

# 基于IMM-PFF的锂离子电池剩余寿命预测

王帅<sup>1</sup>, 李义婷<sup>1\*</sup>, 陈黎飞<sup>1</sup>, 苏小红<sup>2</sup>, 周寿斌<sup>3</sup>

(1. 福建师范大学计算机与网络空间安全学院, 福建福州 350117; 2. 哈尔滨工业大学计算学部, 黑龙江哈尔滨 150001;  
3. 华富储能新技术股份有限公司, 江苏扬州 225699)

**摘要:** 针对单一容量衰退模型在锂离子电池剩余寿命(Remaining Useful Life, RUL)预测中工况泛化能力不足的问题, 本文提出一种基于交互式多模型粒子流滤波(Interactive Multiple Model Particle Flow Filter, IMM-PFF)的预测方法. 通过粒子流滤波对指数、多项式和生物模型进行协同状态估计, 并基于交互式多模型框架动态融合多模型预测结果, 从而自适应匹配电池衰退的多阶段特性. 将美国NASA、马里兰大学等不同工况的锂离子电池退化数据集划分为3个时期, 对本文的方法进行验证. 结果表明, 相比单一模型粒子滤波方法, IMM-PFF的容量预测均方根误差和剩余寿命预测误差分别降低24.3%和4.5%, 为复杂工况下的锂离子电池寿命预测提供了高精度、强鲁棒性的新思路.

**关键词:** 锂离子电池; 剩余寿命; 粒子流滤波; 交互式多模型; 状态估计

**基金项目:** 福建省自然科学基金(No.2023J01297); 国家自然科学基金(No.U1805263)

**中图分类号:** TP206+3

**文献标识码:** A

**文章编号:** 0372-2112(2025)05-1520-13

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20241130

## Remaining Useful Life Prediction of Lithium-Ion Batteries Based on IMM-PFF

WANG Shuai<sup>1</sup>, LI Yi-ting<sup>1\*</sup>, CHEN Li-fei<sup>1</sup>, SU Xiao-hong<sup>2</sup>, ZHOU Shou-bin<sup>3</sup>

(1. College of Computer and Cyber Security, Fujian Normal University, Fuzhou, Fujian 350117, China;

2. Faculty of Computing, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China;

3. Huafu High Technology Energy Storage Co., Ltd., Yangzhou, Jiangsu 225699, China)

**Abstract:** To address the limited generalization capability of single capacity degradation models in predicting the remaining useful life (RUL) of lithium-ion batteries under varying operating conditions, this paper proposes a prediction method based on the interactive multiple model particle flow filter (IMM-PFF). The method employs particle flow filter to collaboratively estimate the states of exponential, polynomial, and Verhulst models, and dynamically integrates multi-model predictions within an interactive multiple model framework, thereby adaptively matching the multi-phase characteristics of battery degradation. Experimental validation is conducted using lithium-ion battery degradation datasets (NASA and CALCE) under diverse operating conditions, which are divided into three distinct degradation phases. Results demonstrate that compared to single-model particle filter methods, the IMM-PFF reduces the root mean square error (RMSE) of capacity prediction and the absolute RUL prediction error by 24.3% and 4.5%, respectively. This study provides a novel high-precision and highly robust framework for lithium-ion batteries lifespan prediction in complex operational scenarios.

**Key words:** lithium-ion battery; remaining useful life; particle flow filter; interactive multiple models; state estimation

**Foundation Item(s):** Natural Science Foundation of Fujian Province (No.2023J01297); National Natural Science Foundation of China (No.U1805263)

## 1 引言

由于锂离子电池在性能上具有高能量密度、低自放电率和长循环寿命等优点, 已跃居为现代便携式电

子设备与可再生能源系统中的核心部件, 广泛应用于电动汽车、电子设备和储能系统等领域<sup>[1]</sup>. 然而, 随着使用时间的延长, 锂离子电池不可避免地会经历性能退化, 导致电池容量的衰减和使用寿命的缩短<sup>[2]</sup>. 因

此,精准预测锂离子电池的剩余使用寿命(Remaining Useful Life, RUL)成为确保设备安全性、提升运行可靠性及优化经济性的关键环节<sup>[3,4]</sup>。在电源管理系统(Battery Management System, BMS)架构中,剩余寿命预测的重要性不言而喻。它不仅能够促进电池使用的最优化策略,还能通过前瞻性预警机制有效防范潜在的安全风险<sup>[5]</sup>。现有电池寿命预测方法主要分为模型驱动方法、数据驱动方法以及结合这二者的混合方法。

模型驱动方法主要依赖于对电池内部反应的深刻理解,包括电化学反应、材料特性、温度、电流等电池运行状态变量,建立能够反映系统性能退化物理规律的数学模型<sup>[6]</sup>。模型驱动的 RUL 预测方法可分为 3 类:等效电路模型、退化机理模型和经验模型。宋胜等人<sup>[7]</sup>在二阶 RC 等效电路的基础上,提出一种基于锂电池片段数据的联合荷电状态(State Of Charge, SOC)估计算法,解决针对单一算法在不同工况下的锂电池片段 SOC 估计精度低的问题,但算法在早期的区间估计不准确。Zhang 等人<sup>[8]</sup>通过推导老化代表与输入电流历史之间的传递函数关系,提出一种考虑副反应的锂离子电池定量电化学老化模型。经验退化模型从数据的角度出发,寻求采集数据(包括电容、电压等)随时间的变化规律,相较于前 2 类模型,这种数学模型更易于获取,但是缺少理论支撑,常见的经验退化模型包括指数退化模型、对数退化模型、高斯退化模型、集成模型等。王菲等人<sup>[9]</sup>提出融合粒子滤波和高斯过程回归对双指数退化模型的参数进行估计,解决锂离子电池在退化过程中出现的容量再生问题。李彦梅等人<sup>[10]</sup>提出一种双高斯模型用于描述锂离子电池老化过程,经实验对比,模型的预测误差得到明显改善,但需要识别 6 个模型参数。

数据驱动方法通常无须对电池的内部退化机制进行深入研究,主要基于电池电流、电压、温度等信息,构造退化数据与健康状态之间的映射关系,实现电池 RUL 预测。目前依靠机器学习和深度学习算法进行预测已成为主流。Liu 等人<sup>[11]</sup>提出一种基于改进的麻雀搜索算法优化的长短期记忆网络的锂离子电池 RUL 预测方法,实现 RUL 预测。王萍等人<sup>[12]</sup>利用高斯过程回归建立老化模型进行健康状态(State Of Health, 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)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,但该方法尚未在其他电池或更为复杂工况下进行验证。Wang 等人<sup>[13]</sup>从充电和放电阶段的电池电压和温度数据中获得原始特征,引入最小冗余最大相关算法来选择最优特征集,构建基于多核相关向量机(Relevance Vector Machine, RVM)和鲸鱼优化算法(Whale Optimization Algorithm, WOA)的混合模型来预测锂离子电池

的 SOH。基于滤波的电池 RUL 预测方法是电池管理系统的主要方法之一。滤波技术主要是通过建立的状态方程和观测方程对电池健康状态进行动态跟踪和预测。常用的滤波算法为卡尔曼滤波(Kalman Filter, KF)、粒子滤波(Particle Filter, PF)以及二者的改进算法<sup>[14,15]</sup>。实际应用中,由于采用 PF 结合经验退化模型可提供预测结果的概率分布且适应非线性及非高斯的状态预测,得到广泛应用<sup>[16]</sup>。然而,标准 PF 在运行过程中不可避免地陷入粒子退化困境。近年来研究者主要从重要性函数的选择和重采样算法的优化 2 个方面 PF 算法进行改进。Zhang 等人<sup>[17]</sup>提出基于线性优化组合重采样的无迹粒子滤波器,无迹卡尔曼滤波器用于生成作为粒子滤波重要性函数的建议分布,线性优化组合重采样算法来克服粒子多样性的不足。Jiao 等人<sup>[18]</sup>采用条件变分自编码代替先验分布减少粒子退化,采用二次权值方法防止粒子多样性丧失,提升电池 RUL 预测精度。数据驱动方法通过学习大量历史数据中的退化规律,能够在一定程度上提高预测精度。然而,这类方法高度依赖充足且高质量数据的标注,模型的泛化能力往往受限于训练数据的多样性。由于电池退化过程的高度非线性特性,机器学习方法在处理复杂问题时易陷入过拟合或欠拟合的风险,影响预测结果的稳健性<sup>[19]</sup>。

尽管当前研究在锂离子电池寿命预测领域取得一定成就,但仍面临多重挑战。一方面,大部分文献利用传统模型驱动方法是以单一模型去做锂离子电池 RUL 预测,得到的预测结果比较单一,预测结果泛化能力比较弱;另一方面,采用 PF 算法结合经验退化模型的电池 RUL 预测中存在粒子退化问题,影响预测的准确性。所以如何应用多个模型,改进 PF 算法,提高锂离子电池 RUL 预测结果的泛化能力是一个重要问题。

粒子流滤波(Particle Flow Filter, PFF)作为一种新兴方法,通过构造同伦函数,求解关于时间的微分方程,实现将粒子从先验分布“流动”到后验分布,因其无须重采样过程,所以克服了传统粒子滤波中粒子退化和样本贫化问题。通常情况下,在处理非线性问题中,PFF 比拓展卡尔曼滤波(Extended Kalman Filter, EKF)或无迹卡尔曼滤波(Unscented Kalman Filter, UKF)的精度高出大约 2 个数量级。为达到与标准粒子流滤波相同的精确度,PFF 需要的粒子数量少 3 个数量级<sup>[20]</sup>。在先前的研究中,提出了多种流动策略,如 IPF(Incompressible Particle Flow)滤波<sup>[21]</sup>、NZDDH(Non-Zore Diffusion Daum-Huang filter)滤波<sup>[22]</sup>、EDH(Exact Daum-Huang)滤波<sup>[23]</sup>等,应用到目标跟踪领域、信道估计、非线性参数估计中。Choi 等人<sup>[24]</sup>证明在线性、非线性、高斯、非高斯以及不同状态空间维度和粒子数量下,IPF

滤波与 EDH 滤波的性能优于著名算法(自举粒子滤波、辅助粒子滤波、拓展卡尔曼滤波和无迹卡尔曼滤波)。Mori 等人<sup>[25]</sup>提出一种自适应步长的粒子流滤波应对求解微分方程造成的僵硬流动,使粒子更平滑从先验分布流动到后验分布。周德运等人<sup>[26]</sup>提出将一种“新息误差”结构引入粒子流动的过程,在噪声较大情况下处理多维问题拥有较高的运算效率和估算精度。

锂离子电池容量衰退过程是一个线性及非线性混合动态过程,考虑到多种模型可以体现锂离子电池衰退的特征,例如线性特征、非线性特征及衰退趋势特征,本文利用粒子流滤波在非线性动态系统的优势,提出一种基于交互式多模型粒子流滤波(Interactive Multiple Model Particle Flow Filter, IMM-PFF)的锂离子电池寿命预测方法,主要研究内容如下:

(1) 针对单一模型因固定函数形式难以全面表征不同工况下电池复杂衰退状态,例如锂离子电池线性特征、非线性特征,及衰退趋势特征,导致泛化能力受限问题,提出交互式多模型方法,融合经验模型中常用的指数退化模型来体现锂离子电池非线性特点,多项式退化模型体现锂离子电池的线性特点,以及生物模型体现锂离子电池衰退趋势特点,旨在更精准捕捉电池的退化混合特征行为,增强模型的适应性和泛化能力。

(2) 针对粒子滤波在电池 RUL 预测中容易陷入粒子退化问题,提出利用粒子流滤波的连续流形迁移特性替代传统重采样机制,在避免粒子多样性损失的同时,显著提升模型参数估计效率。

(3) 通过大量实验数据,对提出的 IMM-PFF 方法进行验证,与现有的寿命预测方法进行对比分析,评估其在不同工况下的预测精度和鲁棒性。

## 2 锂离子电池容量衰退模型

### 2.1 指数模型

在锂离子电池的容量衰退研究中,指数模型<sup>[27]</sup>因其能够较好地拟合电池容量随着时间或循环次数的非线性衰减特性被广泛用于电池寿命预测中,提供较高的预测精度,能较好地解释电池退化过程中出现的快速和缓慢衰减阶段。

指数模型的基本形式为

$$C_k = a_1 \cdot \exp(a_2 \cdot k) + a_3 \cdot \exp(a_4 \cdot k) \quad (1)$$

其中,  $C_k$  表示电池在循环次数  $k$  时的容量,  $a_1$ 、 $a_2$ 、 $a_3$ 、 $a_4$  为模型参数,  $a_1$  和  $a_3$  与电池的内部阻抗有关,  $a_2$  和  $a_4$  反映电池在快速衰减阶段和缓慢衰减阶段的衰减速率。

指数模型能够很好地拟合锂离子电池容量衰退过程中非线性的部分,然而,当电池衰退过程呈现线性变

化时,指数模型的预测结果可能会过于复杂,甚至导致过拟合现象。

### 2.2 多项式模型

多项式模型<sup>[28]</sup>广泛应用于工程和科学领域,描述各种非线性关系。在锂离子电池寿命预测中,多项式模型因其简单和良好的拟合性能用于描述电池容量随充放电循环次数的变化。相比于复杂的物理模型,多项式模型提供了一种计算成本较低且易于实现的方式来预测电池的衰减趋势。

多项式模型的基本形式为

$$C_k = \beta_1 k^2 + \beta_2 k + \beta_3 \quad (2)$$

其中,  $C_k$  表示电池在循环次数  $k$  时的容量,  $\beta_1$ 、 $\beta_2$ 、 $\beta_3$  为多项式模型的系数。

多项式模型能够很好地拟合锂离子电池容量衰退过程中呈现线性变化的部分。当电池处于较稳定的衰退阶段时,多项式模型能够提供较准确的预测结果。然而,当电池衰退过程出现非线性变化时,多项式模型的预测精度可能会受到较大影响。

### 2.3 生物模型

生物模型也叫 Verhulst 模型,源于德国生物学家 Verhulst 对 Malthusian 模型进行改进,以适合预测生长率低的生物繁殖情况,是灰色系统的经典理论之一,构建 Verhulst 模型过程如下<sup>[29]</sup>。

假设存在一组非负的电池容量数据序列:

$$C^{(0)} = (C^{(0)}(1), C^{(0)}(2), \dots, C^{(0)}(n)) \quad (3)$$

对原始数据进行累加得到新数据序列:

$$C^{(1)} = (C^{(1)}(1), C^{(1)}(2), \dots, C^{(1)}(n)) \quad (4)$$

其中,

$$C^{(1)}(i) = \sum_{k=1}^i C^{(0)}(k), i = 1, 2, \dots, n \quad (5)$$

对  $C^{(1)}(i)$  进行紧邻均值生成序列  $L^{(1)}$ :

$$L^{(1)} = (L^{(1)}(2), L^{(1)}(3), \dots, L^{(1)}(n)) \quad (6)$$

其中,  $L^{(1)}(k) = \lambda C^{(1)}(k) + (1 - \lambda) C^{(1)}(k - 1)$ ,  $\lambda = 0.5$ ,  $k = 2, 3, \dots, n$ 。Verhulst 模型可以定义为下面的形式:

$$C^{(0)}(k) + aL^{(1)}(k) = b(L^{(1)}(k))^2 \quad (7)$$

其中,  $a$  为发展系数,  $b$  为灰色作用量,白化方程为

$$\frac{dC^{(1)}}{dt} + aC^{(1)} = b(C^{(1)})^2 \quad (8)$$

利用最小平方方法解决参数矩阵  $[a, b]^T$ ,  $\begin{bmatrix} a \\ b \end{bmatrix} =$

$(B^T B)^{-1} B^T Y$ , 其中:

$$B = \begin{bmatrix} -L^{(1)}(2)(L^{(1)}(2))^2 \\ -L^{(1)}(3)(L^{(1)}(3))^2 \\ \vdots \\ -L^{(1)}(n)(L^{(1)}(n))^2 \end{bmatrix}, Y = \begin{bmatrix} C^{(0)}(2) \\ C^{(0)}(3) \\ \vdots \\ C^{(0)}(n) \end{bmatrix} \quad (9)$$

可以获得原始数列的预测模型:

$$C^{(1)}(k) = \frac{aC^{(1)}(1)}{bC^{(1)}(1) + (a - bC^{(1)}(1))e^{ak}}, k = 1, 2, \dots, n \quad (10)$$

通过上面的推导可以给出锂离子电池  $k$  循环时所对应的剩余容量  $C_k$  的预测模型:

$$C_k = \frac{\gamma_1 C_1}{\gamma_2 C_1 + (\gamma_1 - \gamma_2 C_1)e^{\gamma_1 k}}, k = 1, 2, \dots, n \quad (11)$$

其中,  $C_k$  代表第  $k$  时刻的状态,  $C_1$  是一个常数,  $k$  是时刻,  $\gamma_1$  和  $\gamma_2$  是模型参数.

Xian 等人<sup>[30]</sup>给出了 Verhulst 模型的一步转移状态方程形式, 适合 IMM 的交互作用:

$$C_{k+1} = \frac{1}{\frac{\gamma_2}{\gamma_1} + \left(\frac{1}{C_k} - \frac{\gamma_2}{\gamma_1}\right)e^{\gamma_1}} \quad (12)$$

Verhulst 模型源自生物预测领域, 它能够很好地描述锂离子电池容量衰退的整体趋势. 上述每一个模型都有它自己的适用特点.

用 MATLAB 中的曲线拟合工具求得 3 种模型的拟合参数, 见表 1. 表 2 对比了 3 种模型在拟合程度方面的差异. 均方根误差 (Root Mean Square Error, RMSE) 是衡量预测值与实际观测值之间差异的标准, 通过计算预测误差的平方平均值并取平方根来评估模型的精度, RMSE 值越小, 表示模型的预测结果与实际结果越接近, 精度越高. 决定系数 ( $R^2$ ) 是用于评估回归模型拟合效果的指标, 表示模型解释因变量总变异的比例.  $R^2$  值介于 0~1, 值越接近 1, 说明模型对数据的解释能力越强, 拟合效果越好.

表 1 A1、A2、A3 电池的 3 种模型拟合参数

模型	参数	A1	A2	A3
1	$\alpha_1$	-0.100 400	$-9.86 \times 10^{-7}$	$-1.53 \times 10^{-5}$
	$\alpha_2$	0.008 761	0.057 520 0	0.062 960 0
	$\alpha_3$	0.980 000	0.898 300 0	0.875 700 0
	$\alpha_4$	0.001 297	-0.000 833 8	-0.000 939 9
2	$\beta_1$	$-1.61 \times 10^{-5}$	$-1.07 \times 10^{-5}$	$-2.61 \times 10^{-5}$
	$\beta_2$	0.002 430	0.001 037 0	0.002 118 0
	$\beta_3$	0.821 200	0.851 800 0	0.824 200 0
3	$\gamma_1$	0.008 950	0.006 000 0	0.014 050 0
	$\gamma_2$	0.006 450	0.003 050 0	0.014 300 0

表 2 3 种模型的拟合优度统计

电池	模型 1		模型 2		模型 3	
	RMSE	$R^2$	RMSE	$R^2$	RMSE	$R^2$
A1	0.047 6	0.968 7	0.058 5	0.952 7	0.060 8	0.949 1
A2	0.015 9	0.976 6	0.038 2	0.864 2	0.038 3	0.863 8
A3	0.031 8	0.943 4	0.060 5	0.793 9	0.060 9	0.792 5

### 3 基于交互式多模型粒子流滤波的锂离子电池剩余寿命预测

#### 3.1 粒子流滤波

贝叶斯滤波假设系统的状态和观测都服从一定的概率分布, 为非线性动态系统的状态问题提供了基于概率分布形式的解决方法, 设  $\mathbf{x}_k$  为目标在  $k$  时刻的状态向量,  $\mathbf{z}_k$  为观测值, 状态方程和观测方程为

$$\begin{aligned} \mathbf{x}_k &= f_k(\mathbf{x}_{k-1}, \boldsymbol{\mu}_k) \\ \mathbf{z}_k &= h_k(\mathbf{x}_k, \mathbf{v}_k) \end{aligned} \quad (13)$$

其中,  $f_k$  为状态转移函数,  $\boldsymbol{\mu}_k$  为过程噪声,  $h_k$  为测量函数,  $\mathbf{v}_k$  为测量噪声.

贝叶斯滤波通常包含 2 个步骤:

(1) 预测. 根据系统上一时刻的状态估计和动态模型, 利用贝叶斯定理推断系统当前时刻的状态:

$$p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) = \int_{\mathbf{x}_{k-1}} p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) p(\mathbf{x}_k | \mathbf{x}_{k-1}) d\mathbf{x}_{k-1} \quad (14)$$

(2) 更新. 将观测数据与预测估计进行比较, 更新对系统状态的估计. 更新步骤基于贝叶斯定理, 利用观测数据修正预测估计的不确定性:

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) = \frac{p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) p(\mathbf{z}_k | \mathbf{x}_k)}{\int_{\mathbf{x}_k} p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) p(\mathbf{z}_k | \mathbf{x}_k) d\mathbf{x}_k} \quad (15)$$

其中,  $p(\mathbf{x}_k | \mathbf{x}_{k-1})$  为状态转移密度函数,  $p(\mathbf{z}_k | \mathbf{x}_k)$  为似然函数. 通过交替进行预测和更新步骤, 可以不断迭代更新对系统状态的估计, 实现对系统状态的有效推断和预测. 贝叶斯滤波方法在估计系统状态的同时, 提供了对估计不确定性的量化, 使得对系统状态的推断更加可靠和准确.

粒子流滤波引入拓扑学中的同伦原理将粒子从先验分布移动到对应的后验分布上, 以粒子流动的方式代替贝叶斯公式实现贝叶斯滤波. 为简化表达, 设  $h(\mathbf{x})$  和  $g(\mathbf{x})$  分别代表贝叶斯滤波中的似然函数  $p(\mathbf{x}_k | \mathbf{x}_k)$  和先验概率密度  $p(\mathbf{x}_k | \mathbf{z}_{k-1})$ . 定义对数同伦函数  $\log p(\mathbf{x}, \lambda)$  为

$$\log p(\mathbf{x}, \lambda) = \log g(\mathbf{x}) + \lambda \log h(\mathbf{x}) - \log \mathbf{K}(\lambda) \quad (16)$$

其中,  $\lambda$  是伪离散时间, 取值范围为  $[0, 1]$ ,  $\mathbf{K}(\lambda) = \int_{\mathbf{x}} g(\mathbf{x}) h(\mathbf{x})^\lambda d\mathbf{x}$  是条件概率密度函数的归一化项. 当

$\lambda=0$ 时,粒子流处于先验分布状态,在 $\lambda$ 从0~1的变化过程中,粒子逐渐移动,直到 $\lambda=1$ 时,粒子移动到合适的后验分布区域.贝叶斯准则的粒子流服从Ito随机微分方程<sup>[31]</sup>:

$$d\mathbf{x} = f(\mathbf{x}, \lambda) d\lambda + \sigma(\mathbf{x}, \lambda) d\omega_\lambda \quad (17)$$

其中, $f(\mathbf{x}, \lambda)$ 可以认为是粒子从先验分布移动到后验分布的“速度场”, $\sigma(\mathbf{x}, \lambda)$ 为扩散系数.不考虑过程噪声,假设粒子流是零扩散的, $p(\mathbf{x}, \lambda)$ 满足零扩散项的Fokker-Planck方程<sup>[32]</sup>:

$$d\mathbf{x} = f(\mathbf{x}, \lambda) d\lambda \quad (18)$$

忽略式子中的归一化系数,对其 $\lambda$ 求偏导,并结合上式,可得:

$$\frac{\partial p(\mathbf{x}, \lambda)}{\partial \lambda} = -\text{div}(f(\mathbf{x}, \lambda)p(\mathbf{x}, \lambda)) \quad (19)$$

求解 $f(\mathbf{x}, \lambda)$ 是粒子流滤波算法的核心问题.根据不同的流动限制,式(10)有不同解法,精确粒子流滤波是其中较出名的一种<sup>[33]</sup>.EDH假设先验分布和似然分布都服从高斯分布,精确粒子流可以表示为

$$f(\mathbf{x}, \lambda) = A(\lambda)\mathbf{x} + \mathbf{E} \quad (20)$$

进一步解得:

$$A(\lambda) = -\frac{1}{2} \mathbf{P} \mathbf{H}^T (\lambda \mathbf{H} \mathbf{P} \mathbf{H}^T + \mathbf{R})^{-1} \mathbf{H} \quad (21)$$

$$\mathbf{E} = (\mathbf{I} + 2\lambda A(\lambda)) [(\mathbf{I} + \lambda A(\lambda)) \mathbf{P} \mathbf{H}^T \mathbf{R}^{-1} \mathbf{z} + A(\lambda) \bar{\mathbf{x}}] \quad (22)$$

其中, $\mathbf{R}$ 为测量噪声方差矩阵, $\mathbf{P}$ 表示为先验协方差矩阵, $\mathbf{H}$ 可以通过测量函数 $h_k$ 线性化得到,求解粒子流的系数可以通过EKF/UKF计算得到<sup>[34]</sup>:

$$\mathbf{H} = \left. \frac{\partial h(\mathbf{x}, 0)}{\partial \mathbf{x}} \right|_{\mathbf{x}=\mathbf{x}_i} \quad (23)$$

### 3.2 交互式多模型粒子流滤波

通常情况单一运动模型无法准确捕捉到目标的多运动状态.Bolm和Bar-Shalom提出了交互式多模型(Interactive Multiple Model, IMM)算法<sup>[35]</sup>,该算法引入马尔科夫转移概率矩阵,通过概率加权多个模型的状态估计,实现交互融合多个模型的预测结果<sup>[36]</sup>.IMM采用一个模型集来描述预测目标的运动变化状态,每一个模型对应不同的滤波器,自适应调整各个模型间的转移概率,通过概率加权交互输出多个并行滤波器的预测结果,IMM算法是迄今为止最有效的多模型算法之一<sup>[37]</sup>.

IMM-PFF算法融合了IMM和粒子流滤波算法.首先计算混合概率和各模型的交互输入,根据先验概率密度函数初始化粒子,经过粒子流滤波后,再输出交互预测结果以及更新模型概率<sup>[38]</sup>.IMM-PFF算法原理如图1所示.

对于并行滤波器,考虑以下包含 $M$ 个模型的线性离散时间马尔可夫系统<sup>[39]</sup>:

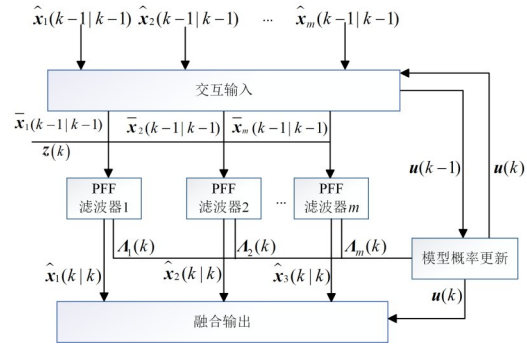


图1 IMM-PFF算法流程图

$$\mathbf{x}(k) = \mathbf{F}(k-1)\mathbf{x}(k-1) + \mathbf{G}(k-1) \cdot \boldsymbol{\omega}(k-1) \quad (24)$$

$$\mathbf{z}(k|k-1) = \mathbf{H}(k) \cdot \mathbf{x}(k|k-1) + \mathbf{v}(k) \quad (25)$$

式(24)和式(25)分别表示系统的状态方程和观测方程, $\mathbf{x}(k)$ 和 $\mathbf{z}(k|k-1)$ 分别是 $k$ 时刻的状态矢量和观测矢量; $\mathbf{F}(k-1)$ 和 $\mathbf{H}(k)$ 分别表示状态矩阵和观测矩阵; $\boldsymbol{\omega}(k-1) \sim N(0, \mathbf{Q}(k-1))$ 和 $\mathbf{v}(k) \sim N(0, \mathbf{R}(k))$ 分别表示状态噪声和观测噪声,二者是零均值标准的高斯白噪声序列. Mod是模型集,模型 $j$ 的先验概率 $\boldsymbol{\mu}_j(0)$ 和模型 $i$ 到模型 $j$ 的马尔可夫转移概率矩阵 $\boldsymbol{\pi}_{ij}$ 分别为

$$\boldsymbol{\mu}_j(0) = \mathbf{P}(\text{Mod}_j(0)) \quad (26)$$

$$\boldsymbol{\pi}_{ij} = \mathbf{P}(\text{Mod}_j(k)|\text{Mod}_i(k-1)) \quad (27)$$

本文提出的IMM-PFF算法的完整流程如下<sup>[40]</sup>:

(1) 计算各模型的初始混合概率

$$\boldsymbol{\mu}_{ij}(k-1|k-1) = \frac{1}{\sum_{i=1}^M \boldsymbol{\pi}_{ij} \boldsymbol{\mu}_j^n(k-1)} \boldsymbol{\pi}_{ij} \boldsymbol{\mu}_i(k-1), i, j \in M \quad (28)$$

其中, $\boldsymbol{\mu}_{ij}(k-1|k-1)$ 为 $k-1$ 时刻第 $i$ 个模型的混合概率矩阵.

(2) 估计状态混合输入

$$\bar{\mathbf{x}}_j(k-1|k-1) = \sum_{i=1}^M \hat{\mathbf{x}}_i(k-1|k-1) \boldsymbol{\mu}_{ij}(k-1|k-1) \quad (29)$$

$$\bar{\mathbf{P}}_j(k-1|k-1) = \sum_{i=1}^M \boldsymbol{\mu}_{ij}(k-1|k-1) \left\{ \hat{\mathbf{P}}_i(k-1|k-1) + \left[ \hat{\mathbf{x}}_i(k-1|k-1) - \hat{\mathbf{x}}_j(k-1|k-1) \right] [\cdot]^T \right\} \quad (30)$$

其中, $\hat{\mathbf{x}}_i(k-1|k-1)$ 和 $\hat{\mathbf{P}}_i(k-1|k-1)$ 是 $k-1$ 时刻第 $i$ 个模型滤波器的状态估计和估计误差协方差矩阵, $\bar{\mathbf{x}}_j(k-1|k-1)$ 和 $\bar{\mathbf{P}}_j(k-1|k-1)$ 是交互结果.

(3) 粒子流滤波

$M$ 个独立的相同滤波器对各自输入数据同时进行滤波处理,得到 $k$ 时刻的状态估计向量 $\hat{\mathbf{x}}_j(k|k)$ 及其对应的估计误差协方差矩阵 $\mathbf{P}_j(k|k)$ <sup>[41]</sup>.计算过程如下:

## ①状态预测

$$\hat{\mathbf{x}}_j^n(k|k-1) \sim N\left(\mathbf{F}_j(k-1)\bar{\mathbf{x}}_j(k-1|k-1), \mathbf{G}(k-1)\mathbf{Q}(k-1)\mathbf{G}(k-1)^T\right) \quad (31)$$

$$\mathbf{P}_j(k|k-1) = \mathbf{F}_j(k-1)\bar{\mathbf{P}}_j(k|k-1)\mathbf{F}_j(k-1)^T + \mathbf{G}(k-1)\mathbf{Q}(k-1)\mathbf{G}(k-1)^T \quad (32)$$

$$\bar{\mathbf{x}}_j(k|k-1) = \sum_{i=1}^N \hat{\mathbf{x}}_i^n(k|k-1) \quad (33)$$

其中,  $\hat{\mathbf{x}}_j^n(k|k-1)$  表示第  $j$  个粒子流滤波在第  $k$  时刻第  $n$  个粒子的状态估计,  $\mathbf{P}_j(k|k-1)$  是对应的估计误差协方差矩阵,  $\mathbf{Q}(k-1)$  表示  $k-1$  时刻的过程噪声协方差矩阵,  $\bar{\mathbf{x}}_j(k|k-1)$  是粒子集合的状态估计均值。

## ②粒子流滤波更新

利用计算得出的  $\bar{\mathbf{x}}_j(k|k-1)$  和  $\mathbf{P}_j(k|k-1)$ , 根据式(21)和式(22)计算  $\mathbf{A}$  和  $\mathbf{E}$ :

For  $t=0: \lambda: 1$

$$\hat{\mathbf{x}}_j^n(k|k-1) = \hat{\mathbf{x}}_j^n(k|k-1) + \lambda(\mathbf{A}\hat{\mathbf{x}}_j^n(k|k-1) + \mathbf{E}) \quad (34)$$

End

根据式(33)重新计算  $\bar{\mathbf{x}}_j(k|k-1)$ 。

## ③状态估计及其协方差矩阵

$$\mathbf{S}_j(k) = \mathbf{H}(k)\mathbf{P}_j(k|k-1)\mathbf{H}(k)^T + \mathbf{R}(k) \quad (35)$$

$$\mathbf{K}_j(k) = \mathbf{P}_j(k|k-1)\mathbf{H}(k)^T\mathbf{S}_j(k)^{-1} \quad (36)$$

$$\hat{\mathbf{x}}_j(k|k) = \bar{\mathbf{x}}_j(k|k-1) + \mathbf{K}_j(k)[z(k) - \mathbf{H}(k)\bar{\mathbf{x}}_j(k|k-1)] \quad (37)$$

$$\mathbf{P}_j(k|k) = [\mathbf{I} - \mathbf{K}_j(k)\mathbf{H}(k)]\mathbf{P}_j(k|k-1) \quad (38)$$

## (4)更新模型后验概率

$$\mathbf{u}_j(k) = \frac{1}{\sum_{j=1}^M \mathbf{A}_j(k)\bar{\mathbf{C}}_j} \mathbf{A}_j(k)\bar{\mathbf{C}}_j \quad (39)$$

其中,  $\mathbf{A}_j(k)$  是第  $j$  个模型的似然函数。

## (5)交互输出

$$\hat{\mathbf{x}}(k|k) = \sum_{j=1}^M \hat{\mathbf{x}}_j(k|k)\mathbf{u}_j(k) \quad (40)$$

$$\mathbf{P}(k|k) = \sum_{j=1}^M \mu_j(k) \left\{ \mathbf{P}_j(k|k) + [\hat{\mathbf{x}}_j(k|k) - \hat{\mathbf{x}}(k|k)][\cdot]^T \right\} \quad (41)$$

重复上述过程可以获得当前时刻输出的状态估计  $\hat{\mathbf{x}}(k|k)$  和估计误差协方差矩阵  $\mathbf{P}(k|k)$ <sup>[42]</sup>。

## 4 实验结果与分析

## 4.1 锂离子电池数据集

在锂离子电池的使用过程中, 电池容量会随着充放电循环的增加而逐渐衰减。为了研究电池容量的变化规律, 马里兰大学高等生命周期工程中心(Center for Advanced Life Cycle Engineering, CALCE)进行了系统的

实验研究, 收集了大量电池在不同工况下的容量数据<sup>[43]</sup>。其中, A1、A2 和 A3 这 3 组电池数据广泛用于研究锂离子电池的退化特性和寿命预测。这 3 组数据集分别代表了电池在不同的充放电条件下的容量变化情况。第 2 组电池退化数据来自美国国家航空航天局预测卓越中心(National Aeronautics and Space Administration Prognostics Center of Excellence, NASA 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。第 3 组电池退化数据集来自西安交通大学(Xi'an JiaoTong University, XJTU), 实验对象为“力神”制造的 18650 型镍钴锰酸锂电池, 电池的标称容量为 2 000 mAh, 标称电压为 3.6 V, 充电截止电压和放电截止电压分别为 4.2 V 和 2.5 V。3 个数据集的锂离子电池容量退化曲线如图 2 所示。

## 4.2 初始参数及状态方程

本文利用交互式多模型对 3 组电池的实际容量数据进行滤波和参数更新。每一个电池对应的状态方程参数初始值都是由容量衰退情况最接近的 2 组电池数据所决定, 测试数据电池 A1 状态方程参数初始值由训练数据电池 A2 和 A3 参数值取平均后获得; 测试数据电池 A2 状态方程参数初始值取训练数据电池 A1 和 A3 参数的平均值; 测试数据电池 A3 状态方程参数初始值取训练数据电池 A1 和 A2 参数的平均值。

为了实现 IMM 对输入量的交互作用, 需要将 3 个模型的状态量均设为电池容量, 以指数模型为例, 一步状态转移方程表达形式如下:

$$C(k+1) = C(k) + \beta_1 \exp(\beta_2 k) [\exp(\beta_2) - 1] + \beta_3 \exp(\beta_4 k) [\exp(\beta_4) - 1] + w_k, w_k \rightarrow N(0, \sigma) \quad (42)$$

对应的测量方程为

$$y(k) = C(k) + v_k, v_k \rightarrow N(0, \sigma) \quad (43)$$

其中,  $C(k)$  表示在第  $k$  循环次数时的电池可用容量预测值;  $y(k)$  表示第  $k$  循环次数时的容量测量值;  $w_k$  和  $v_k$  是零均值, 标准差为  $\sigma$  的高斯噪声;  $\beta_1$ 、 $\beta_2$ 、 $\beta_3$  和  $\beta_4$  是模型参数。

## 4.3 实验结果分析

## 4.3.1 实验设计

在实验中, 以前 70 次循环设为前期训练, 前期预测以第 71 次循环为起点, 中期预测以第 81 次循环为起点, 后期预测以第 91 次循环为起点, 失效阈值为 SOH=0.72 Ah, 即容量  $C_k=0.72$  Ah。A1 电池的实际寿命为 212 循环, A2 电池的实际寿命为 189 循环, A3 电池的实际寿命为 134 循环。

为了验证本文提出算法的有效性, 使用均方根误差(Root Mean Square Error, RMSE)、均方误差(Mean-

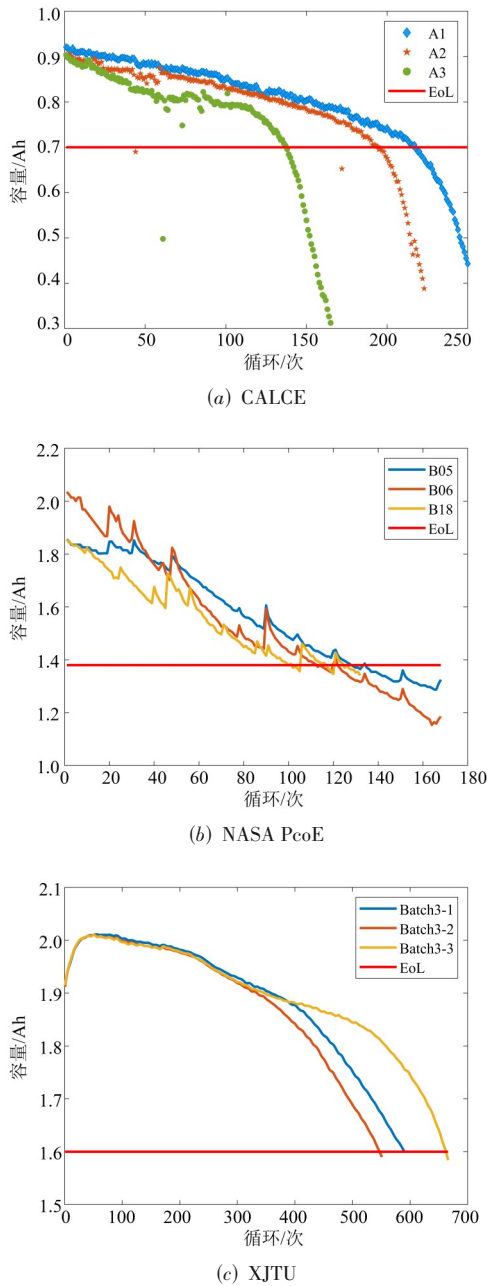


图2 锂离子电池容量退化曲线

square error, MSE)、平均绝对误差(Mean Absolute Error, MAE)和预测误差(Prediction Error, PE)来衡量仿真结果的准确性和稳定性,各指标的表达式如下:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (C_{\text{real}} - C_{\text{pre}})^2} \quad (44)$$

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (C_{\text{real}} - C_{\text{pre}})^2 \quad (45)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |C_{\text{real}} - C_{\text{pre}}| \quad (46)$$

$$\text{PE} = \left| \frac{\text{RUL}_{\text{real}} - \text{RUL}_{\text{pre}}}{\text{RUL}_{\text{real}}} \right| \quad (47)$$

#### 4.3.2 多阶段预测性能实验结果

图3~图5展示了用 IMM-PFF 算法预测电池 A1、A2 和 A3 的容量衰退曲线。在训练阶段初期,算法的预测容量与实际容量之间存在较大差异,主要原因是为了理论上的公平性假设 3 个模型的初始概率为 0.3、0.3 和 0.4。随着算法的逐步迭代优化,转移概率动态调整,预测容量在进入预测阶段前接近实际容量。在每组电池的老化平稳衰减阶段和急剧下降阶段,IMM-PFF 预测容量衰退趋势与实际情况相符合,表明该算法能够有效地预测不同电池的剩余寿命。

表 3 展示 IMM-PFF 和 PFF 算法预测 3 组电池健康状态的误差指标。与指数经验模型应用 PFF 滤波估计的结果相比,IMM-PFF 在 RMSE、MSE、MAE 和 PE 至少降低 24.3%、42.3%、35.1% 和 4.5%。在前期循环中的 IMM-PFF 算法预测 3 组电池容量的精度误差相对较大,是由于模型在初始化阶段对电池初始状态估计得不完全准确所致。随着循环次数的增加,误差逐渐减小,显示出算法自我学习和调整的强大能力。RMSE、MSE 和 MAE 误差在中期的时候最小,后期的误差小于前期,体现模型参数随数据积累而不断优化的结果,整体趋势向好。IMM-PFF 预测电池 A1 和 A2 的寿命误差随着时间的推移越来越小,但预测电池 A3 的中期和后期的寿命误差大于前期。与综合来看,IMM-PFF 算法在后期预测电池的老化情况与实际接近,总体预测误差更小。

表 4 展示了 IMM-PFF 方法在 XJTU 电池数据集上对电池容量衰退的多阶段(前期、中期、后期)预测性能,包括 RMSE、MSE、MAE 和 PE 等评估指标在不同批次的实验结果。从表 4 可以看出,在整个电池寿命预测过程中,各个阶段的误差均保持在较低水平,表明模型在不同电池样本上的预测精度较高,具有较好的稳定性和可靠性。从 RMSE 来看,所有电池的误差值在前期、中期和后期均呈现出逐步下降的趋势。例如, Batch3-1 的 RMSE 从前期的 0.025 4 下降到后期的 0.023 4, Batch3-2 和 Batch3-3 也表现出类似的趋势。这表明模型随着时间的推移对电池寿命的预测更加精确,能够较好适应不同阶段的数据分布。MSE 进一步佐证了 RMSE 的表现。MS 在整个预测过程中始终保持在较低水平,说明模型的预测误差整体较小,且对大误差点的影响进行有效抑制。在 MAE 方面,各阶段的误差值稳定在 0.016 2~0.020 5 之间,整体波动较小,进一步证明了其泛化能力较强,能够适用于不同电池样本。此外,从 PE 来看,虽然中期的误差相对略高,但整体误差均维持在 5~8 个循环之间,这表明模型在不同电池上都能保持较高的预测准确度,且误差控制在合理范围内,满

足工程应用的需求。

本文使用 NASA PCoE 开源数据集,与文献[44]所提的 KCC-PF 方法进行对比. B05、B06 及 B18 的失效阈值设置为 1.38 Ah,设置 B05、B06 的预测起点为第 60 循环,为保证 B18 有足够的迭代步数,设置其预测起点为第 30 循环. IMM-PFF 预测 NASA PCoE 电池的容量衰退情况如图 6 所示. IMM-PFF 预测 3 组电池容量的 RMSE 分别为 0.024 4、0.035 1 及 0.038 8,相比于文献[44]的结果提高了 1.6%、5.8% 及 12.2%.

为进一步验证所提 IMM-PFF 方法,与文献[45]所

提 VMD-LSTM-GPR 方法、文献[46]所提 IWOA-LSSVM 方法和文献[47]所提 VMD-DAIPSO-GPR 方法进行 RUL 预测结果对比分析,结果如表 5 所示. 对于 B05 号电池, IMM-PFF 方法预测 RUL 误差与 VMD-LSTM-GPR 和 VMD-DAIPSO-GPR 相同,均能够准确预测电池达到寿命阈值的循环. 对于 B06 号电池和 B18 号电池, IMM-PFF 方法的 RUL 预测误差略高于 VMD-LSTM-GPR,但优于 IWOA-LSSVM,其预测结果与先进的深度学习 RUL 预测方法相差一个循环,整体达到现有优秀机器学习算法的水平.




图 3 IMM-PFF 预测电池 A1 的容量衰退情况




图 4 IMM-PFF 预测电池 A2 的容量衰退情况




图 5 IMM-PFF 预测电池 A3 的容量衰退情况

表3 IMM-PFF 和 PFF 在 CALCE 数据集上的预测精度误差比较

电 池	预测阶段	前期				中期				后期			
	指标	RMSE	MSE	MAE	PE	RMSE	MSE	MAE	PE	RMSE	MSE	MAE	PE
A1	IMM-PFF	0.035 2	0.001 2	0.029 5	18	0.028 8	0.000 8	0.019 0	11	0.032 4	0.001 0	0.025 4	10
	PFF	0.079 5	0.006 8	0.062 6	23	0.071 2	0.005 1	0.057 3	13	0.059 1	0.005 6	0.051 0	11
A2	IMM-PFF	0.032 5	0.001 1	0.028 1	21	0.029 2	0.000 9	0.019 1	5	0.029 8	0.000 9	0.019 2	3
	PFF	0.060 1	0.003 6	0.043 9	22	0.065 5	0.004 3	0.044 1	11	0.059 8	0.003 6	0.041 2	7
A3	IMM-PFF	0.038 6	0.001 5	0.024 5	2	0.033 8	0.001 1	0.026 8	6	0.033 0	0.001 1	0.022 5	4
	PFF	0.051 0	0.002 6	0.040 1	3	0.053 1	0.002 8	0.041 3	8	0.056 1	0.003 1	0.042 4	7

表4 IMM-PFF 方法在 XJTU 电池数据集上的多阶段预测性能评估

电 池	前期				中期				后期			
	RMSE	MSE	MAE	PE	RMSE	MSE	MAE	PE	RMSE	MSE	MAE	PE
Batch3-1	0.025 4	0.000 6	0.020 3	5	0.024 2	0.000 6	0.019 4	8	0.023 4	0.000 5	0.020 5	7
Batch3-2	0.024 2	0.000 6	0.019 4	5	0.023 1	0.000 5	0.018 5	8	0.022 9	0.000 5	0.018 2	7
Batch3-3	0.021 4	0.000 5	0.017 1	6	0.020 5	0.000 4	0.016 4	8	0.020 3	0.000 4	0.016 2	7




图6 IMM-PFF 预测 NASA PCoE 电池的容量衰退情况

表5 IMM-PFF 与其他 RUL 预测方法比较

电池 序号	方法	预测 起始 处	失效 阈值	实际 RUL	预测 RUL	PE
B05	VMD-LSTM-GPR	80	1.40	44	44	0
	IWOA-LSSVM	80	1.44	31	31	0
	VMD-DAIPSO-GPR	80	1.40	44	45	1
	IMM-PFF	80	1.40	44	44	0
B06	VMD-LSTM-GPR	80	1.40	28	26	2
	IWOA-LSSVM	80	1.44	19	19	0
	IMM-PFF	80	1.40	28	20	1
B18	VMD-LSTM-GPR	60	1.40	36	35	1
	IWOA-LSSVM	60	1.44	32	32	0
	IMM-PFF	60	1.40	36	36	0

4.3.3 模型自适应泛化能力实证

图7和图8分别展示了基于IMM-PFF算法对电池A1和Batch3-1的3种模型概率分布. 初始阶段, 3种模型的概率分别设定为0.3、0.3和0.4, 表示各模型在预测中的初始权重. 从图7可以看出, 在电池循环的前期和后期, 生物模型的概率始终占据主导地位, 表明该模型

在这2个阶段能够更精准地刻画电池性能的衰减趋势, 较好地适应电池的健康状态变化. 相反, 指数模型在电池寿命的前后期预测精度较低, 未能准确反映电池的衰退特征. 在电池寿命的中期阶段, 由于老化过程较为稳定, 各模型的预测性能趋于一致, 模型概率分布相对均衡. 然而, 电池Batch3-1的模型概率变化趋势与A1有所不同. 在前中期, 当电池容量呈线性衰退趋势时, 多项式模型的概率占据主导, 表明其在这一阶段能较好地拟合电池的衰退特征. 而在后期, 由于电池容量衰退加剧, 生物模型的概率迅速上升, 表明其更能适应电池复杂的衰退特性, 并对剩余寿命的变化趋势做出更精准的预测.

IMM-PFF 预测 NASA PCoE 电池的模型概率如图9所示, 可以看到最后3种模型的概率趋近于1/3, 模型概率与CALCE、XJTU数据集不同, 说明本文所提算法可以根据不同电池容量衰退情况, 自适应选择与动态调整模型权重, 具有较强的泛化能力. 随着电池的循环次数增加, IMM-PFF算法能够通过动态调整模型权重, 逐步提高剩余寿命的预测精度, 生物模型在电池的不同阶段表现出较强的适应能力.




图7 IMM-PFF 预测电池 A1 的模型概率




图8 IMM-PFF 预测电池 Batch3-1 的模型概率




图9 IMM-PFF 预测 NASA PCoE 电池的模型概率

### 5 结论

本文提出了一种基于交互式多模型和粒子流滤波的锂离子电池剩余寿命预测方法,以应对单一容量衰退模型在寿命预测中精度不足、泛化能力有限的问题.通过构建双指数模型、多项式模型和生物模型的交互式多模型框架,并结合 PFF 算法对各模型参数进行动态估计,该方法有效提升了 RUL 预测精度.实验结果表明,IMM-PFF 方法从中期开始,能够精准捕捉电池容量的变化趋势,显著提高了 RUL 预测的准确性.中期阶段,IMM-PFF 展示了稳健的适应性,3 种模型的预测

结果趋于一致,进一步验证了算法在不同生命周期阶段对模型权重合理分配的能力.相比传统单一容量衰退模型,IMM-PFF 不仅增强了在不同衰退阶段的预测精度,还通过自适应选择与动态调整模型权重,提升了模型的泛化能力. IMM-PFF 能够适应电池衰退过程中复杂的非线性特性,并提供更加可靠的预测结果.未来的研究将致力于进一步优化算法,提升在电池早期阶段的预测性能,并探索该方法在多种电池类型情况下的广泛应用潜力,为电池管理系统提供更精准的寿命预测支持.

## 参考文献

- [1] JIANG H M, WANG H J, SU Y T, et al. Multiple health indicators assisting data-driven prediction of the later service life for lithium-ion batteries[J]. *Journal of Power Sources*, 2022, 542: 1-8.
- [2] HU X S, XU L, LIN X K, et al. Battery lifetime prognostics[J]. *Joule*, 2020, 4(2): 310-346.
- [3] HU X S, FENG F, LIU K L, et al. State estimation for advanced battery management: Key challenges and future trends[J]. *Renewable and Sustainable Energy Reviews*, 2019, 114: 109334.
- [4] PARK S W, LEE H, WON Y S. A novel aging parameter method for online estimation of Lithium-ion battery states of charge and health[J]. *Journal of Energy Storage*, 2022, 48: 103987.
- [5] WANG J W, DENG Z W, LI J W, et al. State of health trajectory prediction based on multi-output Gaussian process regression for lithium-ion battery[J]. *Batteries*, 2022, 8(10): 134.
- [6] HE Z G, LI Y T, SUN Y Y, et al. State-of-charge estimation of lithium ion batteries based on adaptive iterative extended Kalman filter[J]. *Journal of Energy Storage*, 2021, 39: 102593.
- [7] 宋胜, 李云伍, 赵颖, 等. 锂离子电池片段数据的荷电状态估计研究[J]. *电源技术*, 2022, 46(7): 734-738.
- SONG S, LI Y W, ZHAO Y, et al. Research on SOC estimation based on fragment data of lithium-ion battery[J]. *Chinese Journal of Power Sources*, 2022, 46(7): 734-738. (in Chinese)
- [8] ZHANG X, GAO Y Z, GUO B J, et al. A novel quantitative electrochemical aging model considering side reactions for lithium-ion batteries[J]. *Electrochimica Acta*, 2020, 343: 136070.
- [9] 吴菲, 郑秀娟. 基于 PF-GPR 算法的锂离子电池剩余使用寿命预测[J]. *武汉科技大学学报*, 2022, 45(3): 189-196.
- WU F, ZHENG X J. Remaining useful life prediction of lithium-ion battery based on PF-GPR algorithm[J]. *Journal of Wuhan University of Science and Technology*, 2022, 45(3): 189-196. (in Chinese)
- [10] 李彦梅, 刘惠汉, 张朝龙, 等. 基于双高斯模型的锂电池剩余使用寿命预测方法[J]. *电气工程学报*, 2022, 17(4): 32-40.
- LI Y M, LIU H H, ZHANG C L, et al. Lithium-ion battery RUL prediction method based on double Gaussian model[J]. *Journal of Electrical Engineering*, 2022, 17(4): 32-40. (in Chinese)
- [11] LIU Y W, SUN J, SHANG Y L, et al. A novel remaining useful life prediction method for lithium-ion battery based on long short-term memory network optimized by improved sparrow search algorithm[J]. *Journal of Energy Storage*, 2023, 61: 106645.
- [12] 王萍, 范凌峰, 程泽. 基于健康特征参数的锂离子电池 SOH 和 RUL 联合估计方法[J]. *中国电机工程学报*, 2022, 42(4): 1523-1534.
- WANG P, FAN L F, CHENG Z. A joint state of health and remaining useful life estimation approach for lithium-ion batteries based on health factor parameter[J]. *Proceedings of the CSEE*, 2022, 42(4): 1523-1534. (in Chinese)
- [13] WANG S, ZHANG X C, CHEN W X, et al. State of health prediction based on multi-kernel relevance vector machine and whale optimization algorithm for lithium-ion battery[J]. *Transactions of the Institute of Measurement and Control*, 2021: 01423312211042009.
- [14] WANG S, HAN W, CHEN L F, et al. Experimental verification of lithium-ion battery prognostics based on an interacting multiple model particle filter[J]. *Transactions of the Institute of Measurement and Control*, 2020: 2621-2632.
- [15] 王帅, 韩伟, 陈黎飞, 等. 基于粒子滤波的锂离子电池剩余寿命预测[J]. *电源技术*, 2020, 44(3): 346-351.
- WANG S, HAN W, CHEN L F, et al. Prediction of lithium ion batteries remaining useful life based on particle filtering method[J]. *Chinese Journal of Power Sources*, 2020, 44(3): 346-351. (in Chinese)
- [16] 夏飞鸿. 基于粒子滤波的动力电池剩余使用寿命预测研究[D]. 贵阳: 贵州大学, 2022.
- XIA F H. Research on Prediction of Residual Service Life of Power Battery Based on Particle Filter[D]. Guiyang: Guizhou University, 2022. (in Chinese)
- [17] ZHANG H, MIAO Q, ZHANG X, et al. An improved unscented particle filter approach for lithium-ion battery remaining useful life prediction[J]. *Microelectronics Reliability*, 2018, 81: 288-298.
- [18] JIAO R H, PENG K X, DONG J. Remaining useful life prediction of lithium-ion batteries based on conditional variational autoencoders-particle filter[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(11): 8831-8843.
- [19] 周才杰, 汪玉洁, 李凯铨, 等. 基于灰色关联度分析-长短期记忆神经网络的锂离子电池健康状态估计[J]. *电工技术学报*, 2022, 37(23): 6065-6073.
- ZHOU C J, WANG Y J, LI K Q, et al. State of health estima-

- tion for lithium-ion battery based on gray correlation analysis and long short-term memory neural network[J]. Transactions of China Electrotechnical Society, 2022, 37(23): 6065-6073. (in Chinese)
- [20] DAUM F, HUANG J. Particle degeneracy: Root cause and solution[C]//Signal Processing, Sensor Fusion, and Target Recognition XX. Orlando: SPIE, 2011: 8050.
- [21] DAUM F, HUANG J. Nonlinear filters with log-homotopy[J]. Proceedings of SPIE on the International Society for Optical Engineering, 2007, 7698(2): 5920-5923.
- [22] DAUM F, HUANG J. Particle flow with non-zero diffusion for nonlinear filters[C]//Signal Processing, Sensor Fusion, and Target Recognition XXII. Baltimore: SPIE, 2013: 226-238.
- [23] DAUM F, HUANG J, NOUSHIN A. Exact particle flow for nonlinear filters[C]//Signal Processing, Sensor Fusion, and Target Recognition XIX. Orlando: SPIE, 2010: 92-110.
- [24] CHOI S, WILLETT P, DAUM F, et al. Discussion and application of the Homotopy filter[C]//Signal Processing, Sensor Fusion, and Target Recognition XX. Orlando: SPIE, 2011: 734-745.
- [25] MORI S, DAUM F, DOUGLAS J. Adaptive step size approach to Homotopy-based particle filtering Bayesian update[C]//2016 19th International Conference on Information Fusion. Piscataway: IEEE, 2016: 2035-2042.
- [26] 周德运, 刘斌, 苏茜. 基于“新息误差”的粒子流滤波算法[J]. 计算机应用, 2020, 40(11): 3127-3132.
- ZHOU D Y, LIU B, SU Q. Particle flow filter algorithm based on “innovation error” [J]. Journal of Computer Applications, 2020, 40(11): 3127-3132. (in Chinese)
- [27] GOEBEL K, SAHA B, SAXENA A, et al. Prognostics in battery health management[J]. IEEE Instrumentation & Measurement Magazine, 2008, 11(4): 33-40.
- [28] MICEA M V, UNGUREAN L, CÂRSTOIU G N, et al. Online state-of-health assessment for battery management systems[J]. IEEE Transactions on Instrumentation and Measurement, 2011, 60(6): 1997-2006.
- [29] KAYACAN E, ULUTAS B, KAYNAK O. Grey system theory-based models in time series prediction[J]. Expert Systems with Applications, 2010, 37(2): 1784-1789.
- [30] XIAN W M, LONG B, LI M, et al. Prognostics of lithium-ion batteries based on the verhulst model, particle swarm optimization and particle filter[J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(1): 2-17.
- [31] IT K. Differential equations determining Markov processes[J]. Zenkoku Shijo Sugaku Danwakai, 1942, 244 (1077): 1352-1400.
- [32] RISKEN H. Fokker-Planck Equation[M]. Berlin: Springer, 1984: 63-95.
- [33] WANG J J, ZHAO L L, SU X H. Marginalized particle flow filter[J]. Circuits, Systems, and Signal Processing, 2019, 38(7): 3152-3169.
- [34] 柳超, 王子微, 孙进平. 粒子流粒子滤波检测前跟踪方法[J]. 信号处理, 2019, 35(3): 342-350.
- LIU C, WANG Z W, SUN J P. Particle flow particle filter track-before-detect method[J]. Journal of Signal Processing, 2019, 35(3): 342-350. (in Chinese)
- [35] BLOM H A P, BAR-SHALOM Y. The interacting multiple model algorithm for systems with Markovian switching coefficients[J]. IEEE Transactions on Automatic Control, 1988, 33(8): 780-783.
- [36] 叶瑾, 许枫, 杨娟, 等. 一种基于多传感器的复合量测 IMM-EKF 数据融合算法[J]. 电子学报, 2020, 48(12): 2326-2330.
- YE J, XU F, YANG J, et al. A composite measurement IMM-EKF data fusion algorithm based on multi-sensor[J]. Acta Electronica Sinica, 2020, 48(12): 2326-2330. (in Chinese)
- [37] 曾浩, 母王强, 杨顺平. 高机动目标跟踪 ATPM-IMM 算法[J]. 通信学报, 2022, 43(7): 93-101.
- ZENG H, MU W Q, YANG S P. ATPM-IMM algorithm for high maneuvering target tracking[J]. Journal on Communications, 2022, 43(7): 93-101. (in Chinese)
- [38] 许红, 谢文冲, 袁华东, 等. 基于自适应的增广状态-交互式多模型的机动目标跟踪算法[J]. 电子与信息学报, 2020, 42(11): 2749-2755.
- XU H, XIE W C, YUAN H D, et al. Maneuvering target tracking algorithm based on the adaptive augmented state interacting multiple model[J]. Journal of Electronics & Information Technology, 2020, 42(11): 2749-2755. (in Chinese)
- [39] XUE L, HAN Y L, NA C N. Robust interacting multiple model unscented particle filter for navigation[J]. Mathematical Problems in Engineering, 2020, 2020(1): 8871358.
- [40] 孔德明, 杨丹, 王书涛. 交互式多模型集自适应协同滤波目标跟踪算法研究[J]. 计量学报, 2021, 42(5): 638-644.
- KONG D M, YANG D, WANG S T. Research on interactive multi-model set adaptive collaborative filtering target tracking algorithm[J]. Acta Metrologica Sinica, 2021, 42(5): 638-644. (in Chinese)

- [41] CROUSE D F. Particle flow filters: Biases and bias avoidance[C]//2019 22th International Conference on Information Fusion. Piscataway: IEEE, 2019: 1-8.
- [42] 赵知劲, 吴斌. OFDM 时变信道的粒子流滤波估计算法[J]. 信号处理, 2016, 32(2): 244-251.  
ZHAO Z J, WU Y. The estimation algorithm of OFDM time-varying channel using particle flow filtering[J]. Journal of Signal Processing, 2016, 32(2): 244-251. (in Chinese)
- [43] LIU J, SAXENA A, GOEBEL K, et al. An adaptive recurrent neural network for remaining useful life prediction of lithium-ion batteries[J]. Annual Conference of the PHM Society, 2010, 2: 1-9.
- [44] 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): 86-94.  
CUI X, CHEN Z Q, LU D H, 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): 86-94. (in Chinese)
- [45] 李英顺, 阚宏达, 郭占男, 等. 基于数据预处理和 VMD-LSTM-GPR 的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(10): 3244-3258.  
LI Y S, KAN H D, GUO Z N, et al. Prediction of remaining useful life of lithium-ion battery based on data preprocessing and VMD-LSTM-GPR[J]. Transactions of China Electrotechnical Society, 2024, 39(10): 3244-3258. (in Chinese)
- [46] 李成, 陈球, 于莹莹, 等. 基于 IWOA-LSSVM 的锂离子电池 RUL 预测[J]. 电气工程学报, 2024, 19(3): 399-411.  
LI C, CHEN Q, YU Y Y, et al. Remaining useful life prediction for lithium-ion batteries based on IWOA-LSSVM[J]. Journal of Electrical Engineering, 2024, 19(3): 399-411. (in Chinese)
- [47] 刘金凤, 陈浩玮, HERBERT Ho-Ching Iu. 基于 VMD 和 DAIPSO-GPR 解决容量再生现象的锂离子电池寿命预测研究[J]. 电子与信息学报, 2023, 45(3): 1111-1120.  
LIU J F, CHEN H W, IU H H C. Li-ion batteries life prediction based on variational modal decomposition and DAIPSO-GPR to solve the capacity regeneration phenomenon[J]. Journal of Electronics & Information Technology, 2023, 45(3): 1111-1120. (in Chinese)

#### 作者简介



王帅 女, 1985 年 8 月生, 山东莱州人. 福建师范大学讲师. 主要研究方向为故障诊断、寿命预测.  
E-mail: wangshuaiss@fjnu.edu.cn



李义婷 女, 1998 年 9 月生, 福建三明人. 福建师范大学硕士研究生. 主要研究方向为寿命预测、机器学习.  
E-mail: lyt2018zy@hotmail.com



陈黎飞 男, 1972 年 12 月生, 福建福州人. 福建师范大学教授、博士生导师. 主要研究方向为机器学习与数据挖掘.  
E-mail: clfei@fjnu.edu.cn



苏小红 女, 1966 年 10 月生, 黑龙江哈尔滨人. 哈尔滨工业大学教授. 主要研究方向为智能软件工程、寿命预测.  
E-mail: sxh@hit.edu.cn



周寿斌 男, 1974 年 8 月生, 江苏高邮人. 江苏华富储能新技术股份有限公司技术中心主任. 主要研究方向为储能材料及产品的研发、高安全性动力电池及其热管理.  
E-mail: 595085743@qq.com