 间具有较复杂的联系。因此,使用特定的 HI 进行建模很难适用于多工况。

2) 结合不确定性量化的 SOH 估计。

有限的数据可用性以及多工况下卫星锂离子电池退化过程的随机性和可变性,将进一步增加 SOH 估计过程中的不确定性。现有的估计模型缺乏通用性和透明度,很难准确地量化这些不确定性。因此,忽略不确定性对估计结果的影响,仅基于确定性 SOH 点估计结果进行系统维护和任务规划是不可靠的。

本文提出了一种基于 BNN-PF 的卫星锂离子电池多工况 SOH 估计框架。从卫星在轨可测参数中提取多种

HI,选取多工况下最有效的几种 HI 进行优化并作为模型输入。基于 BNN 构建 HI 与 SOH 间的映射,得到多工况下的 SOH 估计结果和不确定性量化结果。同时,为了提高估计的置信度,本文还通过粒子滤波 (particle filter, PF) 模型对经验模型和 BNN 模型的不确定性进行融合,进一步降低测量噪声的影响。

本文提出的方法与现有方法的差异主要体现在以下两个方面:

1) 空间应用场景下,由于不同的任务要求和环境变化,卫星锂离子电池的运行工况是动态变化的。现有方法主要是在提取特定 HI 后,根据经验直接选取 HI 进行建模。这导致了多工况下退化信息挖掘的局限性,从而影响了后期建模的准确性和通用性。相比之下,本文通过数学指标直接描述了多工况下每个 HI 所包含的退化信息,通过对各 HI 进行动态选取和优化以提高特征在多工况下的适应性。

2) 现有方法往往忽略了由于历史数据不足以及地面测试与在轨运行数据差异较大而导致的不确定性增加的问题,导致模型可靠性不足。相比之下,本文使用贝叶斯神经网络对模型和数据中存在的不确定性建模,利用粒子滤波模型对不确定性进行融合,得到了准确的 SOH 估计结果和可靠的不确定性量化结果。

本文的主要贡献如下:

1) 基于排列熵(permutation entropy, PE) 方法定量表

征卫星锂离子电池各 HI 的单调趋势和信息量,结合主成分分析法 (principal component analysis, PCA) 实现 HI 的选取和冗余消除,最终用于建模的特征在多工况下具有更好的有效性和适应性。

2) 利用 BNN 模型构建特征空间到 SOH 空间的映射,将模型参数视为服从一定概率分布的随机变量,基于动态运行条件,不断调整并训练多个可行模型。分别对 SOH 进行估计并得到结果的概率分布以量化不确定性。同时,通过 PF 模型对不确定性进行融合,降低测量噪声的影响,得到优化的不确定性,且估计精度不低于其他模型。

本文的其余部分组织如下:第 1 节介绍了基于 BNN-PF 的 SOH 估计框架以及多工况下 HI 的选取和概率性 SOH 建模方法,第 2 节介绍了实验结果和分析,第 3 节给出了本文的总结。

1 算法和模型介绍

本文的两个主要贡献是多工况下卫星锂离子电池 HI 的选取和优化以及 SOH 估计和不确定性量化。本节介绍了本文所提方法的理论基础,包括基于 PE-PCA 方法的 HI 选取和优化,以及基于 BNN-PF 的 SOH 估计和不确定性量化方法。本文提出的基于 BNN-PF 的卫星锂离子电池 SOH 估计框架如图 1 所示。




图 1 SOH 估计方法的总体框图

Fig. 1 Schematic of the proposed SOH estimation approach

本文提出的 SOH 估计方法分为 3 个部分实现。第 1 部分从在轨可测参数中提取多种 HI, 结合 PE 方法和 PCA 方法对 HI 进行选取和优化, 以获得多工况下最有效的特征。第 2 部分将多工况下的不确定性引入网络参数, 将参数分布纳入模型, 通过 BNN 模型构建特征空间到 SOH 空间的非线性映射, 得到 SOH 估计结果和置信区间表示。第 3 部分基于 PF 模型融合 BNN 模型和容量退化模型的不确定性, 得到优化后的不确定性。通过文章提出的 BNN-PF 模型可以获得更可靠的 SOH 估计结果和不确定性。

1.1 多工况下 HI 的选取与优化

在空间应用场景下, 随着卫星任务的调整, 电池放电策略不断变化, 而充电策略通常保持不变。由于充电曲线相对稳定, 且充电数据的历史依赖性能有效反映卫星锂离子电池的电化学反应, 因此本文只从充电过程中提取 HI。

本文结合在轨可测参数的变化规律, 从卫星锂离子电池充电数据中提取了 12 个可表征性能退化的指标: 恒流充电时间 (constant current charging time, CCCT)、恒压充电时间 (constant voltage charging time, CVCT)、等充电电压升的时间间隔 (time interval of equal charge voltage rise, TIE-CVR)、等充电电流降的时间间隔 (time interval of equal charge current drop, TIE-CCD)、等充电电压升的充电容量升 (charge capacity rise of equal charge voltage rise, CCR-CVR)、等充电容量升的充电电压升 (charge voltage rise of equal charge capacity rise, CVR-CCR)、电压标准差 (voltage standard deviation, VSTD)、电压均方根值 (voltage root-mean-square value, VRMS)、电压曲线最大斜率 (maximum slope of voltage curve, MSV)、电流曲线最大梯度 (maximum gradient of current curve, MGC)、电压样本熵 (voltage sample entropy, VSE) 和电流样本熵 (current sample entropy, CSE)。根据各 HI 的提取机制, 可将其分类如表 1 所示。

表 1 健康因子分类

Table 1 Health indicator classification		
	健康因子	变量名称
基于时间	CCCT	H_{CCCT}
	CVCT	H_{CVCT}
	TIE-CVR	$H_{TIE-CVR}$
	TIE-CCD	$H_{TIE-CCD}$
	CCR-CVR	$H_{CCR-CVR}$
基于电压	CVR-CCR	$H_{CVR-CCR}$
	VSTD	H_{VSTD}
	VRMS	H_{VRMS}
	MSV	H_{MSV}
基于斜率	MGC	H_{MGC}
	VSE	H_{VSE}
基于热力学	CSE	H_{CSE}

恒流充电时间直接表征可充电容量, 反映了电池极化情况, 随着电池的退化, 极化现象逐渐加剧, CCCT 值随之降低。恒压充电模式用来消除恒流充电产生的极化现象, 随着电池的退化, 锂嵌入过程更加困难, CVCT 值随之增加。因此, CCCT 和 CVCT 可作为表征 SOH 的退化特征^[25]。由于旧电池的电压上升速率更高, 在初始电压相同的情况下, 充电电压上升相同值所需的时间更短^[26]。同时, 由于容量是特定时间间隔内的电流积分, 所以等充电电压上升的充电容量上升与等充电电压上升的时间间隔相等。因此, CCR-CVR 和 TIE-CVR 可用于电池退化建模。由于容量与时间间隔的关系, 充电容量相同意味着恒流充电阶段的时间间隔相同。随着电池性能的退化, 充电电压会随着等充电容量的增大而增大。因此, CVR-CCR 也可作为 SOH 估计的指标。由于充电过程中内阻增大, 容量减小, 电压斜率增大, 因此电压曲线的最大斜率可以作为 SOH 估计的指标。标准差和均方根值描述了电压曲线的波动和分散, 因此这两个指标可以间接地估计 SOH。样本熵表征了时间序列的无序程度, 电压和电流数据序列的样本熵在一定程度上可以反映热力学系统变化对电池的影响。因此, 电压和电流的样本熵可以作为退化特征。考虑到卫星在轨运行中电池放电深度相对固定的情况, 若某个循环的 HI 曲线无法提取, 可忽略该循环, 从下一个循环继续提取 HI。

本文采用 PE-PCA 方法实现了 HI 的选取和优化。首先根据 PE 值对 12 个 HI 进行排序, HI 的 PE 值越小, 表明该 HI 的单调趋势越大, 包含的退化信息越多。然后, 根据 PE 值由低到高将 HI 依次增加进行一系列 PCA 融合和 PE 测试。最后, 选择最小 PE 值对应的融合特征作为 SOH 估计模型的输入。多工况下卫星锂离子电池 HI 的选取和优化过程如图 2 所示。




图 2 健康因子的选取和优化过程

Fig. 2 Schematic of HI selection and optimization

不同 HI 所包含的容量退化信息是不同的, 选取最有效的特征作为模型输入, 可以减少数据预处理时间, 提高模型的估计性能并降低估计结果的不确定性。

PE 方法通过相邻数据的顺序关系分析时序数据复杂性, 并将概率赋给有序模式。该方法只关注构造的状态向量的数值比较, 不考虑其他复杂的运算, 能够克服噪

声对时序分析结果的影响。本文利用 PE 方法定量挖掘卫星锂离子电池各 HI 中包含的整体单调趋势,比较各维度感知数据中包含的退化信息量。高熵值表示时间序列数据相似度恒定,包含的信息较少;低熵值表示无序和不规则,HI 包含更多的信息。因此具有更显著单调趋势的特征包含更多退化信息,可作为多工况下 SOH 估计模型的输入。PE 方法包括 4 个步骤:

1) 将每个 HI 视作一个一维时间序列数据,以恒流充电时间数据序列 $H_{CCCT} = \{x(t)\}, t = 1, 2, \dots, n$ 为例,其中 t 为卫星锂离子电池的循环次数,将其映射到 d 维相空间进行重构,得到 K 行 d 列的相空间矩阵即:

$$A_{K,d} = \begin{bmatrix} x(1) & x(1+\tau) & \cdots & x(1+(d-1)\tau) \\ \vdots & \vdots & \vdots & \vdots \\ x(j) & x(j+\tau) & \cdots & x(j+(d-1)\tau) \\ \vdots & \vdots & \vdots & \vdots \\ x(K) & x(K+\tau) & \cdots & x(K+(d-1)\tau) \end{bmatrix} \quad (1)$$

其中, d 表示嵌入维数, τ 表示延迟时间, K 表示状态向量的个数,矩阵中的每一行为一个状态向量。相空间矩阵中存在 $K = n - (d-1)\tau$ 个状态向量;

2) 比较相空间矩阵中的各状态向量 $[x(l), x(l+\tau), \dots, x(l+(d-1)\tau)]$, 对于每个状态向量可得到一个符号序列:

$$\pi_l = [j_1, j_2, j_3, \dots, j_d] \quad (2)$$

其中, l 表示状态向量索引, π_l 满足:

$$\begin{aligned} x(l+(j_1-1)\tau) &\leq x(l+(j_2-1)\tau) \\ &\leq x(l+(j_3-1)\tau) \\ &\leq \cdots \leq x(l+(j_d-1)\tau) \end{aligned} \quad (3)$$

因此可得到相空间矩阵对应的排列矩阵:

$$\pi = [\pi_1, \pi_2, \dots, \pi_{n-(d-1)\tau}]^T \quad (4)$$

3) 计算每个状态向量对应的排列 π_l 的相对概率:

$$p(\pi_l) = \frac{T}{n - (d-1)\tau} \quad (5)$$

其中, T 代表相应排列的个数;

4) 用相对概率计算各 HI 的排列熵结果:

$$E(d) = - \sum_{i=1}^{d!} p(\pi_i) \log_2(p(\pi_i)) \quad (6)$$

本文采用了二阶排列熵方法,嵌入维数 $d=2$,延迟时间 $\tau=1$,每个 HI 都可以看作是一个一维时间序列数据集,利用 PE 方法分析数据的单调趋势,定量评价各 HI 包含的退化信息量,从而实现 HI 的选择。

卫星在轨可测参数间以及不同 HI 间存在复杂的相关性,其中的冗余信息不利于 SOH 快速估计。本文利用 PCA 算法剔除冗余数据,降低计算复杂度,为 SOH 估计模型提供更有效的输入特征,从而支持多工况下的 SOH 估计建模。

PCA 算法是一种用于特征提取的降维方法。该方法通过对原始数据矩阵内部结构关系的分析计算,生成一系列不相关的新变量。根据需要从中选择新的变量(主成分),其可以充分解释原始数据的变化。PCA 算法包括 4 个步骤:

1) 对于由卫星锂离子电池的 n 个 HI 组成的数据 $H = \{X_n\} = \{H_{CCCT}, H_{CVCT}, \dots\}$, 对数据集 $\{X_n\}$ 去中心化并计算得到协方差矩阵:

$$S = \frac{1}{n-1} X^{*T} X^* \quad (7)$$

其中, X^* 表示去中心化后的标准化数据矩阵;

2) 用特征值分解法求出协方差矩阵的特征值和特征向量:

$$S u_i = \lambda_i u_i \quad (8)$$

其中, u_i 表示特征向量, λ_i 表示特征值,且 $i = 1, 2, \dots, n$;

3) 对特征值从大到小进行排序,计算每个特征值的累积信息:

$$r_i = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i} \times 100\% \quad (9)$$

选取累积贡献率大于 98% 的前 k 个变量为主成分;

4) 将数据集投影到由所选特征向量构建的新空间中可知:

$$Y_k = X^* \times P \quad (10)$$

其中, P 是选定的 k 个特征值对应的特征向量矩阵, Y_k 表示由 n 个健康因子最终融合得到的降维数据序列。

采用 PCA 方法对所选 HI 进行优化,融合后的特征在多工况下具有更好的有效性和适应性。

1.2 基于 BNN 的 SOH 估计与不确定性量化

在卫星的电池管理系统中,多工况问题将导致模型和数据中的不确定性增加,最终导致卫星锂离子电池的 SOH 估计值与实际结果存在较大差异。退化评估模型需要量化由有限的数据可用性和多工况下退化过程的随机性和可变性所引起的相关不确定性,以避免 SOH 估计的置信度不足和过高。贝叶斯方法为使用后验假设推断量化不确定性提供了一个通用框架^[27]。在卫星锂离子电池的 SOH 估计中,衡量估计结果的不确定性和估计精度是同等重要的。

贝叶斯神经网络模型定义了模型参数的概率分布,将模型参数视为随机变量,通过概率分布对模型和数据中存在的不确定性进行量化,利用贝叶斯定理更新这些模型参数的概率分布,并对所有模型权重的似然进行积分,以量化 SOH 估计中的不确定性。本文采用基于 LSTM 的贝叶斯概率模型来构建估计模型,贝叶斯神经网络模型结构如图 3 所示。




图3 用于实现健康状态估计的 BNN 模型结构

Fig.3 Schematic of BNN model for SOH estimation

以 CCCT 序列 $\mathbf{X} = H_{CCCT} = \{x(t)\}, t = 1, 2, \dots, n$ 以及对应的 SOH 序列 $\mathbf{Y} = \{y(t)\}, t = 1, 2, \dots, n$ 为例,其中 $x(t)$ 和 $y(t)$ 表示第 t 循环的样本数据, n 表示循环次数。基于 BNN 模型的 SOH 估计可以表示为一个回归问题,回归模型 $y = f^w(x)$ 将特征空间和 SOH 空间联系在一起,其中 w 是模型的参数向量。考虑到多工况下由于可用数据不足的限制产生的认知不确定性,将确定性权重 w 替换为表示认知不确定性的概率权重,引入先验概率 $p(w)$,得到条件概率分布 $p(w|\mathbf{X}, \mathbf{Y})$ 为:

$$p(w|\mathbf{X}, \mathbf{Y}) = \frac{P(\mathbf{Y}|\mathbf{X}, w) \cdot p(w)}{p(\mathbf{Y}|\mathbf{X})} \quad (11)$$

参考式 (11), 通过训练将模型参数的先验概率 $p(w)$ 修正为分布区间更窄的后验概率 $p(w|\mathbf{X}, \mathbf{Y})$ 。

此外,使用似然分布 $p(y|x, w)$ 捕获 HI 的新样本数据和固定 w 所给出的随机不确定性。BNN 模型 $y = f^w(x)$ 可用于基于后验概率和似然分布的后续不确定性推理。当输入 HI 给定时,结合两种不确定性的输出估计结果可表示为:

$$p(y|x, \mathbf{X}, \mathbf{Y}) = \int p(y|x, w) p(w|\mathbf{X}, \mathbf{Y}) dw \quad (12)$$

参考式 (12), 积分由历史数据和基于新输入数据的更新数据计算得到。

由于 BNN 模型中模型参数较多,先验是非线性且非共轭的,变分推断可以解决式 (11) 中后验概率 $p(w|\mathbf{X}, \mathbf{Y})$ 较难计算的问题^[28]。该方法通过持续调整参数 θ 使变分分布近似于后验概率分布。KL 散度用于量化这两个分布之间的距离。由式 (11) 可得:

$$\begin{aligned} KL(q_\theta(w) \parallel p(w|\mathbf{X}, \mathbf{Y})) &= \\ \int q_\theta(w) \log \frac{q_\theta(w)}{p(w|\mathbf{X}, \mathbf{Y})} &= KL(q_\theta(w) \parallel p(w)) - \\ \int q_\theta(w) \log(p(\mathbf{Y}|\mathbf{X}, w)) dw & \end{aligned} \quad (13)$$

其中,第 1 项是变分分布 $q_\theta(w)$ 与先验概率分布 $p(w)$ 之间的 KL 散度,第 2 项是变分分布 $q_\theta(w)$ 的对数似然的期望值。通过调整变分参数使 $q_\theta(w)$ 近似 $p(w|\mathbf{X}, \mathbf{Y})$,并将近似的变分分布 $q_\theta(w)$ 代入式 (12) 中,最终可得到两种不确定性相结合模型输出结果。

1.3 基于 PF 的容量退化模型与 BNN 模型的不确定性融合

本节介绍了卫星锂离子电池的容量退化模型,并通过 PF 模型将其不确定性与 BNN 模型融合。卫星锂离子电池的 SOH 估计不仅依赖于当前的观测数据,还依赖于历史观测和系统的动态特性。PF 模型通过结合 BNN 模型对不确定性的量化能力以及容量退化模型对电池系统内部机理的解释能力,实现模型优势互补,基于 BNN 的观测数据和容量退化模型的预测数据,在动态条件下对 SOH 进行连续跟踪和更新,逐步优化状态估计,最终实现对观测数据中的噪声有效处理,降低 SOH 估计的不确定性,提高 SOH 估计的可信度。

粒子滤波是一种基于蒙特卡罗方法的贝叶斯状态估计算法,利用重要性采样得到的加权粒子集来近似未知状态的后验概率密度,其通过调整用于估计的粒子权值来更新状态,并用样本均值代替积分运算,得到状态的最小方差估计。基于粒子滤波的容量退化模型与 BNN 模型的不确定性融合过程如图 4 所示。

Saha 等^[29] 根据电池退化过程中的参数变化,建立了基于容量衰减的寿命退化模型,能较好地反映锂离子电池的退化情况。本文将该模型作为状态转换模型,将 BNN 模型作为观测模型,两者共同构成状态空间模型。利用 BNN 模型得到的 SOH 估计值和不确定性量化结果作为观测值和观测噪声,最终实现不确定性的融合,实现了更可靠的卫星锂离子电池 SOH 估计及其不确定性的表征。状态空间模型如式 (4) 所示。




图 4 不确定性融合过程

Fig. 4 Schematic of uncertainty fusion

$$\begin{cases} SOH_k = \eta_c SOH_{k-1} + \beta_1 \exp(-\beta_2 / \Delta t_{k-1}) + \varphi_{k-1} \\ \widetilde{SOH}_k = SOH_k + \psi_k \end{cases} \quad (14)$$

式中: k 为卫星锂离子电池充放电过程的循环周期, η_c 为库仑效率, Δt_k 为两个循环之间的休息时间, β_1 和 β_2 为待确定的模型参数, $\widetilde{SOH}_k$ 为第 k 次循环基于 BNN 模型的 SOH 估计结果, φ_k 为独立零均值噪声项。

基于 PF 的容量退化模型与 BNN 模型的不确定性融合流程如下: 1) 对 PF 模型参数进行初始化设定; 2) 基于状态转移模型中的递推方程对每个粒子的 SOH 进行预测; 3) 利用 BNN 模型的观测值和观测噪声对粒子的权重进行更新; 4) 通过归一化粒子的权重, 使其和为 1, 并根据权重对粒子进行重采样, 保留权重较高的粒子, 去除权重较低的粒子, 防止粒子退化; 5) 通过粒子的加权平均得到当前时间步的 SOH 估计值。计算粒子分布的方差, 作为 SOH 估计的不确定性度量; 6) 重复步骤 2) ~ 5), 不断更新系统状态, 直到得到所有的优化后的 SOH 估计结果和不确定性量化结果。

2 实验与分析

本节首先介绍了实验数据集的来源, 后采用两组实验来验证所提方法在多工况下的有效性。最后对比了本文模型与其他模型的实验结果。

2.1 实验数据集

本文使用哈尔滨工业大学提取的电池循环数据集来模拟卫星锂离子电池组在室温下的在轨运行模式。数据集是 DLG(上海) 电池有限公司生产的 18650 锂离子电池在室内环境(恒温 25℃)循环充放电获得的^[30]。电池循环试验在如图 5 所示的电池测试系统上完成。

在空间应用场景下, 卫星锂离子电池串并联成组后




图 5 电池测试系统

Fig. 5 Battery testing system

用作航天器电源系统部件, 正极材料多为层状结构正极材料, 包括 LiCoO_2 与三元材料 NCM、NCA 等。卫星锂离子电池长期处于相对恒定的环境温度下, 当在阴影区域或太阳电池阵能力无法满足负载需求时, 电池开始放电, 放电电流由负载功率决定, 且可近似地看作恒流放电。在日照期间, 电池由放电切换到充电, 充电过程采用恒流—恒压模式, 充电电流根据电池的健康状态进行调整。从充电结束到下一次地影期开始的这段时间为电池的搁置过程。

研究所用 18650 锂离子电池与卫星锂离子电池使用相同的三元材料作为正极, 因此, 两种电池的性能退化机理相似, 内部电化学性质差异较小。实验选取数据集中相同充电倍率、不同放电倍率的单体 1、单体 2、单体 3 三个电池来验证方法的有效性和可靠性, 各电池工况如表 2 所示。研究设计相同的温度来模拟空间应用场景下恒定的环境温度, 相同的充电电流来模拟卫星锂离子电池相同的充电条件, 并采用不同的放电电流来模拟卫星锂离子电池执行不同任务时的动态放电条件。因此, 实验所用电池的充放电过程可等效替代空间应用场景下卫星锂离子电池的工作模式, 实验结果也具有较高的可信度。在将电池单体串并联成组后, 单体间的不一致性会使电

池组退化过程变得复杂。但是,当前的 SOH 估计方法对于电池单体和电池组是通用的,作者将在未来的工作中进一步考虑电池组中不一致性的问题。

表 2 各电池对应工况

参数	单体 1	单体 2	单体 3
额定容量	2 200 mAh		
额定电压	3.6 V		
充电截止电压	4.2 V		
放电截止电压	2.7 V		
充电倍率	1.0 C	1.0 C	1.0 C
放电倍率	0.5 C	1.0 C	1.5 C

不同放电条件下锂离子电池的退化情况如图 6 所示。图 6 展示了不同放电条件下锂离子电池第 100、300、500 次循环的放电电压曲线,由图可知,放电倍率越大,锂离子电池的放电时间越短。




图 6 不同放电条件下的锂离子电池退化情况
Fig. 6 Lithium-ion battery degradation reflected in different discharge conditions

2.2 实验设计和评价指标

为了验证所提方法的有效性,本文分别以 HI 种类和概率性 SOH 估计方法为变量设计两组实验。

实验组 1 选取不同类型的 HI 作为退化评估模型的输入。对照组 1 选择单一 HI 作为 SOH 估计模型输入特征;对照组 2 根据 PE-PCA 方法选取不同类型的 HI 进行融合,作为模型输入特征。实验组 1 用来验证本文提出的基于 PE-PCA 的 HI 选取和优化方法在多工况下的有效性和适应性。

实验组 2 采用 PE-PCA 方法得到的融合特征作为 SOH 估计模型的输入,通过不同的非线性映射模型得到 SOH 估计和不确定性量化结果。对照组 1、2、3 分别通过 BNN 模型、RVM 模型、GPR 模型获得 SOH 估计和不确定性量化结果;对照组 4 通过 PF 模型融合基于对照组 1 的

不确定性和容量退化模型的不确定性,得到 SOH 估计和不确定性量化结果。实验组 2 用来验证本文提出的基于 BNN-PF 的概率性 SOH 估计方法的可靠性。

本文用 5 个指标来评价模型的估计精度和模型的不确定性。

1) 均方根误差 (root mean square error, RMSE): RMSE 表示锂离子电池 SOH 估计值与实际 SOH 值的均方根误差的算术平方根,它可以用来表示估计结果的准确性。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (SOH_{Prediction} - SOH_{True})^2}$$

(15)

2) 平均绝对误差 (mean absolute error, MAE): MAE 表示锂离子电池 SOH 估计值与实际 SOH 值的绝对误差的平均值,它可以用来表示估计结果的稳定性。

$$MAE = \frac{1}{N} \sum_{i=1}^N |SOH_{Prediction} - SOH_{True}|$$

(16)

3) 相对误差 (relative error, RE): RE 表示锂离子电池 SOH 估计值与实际 SOH 值的绝对误差之比,它可以用来表示估计结果的可靠性。

$$RE = \frac{|SOH_{Prediction} - SOH_{True}|}{SOH_{True}}$$

(17)

4) 预测区间覆盖概率 (prediction interval coverage probability, PICP): PICP 表示 SOH 实际值落在 SOH 估计值置信区间范围内的比例,它可以用来评价不确定区间的可靠性。

$$PICP = \frac{1}{N} \sum_{i=1}^N c_i$$

(18)

其中, N 为预测样本数, c_i 为布尔值,当置信区间包含实际 SOH 值时记为 1,否则记为 0。本文中设置 95% 的置信区间来量化 SOH 估计结果的不确定性。

5) 预测区间归一化平均宽度 (prediction interval normalized average width, PINAW): PINAW 表示 SOH 估计值的置信区间的宽度,它可以表征置信区间太宽而不能给出有效不确定性信息的问题。

$$PINAW = \frac{1}{NR} \sum_{i=1}^N SOH_{upper} - SOH_{lower}$$

(19)

式中: SOH_{upper} , SOH_{lower} 为置信区间的上界和下界, R 为用于归一化的实际 SOH 值的范围。

2.3 实验结果和讨论

实验组 1 中,对照组 1 各单一 HI 的 PE 计算结果及排序结果如表 3 所示。对照组 2 中不同种类的 HI 经 PCA 融合后的 PE 结果和 Pearson 结果如表 4 所示。

由表 3 可得,各 HI 在多工况下的 PE 值排序结果不同,即各 HI 在多工况下包含的退化信息不同,对电池性能退化的表征能力具有较大差异。TIE-CCD 特征在多种工况下都可计算得到较小的 PE 值,在多种 HI 中 PE 值

表 3 各 HI 的 PE 结果和排序结果

Table 3 The PE results and ordering results of each HI

HI	单体 1		单体 2		单体 3	
	PE	排序 结果	PE	排序 结果	PE	排序 结果
TIE-CCD	0.805 1	1	0.856 8	1	0.839 2	2
CCCT	0.826 6	2	0.899 6	4	0.894 6	5
VRMS	0.836 8	3	0.892 1	3	0.892 9	3
CVR-CCR	0.863 1	4	0.880 3	2	0.807 8	1
CCR-CVR	0.882 8	5	0.923 7	5	0.922 7	6
CVCT	0.935 1	6	0.938 8	6	0.892 9	4
VSTD	0.946 7	7	0.964 9	7	0.972 5	7
TIE-CVR	0.977 2	8	0.988 9	8	0.979 5	8
MGC	0.998 7	9	0.994 9	9	0.982 3	9
MSV	0.999 2	10	0.996 7	10	0.999 9	12
VSE	0.999 9	11	0.999 9	11	0.999 9	11
CSE	0.999 9	12	0.999 9	12	0.999 9	10

表 4 不同数量的 HI 经 PCA 融合后的 PE 和 Pearson 结果

Table 4 The PE and Pearson results after PCA fusion for different amounts of HI

数量	PE			Pearson		
	单体 1	单体 2	单体 3	单体 1	单体 2	单体 3
2	0.731 5	0.997 9	0.975 7	-0.995 8	-0.929 3	0.813 2
3	0.763 9	0.989 5	0.984 9	-0.995 6	-0.929 3	-0.813 0
4	0.748 0	0.981 4	0.953 1	-0.995 8	0.921 6	-0.961 9
5	0.763 9	0.969 0	0.912 3	0.995 4	0.830 1	-0.972 1
6	0.805 1	0.786 1	0.788 3	-0.993 5	-0.996 1	-0.997 2
7	0.799 5	0.774 7	0.800 6	-0.993 5	-0.996 1	0.997 2
8	0.779 1	0.813 2	0.861 7	0.997 0	0.996 2	0.999 1
9	0.779 1	0.808 0	0.915 3	0.997 0	0.996 2	-0.999 1
10	0.805 1	0.813 2	0.861 7	0.997 3	0.996 2	0.999 1
11	0.805 1	0.810 6	0.933 7	0.997 3	0.996 2	0.999 0
12	0.779 1	0.808 0	0.936 3	0.997 0	0.996 2	0.999 1

排序结果分别为第 1、第 1、第 2,即 TIE-CCD 特征在多工况下都包含较多的退化信息,对性能退化的表征能力在多工况下具有较好的适应性。MSV、VSE、CSE 特征在多工况下的 PE 值较大,均接近 1,即特征包含较少的退化信息,且对多工况的适应能力较差,计算其 Pearson 相关系数,结果大于 0.80,因此,该特征与电池退化具有较大的相关性。对比表 3 和 4 的 PE 结果,3 个电池单一 HI 的最小 PE 值分别为 0.805 1 bit、0.856 8 bit 和 0.807 8 bit,最大 PE 值为 0.999 9 bit。各电池经 PE 方法分别选取 2、7 和 6 个 HI 经 PCA 方法融合得到的特征的 PE 值分别为 0.731 5 bit、0.774 7 bit 和 0.788 3 bit,PE 值比任何单一的 HI 都低,即各电池经 PE-PCA 方法选取和优化得到的特征在多种工况下具有更多的退化信息。与其他单一 HI 相比,基于 PE-PCA 方法得到的特征可以作为多工况下表征电池性能退化的指标,且作为退化评估模型的输入用来估计 SOH 将获得相对较好的精度和稳定性。

此外,由表 4 可得,计算各电池融合特征的 Pearson 相关系数,结果均大于 0.80,可验证经 PE-PCA 方法得到的特征与 SOH 退化曲线具有较大的相关性。多工况下各电池经 PE-PCA 方法选取和优化得到的特征的变化曲线和各电池 SOH 退化曲线如图 7 所示。




图 7 不同电池的融合特征和 SOH 曲线

Fig. 7 Fused HI and SOH fade of each cell

实验组 2 不同非线性映射模型得到的 SOH 估计结果和不确定性量化结果以及相对误差如图 8 所示。不同模型对 SOH 估计和不确定性量化结果的 RMSE、MAE、PICP、PINAW 评价指标如图 9 所示。

由图 8 不同模型 SOH 估计结果的相对误差变化曲线可以看出,各模型的相对误差均小于 2%,说明各模型具有较好的可靠性。对比图 9 各模型的 RMSE 和 MAE 指标可得,基于 BNN-PF 模型的 SOH 估计结果的 RMSE 和 MAE 均不低于其他模型,与其他模型相比,该模型具有较好的估计精度和较高的稳定性。

结合图 8 各模型的不确定性量化结果与图 9 的不确定性评价指标 PICP、PINAW 对比结果,可以得出:在 RVM 模型的评价结果中,置信区间覆盖了所有的实际 SOH 结果, PICP 最高,占比为 100%,而 PINAW 为 0.259 6,其置信区间宽度远远大于其他模型。这可能是由于噪声的干扰使得稀疏先验分布在选择支持向量时过于保守或者由于方法导致的过拟合问题,最终使得估计结果的不确定性增加,置信区间变宽。在 GPR 模型的评价结果中,PINAW 最低,为 0.021 2,说明置信区间较窄。但是,PICP 值低于其他模型,在 95%置信水平下不满足 PICP 要求。过宽或过窄的置信区间不能为决策者提供任何有意义的信息,可能导致卫星电池管理中的风险和地面操作人员的误导性决策。与 RVM 和 GPR 模型相比,BNN 和 BNN-PF 模型获得的不确定性量化结果更接近 95%置信水平,且置信区间的宽度更为适宜。综合考虑,多工况下基于 BNN-PF 模型实现的不确定性量化结果具有较高的可靠性。结合图 8 不同模型的 SOH 估计和不确定性量化结果和图 9 的指标评价结果,实验组 2




图 8 基于不同模型的 SOH 估计结果和不确定性量化结果(单体 1~单体 2)

Fig. 8 SOH estimation and uncertainty quantification results based on different models (Cell1~Cell2)




图 9 不同模型所得结果的评价指标(单体 1~单体 2)

Fig. 9 Evaluation for results of different models (Cell1~Cell2)

证明了本文基于 BNN-PF 模型的 SOH 估计和不确定性量化具有较好的准确性和可靠性。

基于本文提出的方法对多工况下锂离子电池的交叉验证试验结果的评价如表 5 所示。

表 5 不同交叉验证试验结果的评价指标

Table 5 Evaluation of different cross-validation test results

	RMSE	MAE	PICP	PINAW
单体 1~单体 2	0.001 9	0.001 4	0.970 3	0.042 2
单体 1~单体 3	0.002 3	0.001 4	0.985 3	0.038 3
单体 2~单体 1	0.002 0	0.001 5	0.958 8	0.038 9
单体 2~单体 3	0.002 2	0.001 3	0.983 8	0.039 1
单体 3~单体 1	0.005 8	0.004 4	0.869 4	0.067 0
单体 3~单体 2	0.005 6	0.004 5	0.828 4	0.067 4

由表 5 可得,基于本文所提 BNN-PF 框架得到的 SOH 估计结果,其 RMSE 和 MAE 指标均低于平均水平,不确定性量化结果的 PICP 指标均高于 80%,PINAW 指标均低于 0.1。本文所提方法可有效提高多工况下的 SOH 估计和不确定性量化的准确性和可靠性。

3 结 论

本文提出了一种基于 BNN-PF 的多工况卫星锂离子电池 SOH 估计方法。该方法通过三部分实现:首先,基于在轨可测参数提取 12 个 HI,采用 PE-PCA 方法对各类 HI 进行了选取和优化,融合后的特征的 PE 结果均低于 0.80 bit,也低于大多数单一 HI,并且含有更多的退化信息。研究结果表明,基于 PE-PCA 方法选取和优化得到的特征在多种工况下具有较高的适应性。然后,将融合后的特征作为模型输入,利用基于 LSTM 的贝叶斯神经网络模型实现多工况下的 SOH 估计和不确定性量化。结果证明,基于 BNN 模型的 SOH 估计结果的准确性和稳定性不低于其他模型,不确定性量化结果的可靠性优于其他浅层机器学习方法。最后通过 PF 模型融合了容量衰退模型的不确定性。实验结果表明,基于 BNN-PF 方法的 SOH 估计结果和不确定性量化结果具有较高的精度、稳定性和可靠性。综合两个实验组的研究结果,本文方法可用于多工况下卫星锂离子电池的概率性 SOH 估计,估计结果具有较高的精度和鲁棒性,同时可提供可靠的不确定性量化结果。

在未来,研究将考虑显著影响卫星锂离子电池性能

退化的耦合电应力参数。通过耦合电应力条件下卫星锂离子电池性能退化的等效迁移建模,提高多工况下的 SOH 估计精度。

参考文献

- [1] SONG Y, PENG Y, LIU D. Model-based health diagnosis for lithium-ion battery pack in space applications [J]. IEEE Transactions on Industrial Electronics, 2020, 68(12): 12375-12384.
- [2] 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.
- [3] YANG Y. A machine-learning prediction method of lithium-ion battery life based on charge process for different applications [J]. Applied Energy, 2021, 292: 116897.
- [4] HU X, XU L, LIN X, et al. Battery lifetime prognostics[J]. Joule, 2020, 4(2): 310-346.
- [5] WANG Z, ZHENG M, GUO J, et al. Uncertain UAV ISR mission planning problem with multiple correlated objectives[J]. Journal of Intelligent & Fuzzy Systems, 2017, 32(1): 321-335.
- [6] TELIZ E, ZINOLA C F, DIAZ V. Identification and quantification of ageing mechanisms in Li-ion batteries by Electrochemical impedance spectroscopy[J]. Electrochimica Acta, 2022, 426: 140801.
- [7] WEN J, ZOU Q, CHEN C, et al. Linear correlation between state-of-health and incremental state-of-charge in Li-ion batteries and its application to SoH evaluation[J]. Electrochimica Acta, 2022, 434: 141300.
- [8] 刘大同, 宋宇晨, 武巍, 等. 锂离子电池组健康状态估计综述[J]. 仪器仪表学报, 2020, 41(11): 1-18.
LIU D T, SONG Y CH, WU W, et al. Review of state of health estimation for lithium-ion battery pack [J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 1-18.
- [9] 汪宇航, 黄海宏, 王海欣, 等. 基于荷电状态差异的退役电池健康状态快速估计研究[J]. 仪器仪表学报, 2023, 44(12): 55-68.
WANG Y H, HUANG H H, WANG H X, et al. Research on fast estimation of the state of health of retired batteries based on the state of charge differences[J]. Chinese Journal of Scientific Instrument, 2023, 44(12): 55-68.
- [10] LI Y, SHENG H, CHENG Y, et al. State-of-health estimation of lithium-ion batteries based on semi-supervised transfer component analysis [J]. Applied Energy, 2020, 277: 115504.
- [11] 丁同, 傅晓锦. 基于改进粒子群优化算法和极限学习机的锂离子电池健康状态预测[J]. 国外电子测量技术, 2023, 42(5): 163-173.
DING T, FU X J. Improved particle swarm optimization and an extreme learning machine are used to predict the health state of lithium-ion batteries [J]. Foreign Electronic Measurement Technology, 2023, 42(5): 163-173.
- [12] 郑雪莹, 邓晓刚, 曹玉苹. 基于能量加权高斯过程回归的锂离子电池健康状态预测[J]. 电子测量与仪器学报, 2020, 34(6): 63-69.
ZHENG X Y, DENG X G, CAO Y P. State of health prediction of lithium-ion batteries based on energy-weighted Gaussian process regression [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(6): 63-69.
- [13] 李强龙, 孙建瑞, 赵坤, 等. 基于 IALO-SVR 的锂电池健康状态预测[J]. 电子测量与仪器学报, 2022, 36(1): 204-211.
LI Q L, SUN J R, ZHAO K, et al. Prediction for the state of health of lithium-ion batteries based on IALO-SVR [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 204-211.
- [14] 郭敏, 张浩. 基于改进 Bi-LSTM 网络下的多时变状态锂电池剩余寿命预测方法[J]. 国外电子测量技术, 2023, 42(10): 59-68.
GUO M, ZHANG H. Remaining useful life prediction method of lithium-ion battery in multiple time-varying states based on an improved Bi-LSTM network [J]. Foreign Electronic Measurement Technology, 2023, 42(10): 59-68.
- [15] ZHU Y, LI X, ZHANG Y, et al. Cross-domain prognostic method of lithium-ion battery in new energy electric aircraft with domain adaptation [J]. IEEE Sensors Journal, 2023.
- [16] 张朝龙, 罗来劲, 刘惠汉, 等. 基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计[J]. 电子测量与仪器学报, 2023, 37(1): 167-176.
ZHANG CH L, LUO L J, LIU H H, et al. State of health estimation of Lithium-ion batteries based on incremental energy analysis and BiGRU-Dropout [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 167-176.
- [17] KHAN S, YAIRI T. A review on the application of deep learning in system health management[J]. Mechanical

- Systems and Signal Processing, 2018, 107: 241-265.
- [18] SANKARARAMAN S. Significance, interpretation, and quantification of uncertainty in prognostics and remaining useful life prediction[J]. Mechanical Systems and Signal Processing, 2015, 52: 228-247.
- [19] HULLERMEIER E, WAEGERMAN W. Aleatoric and epistemic uncertainty in machine learning: An introduction to concepts and methods[J]. Machine Learning, 2021, 110: 457-506.
- [20] SONG Y, LIU D, PENG Y. Data-driven on-line health assessment for lithium-ion battery with uncertainty presentation[C]. 2018 IEEE International Conference on Prognostics and Health Management (ICPHM). IEEE, 2018: 1-7.
- [21] LIU D, PANG J, ZHOU J, 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.
- [22] ZHANG S, LIU Z, SU H. State of health estimation for lithium-ion batteries on few-shot learning[J]. Energy, 2023, 268: 126726.
- [23] KE Y, LONG M, YANG F, et al. A Bayesian deep learning pipeline for lithium-ion battery SOH estimation with uncertainty quantification [J]. Quality and Reliability Engineering International, 2024, 40(1): 406-427.
- [24] LAKSHMINARAYANAN B, PRITZEL A, BLUNDELL C. Simple and scalable predictive uncertainty estimation using deep ensembles[J]. CoRR, 2016, abs/1612.01474.
- [25] 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[J]. Journal of Power Sources, 2018, 384: 387-395.
- [26] LIU D, SONG Y, LI L, et al. On-line life cycle health assessment for lithium-ion battery in electric vehicles[J]. Journal of Cleaner Production, 2018, 199: 1050-1065.
- [27] GAL Y, GHAHRAMANI Z. Dropout as a Bayesian approximation: Representing model uncertainty in deep learning [C]. International Conference on Machine Learning, PMLR, 2016: 1050-1059.
- [28] BLEI D M, KUCUKEIBIR A, MCAULIFFE J D. Variational inference: A review for statisticians [J]. Journal of the American statistical Association, 2017, 112(518): 859-877.
- [29] SAHA B, GOEBEL K. Modeling Li-ion battery capacity depletion in a particle filtering framework [C]. Annual Conference of the PHM Society, 2009, 1(1).
- [30] SONG Y, LIU D, LIAO H, et al. A hybrid statistical data-driven method for on-line joint state estimation of lithium-ion batteries[J]. Applied Energy, 2020, 261: 114408.

作者简介



潘大为, 2012 年于哈尔滨工业大学获得博士学位, 现为哈尔滨工程大学助理教授, 主要研究方向为自动测试技术和系统健康管理。

E-mail: pandawei@hrbeu.edu.cn

Pan Dawei received his Ph. D. degree from Harbin Institute of Technology (HIT) in 2012. Now he is an Assistant Professor in Harbin Engineering University. His main research interests include automatic test technologies and system health management.



师杰, 2021 年于哈尔滨工程大学获得学士学位, 现为哈尔滨工程大学硕士研究生, 主要研究方向为锂离子电池状态估计和寿命预测。

E-mail: sjyezuiyu@hrbeu.edu.cn

Shi Jie received his B. Sc. degree from Harbin Engineering University in 2021. Now he is a M. Sc. candidate in Harbin Engineering University. His main research interests include lithium-ion battery state estimation and lifetime prediction.



宋宇晨 (通信作者), 2021 年于哈尔滨工业大学获得博士学位, 现为哈尔滨工业大学助理教授, 主要研究方向为空间电源系统在线健康诊断和预测、锂离子电池组感知、状态监测和高性能电池管理系统。

E-mail: songyuchen@hit.edu.cn

Song Yuchen (Corresponding author) received his Ph. D. degree from Harbin Institute of Technology (HIT) in 2021. Now he is an Assistant Professor in Harbin Institute of Technology. His main research interests include space power system online health diagnosis and prognosis, lithium-ion battery pack sensing, state monitoring, and high-performance battery management systems.