

DOI: 10.19783/j.cnki.pspc.231034

# 基于改进粒子滤波的锂离子电池剩余寿命预测

刘博<sup>1</sup>, 尹杰<sup>1</sup>, 李然<sup>2</sup>

(1. 哈尔滨理工大学传感器与可靠性工程研究所, 黑龙江 哈尔滨 150080;  
2. 汽车电子驱动控制与系统集成教育部工程研究中心, 黑龙江 哈尔滨 150080)

**摘要:** 针对锂离子电池剩余寿命预测精度低、泛化能力差等问题, 提出基于改进粒子滤波的预测方案。首先, 提出双高斯模型作为退化经验模型, 拟合锂离子电池的容量退化过程。然后, 通过先验知识设置退化模型的初始参数, 并利用粒子滤波方法进行参数更新。针对预测过程中出现的粒子退化问题, 提出高斯混合方法进行粒子重采样, 拟合重采样过程中粒子复杂的非线性分布和长尾分布, 保证预测结果的概率密度分布状况均匀且集中。最后在不同的数据集上进行了实验验证, 结果表明所提出的改进粒子滤波方案具有较高的精度和较强的鲁棒性。

**关键词:** 锂离子电池; 剩余寿命预测; 粒子滤波; 高斯混合模型

## Improved particle filter algorithm for remaining useful life prediction of lithium-ion batteries

LIU Bo<sup>1</sup>, YIN Jie<sup>1</sup>, LI Ran<sup>2</sup>

(1. Institute of Sensor and Reliability Engineering, Harbin University of Science and Technology, Harbin 150080, China;  
2. Automotive Electronic Drive Control and System Integration Engineering Research Center,  
Ministry of Education, Harbin 150080, China)

**Abstract:** A prediction method based on improved particle filtering is proposed to improve the low accuracy and poor generalizability of the remaining life prediction of lithium-ion batteries. First, a double Gaussian model is taken as a degradation empirical model to fit the capacity degradation process of lithium-ion batteries. Then the initial parameters of the degradation model are set by using a priori knowledge, and the particle filtering method is used to update the parameters. The Gaussian mixture method for particle resampling is proposed to solve the particle degradation problem. This fits the complex nonlinear distribution and long-tailed distribution of particles in the resampling process, and ensures that the probability density distribution status of the prediction results is uniform and concentrated. Finally, experimental validation is carried out on different datasets, and the results show that the improved particle filtering method proposed has high accuracy and strong robustness.

This work is supported by the Natural Science Foundation of Heilongjiang Province (No. LH2022E088).

**Key words:** Li-ion battery; remaining useful life; particle filter; Gaussian mixture model

## 0 引言

锂离子电池凭借其污染小、循环寿命长的优势被广泛应用于新能源行业<sup>[1]</sup>。但是在反复使用过程中, 电池内部的化学反应会产生副产物堆积, 电解液中溶剂将蒸发和分解, 电极材料也会遭到损耗<sup>[2]</sup>。这些寿命退化因素会导致锂离子电池容量衰减、循环性能下降, 当退化到一定的阈值时电池会失效, 丧失提供能源的能力, 并且存在漏电、短路的风险, 为其所在系统带来严重的威胁<sup>[3-4]</sup>。因此, 对锂离子电池剩余使用寿命(remaining useful life, RUL)的精准

预测成为评估电池设备系统安全性和可靠性的热门研究方向。

当前主流的电池 RUL 预测方案主要分为基于深度学习<sup>[5]</sup>的预测方法和基于模型<sup>[6]</sup>的预测方法。基于深度学习的预测方法通过挖掘电池运行过程中各性能参数的内在关系, 推测电池的剩余使用寿命, 但此类方法需要一定的数据量作为支撑, 以保证预测模型得到充分训练从而进行准确的寿命预测, 对于小样本数据预测任务的局限性较大<sup>[7]</sup>。而基于模型的预测方法又常包含 3 种: 电化学模型、等效电路模型和退化经验模型。基于电化学模型的方法需要研究外部状态、电荷状态、电解质浓度、扩散系数等老化因素对状态变量的影响, 同时还需考虑电池的内部运行机制和老化机制, 建模过程较为复杂<sup>[8]</sup>。

**基金项目:** 黑龙江省自然科学基金项目资助(LH2022E088);  
教育部联合发展基金项目资助(8091B022133)

基于等效电路模型的参数一旦确定,可较精准地计算标定工作环境和充放电条件下的电池响应和老化问题,但电池机理模型的参数一般是根据电极材料的物理特性得到的,与负载环境、几何形状、材料属性和失效机制强相关,需要相当的先验知识作为基础,实施难度较大<sup>[9]</sup>。

退化经验模型相较于电化学模型和等效电路模型更加灵活,常结合粒子滤波(particle filter, PF)等非线性算法进行改进,对于电池的复杂非线性特性建模更加简单、准确。电池的退化趋势受多方面因素的影响而呈非线性,采用单一的线性模型描述电池的全周期退化过程过于笼统,难以体现退化过程中的细节变化。因此寻求一种可以进行动态变化的参数估计方法对线性模型进行改进是有必要的。文献[10]从放电曲线中提取特征电压作为健康特征,利用改进的粒子滤波算法实时估计特征电压,实现健康状态(state of health, SOH)估计和 RUL 预测。文献[11]将通过电化学阻抗谱测得的传递电阻作为电池的健康指标,并建立了一阶多项式方程拟合电池的退化数据,利用粒子滤波算法对 RUL 进行预测。文献[12]针对电池容量退化的非线性提出一种经验退化模型,利用三步数学变换来提高时间平方根模型的灵活性,使退化模型的初始参数更加精准,结合 PF 算法证明了所提出的方法在 RUL 预测方面具有更高的精度。文献[13]利用混沌粒子群算法对 PF 算法进行改进,驱动粒子的先验分布向高似然概率方向发展,实验结果表明,该方法解决了粒子稀疏的问题,使模型的精度得到提高。尽管利用粒子滤波算法对退化经验模型进行改进的研究已经取得一定进展,但改良方法多为相关算法的补充融合,预测精度及泛化能力受电池本身状态、负载状况和环境条件等因素影响,预测结果的概率密度分布情况较为分散,粒子退化情况有待改良。

因此,本文提出基于改进粒子滤波的锂离子电池 RUL 预测方法。首先结合电池的非线性退化特点,将双高斯模型作为基础退化模型,并根据已知数据进行参数拟合,确定模型参数初值;然后利用粒子滤波算法更新模型参数,提出高斯混合模型进行粒子重采样,缓解粒子退化现象并保证粒子的多样性;最后通过对比实验确定不同退化阶段所适用的粒子重采样方法,并在电池数据集上进行了验证。

## 1 基于容量的退化过程拟合

### 1.1 实验数据

本文采用马里兰大学 CALCE 研究中心的电池日历退化数据进行算法验证。该数据集由 CS2\_35、

CS2\_36、CS2\_37 和 CS2\_38 四组电池的容量退化数据组成<sup>[14]</sup>。CS2 系列电池属于钴酸锂电池,阴极为 LiCoO<sub>2</sub>,阳极为含聚丙烯氯化物的层状石墨,额定容量为 1.1 Ah。试验过程为:首先以 0.55 A 的电流恒流充电,直至截止电压 4.2 V;然后恒压保持,直到充电电流降至 0.05 A,最后以 0.55 A 的电流进行恒流放电,将电压降至 2.7 V。锂离子电池寿命循环试验的结束条件为电池容量降为额定容量的 70%。对于此数据集,阈值容量设置为其额定容量的 80%<sup>[15]</sup>。图 1 为电池数据的容量衰减曲线。

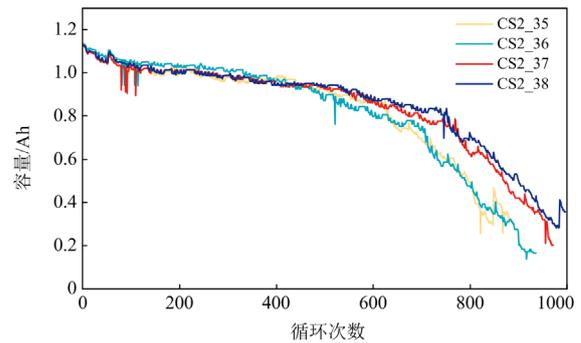


图 1 电池容量衰减曲线

Fig. 1 Decay curve of battery capacity

### 1.2 退化模型建立

在锂离子电池 RUL 预测之前,应建立退化模型。传统上,双指数退化模型和三参数多项式退化模型被广泛应用于电池 RUL 预测。随着充电次数的增加,锂电池的容量会逐渐减少,其下降趋势分为两个阶段,即缓慢阶段和快速阶段,表现为在循环初期容量下降速率较慢,循环后期下降速率变快,整体下降呈现非线性凹凸的退化趋势。对于双高斯模型,其使用两个高斯形式的结构,对于非线性特征有较好的适应性,而且针对两个变化阶段,此模型也能更好地描述。因此,本文选择双高斯模型作为电池的经验退化模型,使得模型的描述能力更强,能更准确地表现电池容量退化趋势与特征。双高斯函数退化模型如式(1)所示。

$$C_k = a_k \cdot e^{-\frac{k-b_k}{c_k}} + d_k \cdot e^{-\frac{k-e_k}{f_k}} \quad (1)$$

式中:  $C_k$  为容量;  $k$  为循环周期次数;  $a_k$ 、 $d_k$  控制双高斯函数的振幅,决定函数整体的峰值;  $b_k$ 、 $e_k$  可以决定电池两个生命退化阶段的中心位置,控制退化拐点的平移;  $c_k$ 、 $f_k$  可以决定函数分布的扩散程度,保证覆盖电池整个生命退化周期。对比双指数模型、多项式模型和修正多项式模型<sup>[16]</sup>的拟合程度,验证双高斯模型的优越性,参数拟合情况如表 1 所示。

表1 不同模型失效阈值前拟合效果比较

Table 1 Comparison of fitting before failure threshold for different models

电池序号	双指数	多项式	修正多项式	双高斯
CS2-35	0.8940	0.8529	0.9001	<b>0.9009</b>
CS2-36	0.9533	0.9388	0.9756	<b>0.9801</b>
CS2-37	0.9607	0.9305	0.9608	<b>0.9610</b>
CS2-38	0.9592	0.9436	<b>0.9561</b>	0.9554

采用确定系数  $R^2$  (R-Square) 作为不同退化模型拟合优度检验的评价指标,  $R^2$  越接近 1, 说明退化模型的拟合情况越好。拟合结果表明, 双高斯模型在拟合电池全周期容量退化数据时具有更好的效果, 可用于作为 RUL 预测的基础模型。容量退化数据拟合曲线如图 2 所示。

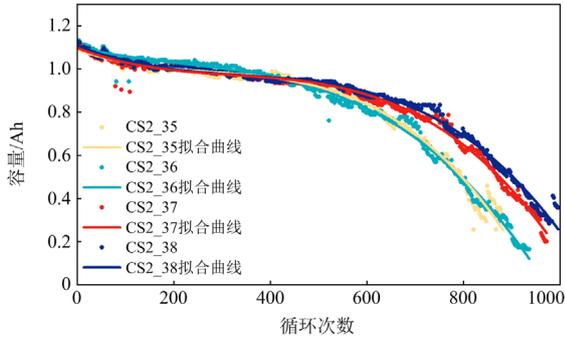


图2 容量退化数据拟合曲线图

Fig. 2 Capacity degradation data fitting curve

电池剩余寿命的退化情况是未知的, 只通过被测电池本身已有的数据进行曲线拟合不符合全周期的退化情况, 具有局限性。因此, 本文将同一型号中已经完全退化的电池容量数据作为被测电池参数预设的先验数据, 取已知电池的拟合方程参数的平均值作为被测电池退化方程的参数初值(具体分组见表 2), 然后通过粒子滤波算法和真实退化数据对参数进行动态估计。表 3 为各电池最终的退化方程初始参数设置。

表2 参数估计实验设置

Table 2 Experimental setup for parameter estimation

预测数据	训练数据
CS2_35	CS2_36, CS2_37, CS2_38
CS2_36	CS2_35, CS2_37, CS2_38
CS2_37	CS2_35, CS2_36, CS2_38
CS2_38	CS2_35, CS2_36, CS2_37

表3 退化方程初始参数设置

Table 3 Initial parameter setting for the degradation equation

电池序号	$a_1$	$b_1$	$c_1$	$a_2$	$b_2$	$c_2$
CS2-35	1.204	-351.13	860.5	0.516	622.5	443.3
CS2-36	1.209	-343.8	860.5	0.515	626.933	423.466
CS2-37	1.195	-314.03	812.83	0.521	600.166	414.033
CS2-38	1.175	-294.83	784.96	0.528	589.6	413

## 2 基于粒子滤波算法的 RUL 预测方法

### 2.1 粒子滤波算法

粒子滤波算法基于贝叶斯滤波原理, 采用蒙特卡洛思想通过一组随机采样的粒子表示潜在的参数值空间, 对参数进行估计<sup>[17]</sup>。这些粒子在每个时间步根据观测数据进行权重更新, 然后通过重采样来反映参数估计的精度。通过迭代更新和重采样, 粒子滤波算法可以逐步逼近真实的参数值, 并提供参数的概率分布<sup>[18]</sup>。对于锂离子电池 RUL 预测任务, 只利用已有数据进行参数拟合确定模型参数的方法无法捕捉电池的动态变化。而粒子滤波算法可以通过观测数据对系统的未知参数进行估计, 满足参数动态变化的要求, 给出预测结果的区间估计值, 因此可以用来进行电池 RUL 预测。

退化模型选定为双高斯模型, 将式(1)的参数离散化可得双高斯模型的状态转移方程和测量方程, 分别如式(2)和式(3)所示。

$$\mathbf{x}_k = [a_k \ b_k \ c_k \ d_k \ e_k \ f_k]^T \rightarrow p(\mathbf{x}_k / \mathbf{x}_{k-1})$$

$$\begin{cases} a_k = a_{k-1} + v_a, v_a \sim N(0, \sigma_a^2) \\ b_k = b_{k-1} + v_b, v_b \sim N(0, \sigma_b^2) \\ c_k = c_{k-1} + v_c, v_c \sim N(0, \sigma_c^2) \\ d_k = d_{k-1} + v_d, v_d \sim N(0, \sigma_d^2) \\ e_k = e_{k-1} + v_e, v_e \sim N(0, \sigma_e^2) \\ f_k = f_{k-1} + v_f, v_f \sim N(0, \sigma_f^2) \end{cases} \quad (2)$$

式中:  $v_r(k) \sim N(0, \delta_r)$  是高斯白噪声, 其均值是 0, 方差为  $\delta_r$ ;  $r(r = a, b, c, d, e, f)$  代表参数的变化顺序; 参数的初始状态值为  $\mathbf{x}_0$ ,  $\mathbf{x}_0 = [a_0, b_0, c_0, d_0, e_0, f_0]$ ;  $p(\mathbf{x}_k / \mathbf{x}_{k-1})$  为先验概率。测量方程为

$$C_k = a_k \cdot e^{-\frac{k-b_k}{c_k}} + d_k \cdot e^{-\frac{k-e_k}{f_k}} + v_k \rightarrow p(C_k / X_k) \quad (3)$$

其中  $v_k \sim N(0, \sigma_v)$  为测量噪声,  $p(C_k / X_k)$  为观测分布。初始化模型参数  $\mathbf{x}_0 = [a_0, b_0, c_0, d_0, e_0, f_0]$ , 由先验分布  $P(\mathbf{x}_0)$  生成粒子集  $\{\mathbf{x}_0^i\}_{i=1}^N$ ,  $i = (1, N)$ ,  $N$  为粒子总数, 所有粒子初始化权重  $\omega_0^i = 1/N$ , 利用 PF

算法更新状态。 $x_k$  的后验概率密度函数  $p(x_k / C_{k-1})$  分预测和更新两步进行计算, 其中预测步为

$$p(x_k / C_{k-1}) = \int p(x_k / x_{k-1}) p(x_{k-1} / C_{k-1}) dx_{k-1} \quad (4)$$

当观测到测量值  $C_k$  时, 状态方程的  $x_k$  可更新为

$$p(x_k / C_k) = \frac{p(C_k / x_k) p(x_k / C_{k-1})}{\int p(C_k / x_k) p(x_k / C_{k-1}) dx_k} \quad (5)$$

为避免进行积分运算, 利用一组带有权重的粒子  $\omega_k^i (i=1, 2, \dots, N, N$  代表粒子总数) 来近似后验概率密度函数, 计算样本的期望值近似状态的估计值。通常情况下无法在状态方程的后验概率密度函数的  $p(x_k / C_k)$  中直接进行采样, 因此采用计算粒子的重要性并进行重采样的方法解决此问题。粒子  $x_k^i$  在第  $k$  次循环中计算如式(6)所示。

$$x_k^i \sim q(x_k^i | x_{k-1}^i, C_0^i) = p(x_k^i | x_{k-1}^i) \quad (6)$$

则  $\omega_k^i$  的近似后验概率密度函数(粒子重要性)可表示为

$$\omega_k^i = \omega_{k-1}^i \frac{p(C_k / x_k^i) p(x_k^i / x_{k-1}^i)}{q(x_k^i / x_{k-1}^i, S_k)} \quad (7)$$

式中,  $S_k$  为测量值。

粒子的权重采用归一标准化:

$$\bar{\omega}_k^i = \frac{\omega_k^i}{\sum_{i=1}^N \omega_k^i} \quad (8)$$

## 2.2 高斯混合重采样

粒子滤波算法在进行多次迭代之后, 会出现粒子退化现象, 即粒子的权重集中在少量的几个粒子上, 而大部分粒子偏离实际值, 粒子的多样性骤降, 影响计算精度。通常采用增加粒子数或采取粒子重采样方法缓解此问题。但增加粒子数将不可避免地增加计算复杂度, 因此本文从重采样方法入手, 提出高斯混合模型进行粒子重采样, 在不增加粒子数量的前提下保证粒子的多样性。

在电池剩余使用寿命预测中, 电池可能会受到多种因素影响, 导致其剩余寿命的分布是多模态的。高斯混合模型能够通过组合多个高斯分布来逼近复杂的多模态分布, 更好地描述电池剩余寿命的变化情况。并且高斯混合模型可以根据实际情况调整高斯分量的权重、均值和标准差, 从而更好地拟合复杂的非线性数据分布和长尾分布。这使得高斯混合模型能够更精确地建模复杂的数据分布, 提高滤波的准确性。具体步骤如下所述。

1) 计算归一化权重。首先, 需要计算每个粒子的权重, 并按照式(8)进行权重归一化。

2) 构建高斯混合模型。将每个粒子的位置作为

高斯混合模型的均值, 并使用一个固定的标准差或根据实际情况设置标准差。高斯混合模型的公式为

$$g_i(x) = \sum_{k=1}^K \pi_k \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(x-\mu_i)^2}{2\sigma_i^2}} \quad (9)$$

式中:  $g_i(x)$  是第  $i$  个高斯成分的概率密度函数;  $\pi_k$  为第  $k$  个高斯分布的权重;  $x$  是随机变量, 其概率密度由所有高斯分布的加权和给出;  $\mu_i$  是第  $i$  个粒子的均值;  $\sigma_i$  是第  $i$  个粒子的标准差。

3) 计算高斯混合模型的权重。使用归一化后的粒子权重作为高斯混合模型中每个分量的权重, 即

$$\omega_i^{\text{gm}} = \omega_i \quad (10)$$

式中:  $\omega_i^{\text{gm}}$  是高斯混合模型中第  $i$  个分量的权重;  $\omega_i$  是归一化后的第  $i$  个粒子的权重。

4) 从高斯混合模型中采样。使用高斯混合模型进行采样, 生成新的粒子集合。假设采样得到的新粒子集合为  $x_{\text{new}}$ , 采样过程为

$$x_{\text{new}} \sim \text{GM}(\mu, \sigma, \omega_i^{\text{gm}}) \quad (11)$$

式中, GM 为高斯混合模型。

5) 更新权重。在高斯混合模型重采样中, 所有生成的新粒子都会被赋予相同的权重, 通常是均匀分布的权重, 即更新后的权重为

$$x_{\text{new}} = \left[ \frac{1}{N}, \frac{1}{N}, \dots, \frac{1}{N} \right] \quad (12)$$

6) 更新粒子集合。使用采样得到的新粒子集合  $x_{\text{new}}$  取代原来的粒子集合, 完成重采样过程。

重采样方案确定后需设置失效阈值  $N_T$ , 如果粒子多样性系数  $\hat{N}_{\text{eff}} < N_T$  则开始重采样, 一般来说  $N_T = 2N/3$ 。重采样后得到权值相同的粒子集  $\{\hat{x}_k^i\}, i=1, \dots, N$ ,  $\hat{x}_k^i$  是粒子  $i$  在第  $k$  次循环时的模型参数  $[a, b, c, d, e, f]$  的估计值。将  $\hat{x}_k^i$  代入双高斯观测方程  $h(\cdot)$  即可得到第  $k$  次的容量估计值  $C_k^i$ ,  $C_k^i = h(x_k^i)$ 。

$$\hat{N}_{\text{eff}} = \frac{1}{\sum_{i=1}^N (\bar{\omega}_k^i)^2} \quad (13)$$

第  $i$  个粒子在第  $k$  次循环时向前  $j$  步的预测值可由式(14)计算。

$$C_{k+j}^i = a_k^i \cdot e^{-\left[\frac{(k+j)-b_k^i}{c_k^i}\right]} + d_k^i \cdot e^{-\left[\frac{(k+j)-e_k^i}{f_k^i}\right]} \quad (14)$$

PDF 估计值通过各样本值和相应的权值表示为

$$p(C_{k+j} | C_{0:k}) \approx \sum_{i=1}^N \omega_k^i \delta(C_{k+j} - C_{k+j}^i) \quad (15)$$

第  $k+j$  次循环的电池容量为

$$C_{k+j} = \sum_{i=1}^N \omega_k^i C_{k+j}^i \quad (16)$$

改进粒子滤波算法预测 RUL 总结如下:

1) 利用 LM 算法获得双高斯函数的初始参数  $x_0 = [a_0, b_0, c_0, d_0, e_0, f_0]$ , 设置粒子个数  $N$ , 重采样阈值  $N_T = 2N/3$ , 预测长度为  $j$ 。

2) 由先验分布  $p(x_0)$  生成粒子集  $\{x_0^i\}_{i=1}^N, i = 1, \dots, N$ , 初始化粒子权重  $\omega_0^i = 1/N$ 。

3) 根据  $x_k^i \sim q(x_k^i | x_{k-1}^i, C_0^i)$  采样得到新粒子集  $x_k^i$ 。其中  $q(x_k^i | x_{k-1}^i, C_0^i)$  为采样密度函数,  $k$  为充放

电循环次数。

4) 通过式(6)计算粒子权重, 并按式(7)进行粒子权重归一化。

5) 高斯混合重采样得到新的粒子集  $\{\tilde{x}_{0:k}^i, 1/N\}_{i=1}^N$ , 其中  $\tilde{x}_{0:k}^i$  是粒子  $i$  在第  $k$  次循环时的系数  $[a, b, c, d, e, f]$ ,  $1/N$  代表权重归一化。

6) 输出第  $k$  次循环的容量估计值  $C_k^i = h(\tilde{x}_k^i)$ 。

基于粒子滤波的锂离子电池 RUL 预测流程如图 3 所示。

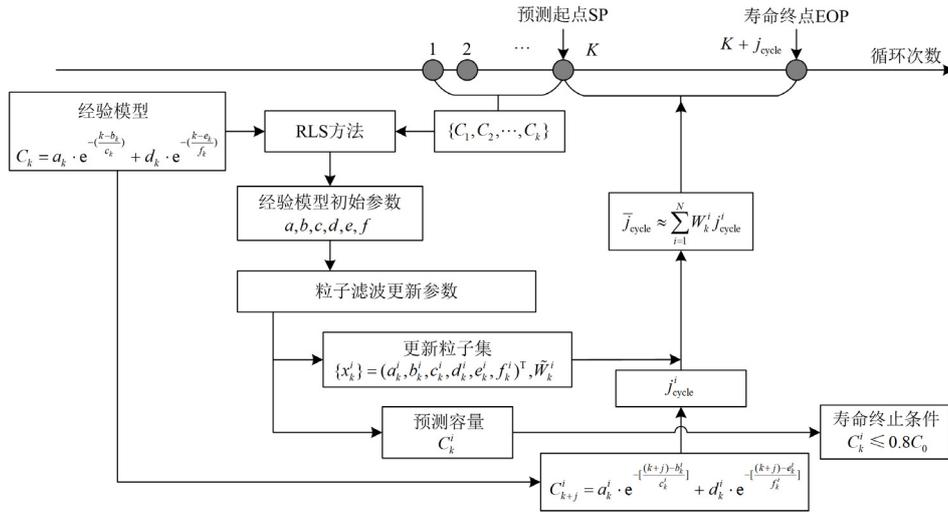


图 3 粒子滤波预测 RUL 流程

Fig. 3 Flow chart of RUL prediction using particle filter method

### 3 实验结果分析

#### 3.1 评价指标

本文的模型评价指标采用平均绝对误差  $E_{MA}$  (mean absolute error, MAE)、均方误差  $E_{RMS}$  (root mean square error, RMSE), 另引入针对锂离子电池容量预测的 RUL 相对误差  $E_R$  (relative error, RE)和相对精度  $P_{re}$ 。

$$E_R = |T_{RUL, pred} - T_{RUL, true}| \quad (17)$$

$$P_{re} = 1 - \frac{|T_{RUL, pred} - T_{RUL, true}|}{T_{RUL, true}} \times 100\% \quad (18)$$

式中:  $T_{RUL, pred}$  和  $T_{RUL, true}$  分别代表电池容量达到失效阈值时, 剩余寿命的预测值和实际值; 在进行容量预测任务时,  $P_{re}$  为主要的评价指标。

#### 3.2 实验与分析

本文在相同的参数设定下将 3 种重采样方法应用于锂离子电池 RUL 预测当中, 随机重采样

(random resampling)记为 RPF<sup>[19]</sup>、系统重采样(system resampling)记为 SPF<sup>[20]</sup>、高斯混合重采样(Gaussian mixed resampling)记为 GPF, 粒子数设为 300, 过程噪声数值设为方程参数初值的十分之一, 在 CACLE 电池数据集上进行验证, 每个测试电池设置两个不同的预测起点。4 块电池在预测起点为 350 次循环时运行 10 次的平均结果如表 4 所示, 图 4 为 3 种方法的预测结果对比。

对于 RUL 预测任务来说,  $E_R$  和  $P_{re}$  作为主要的参考目标, 可以直接反映出预测结果与真实阈值之间的误差。观察结果可以看出, 在起点为 350 次循环的预测任务上, 高斯混合重采样方法(GPF)具有更高的精度。

其中预测结果较差的一组为 CS2\_35 号电池, 观察其退化曲线可以看到, 在预测起点 350 之前, 电池的退化有一个较为明显的容量回升现象, 使得整体退化趋势的单调性发生了变化, 这对预测产生了较大的难度。通过 GPF 算法得到的 RE 值为 13,

表 4 预测起点为 350 次循环时的实验结果

Table 4 Experimental results when prediction start point is 350th cycle

No.	方法	$E_R$	$E_{MA}$	$E_{RMS}$	$R^2$	$P_{re}$	预测阈值	90%置信区间	$t/s$
CS2_35 (516)	RPF	19	0.0113	0.0144	0.8948	0.0368	535	[534.36, 535.57]	37.4648
	SPF	27	0.0128	0.016	0.8699	0.0523	543	[541.33, 543.68]	36.6569
	GPF	13	0.0118	0.0151	0.8837	0.0252	503	[502.11, 504.14]	43.4258
CS2_36 (484)	RPF	13	0.019	0.0252	0.8333	0.0269	471	[470.05, 472.45]	43.4208
	SPF	9	0.0175	0.0236	0.8531	0.0186	475	[474.95, 476.22]	37.6692
	GPF	6	0.0152	0.019	0.9049	0.0124	478	[476.68, 478.44]	37.9704
CS2_37 (555)	RPF	16	0.012	0.0141	0.8318	0.0288	571	[570.54, 572.61]	39.3188
	SPF	8	0.0107	0.0126	0.865	0.0144	547	[546.60, 548.13]	37.8268
	GPF	4	0.0085	0.0104	0.909	0.0072	551	[550.18, 552.72]	45.213
CS2_38 (549)	RPF	14	0.0187	0.0234	0.3056	0.0255	563	[562.29, 564.58]	39.0884
	SPF	12	0.0189	0.0233	0.3116	0.0219	537	[536.85, 538.57]	37.5266
	GPF	3	0.0142	0.0174	0.6146	0.0055	546	[545.07, 547.24]	44.0681

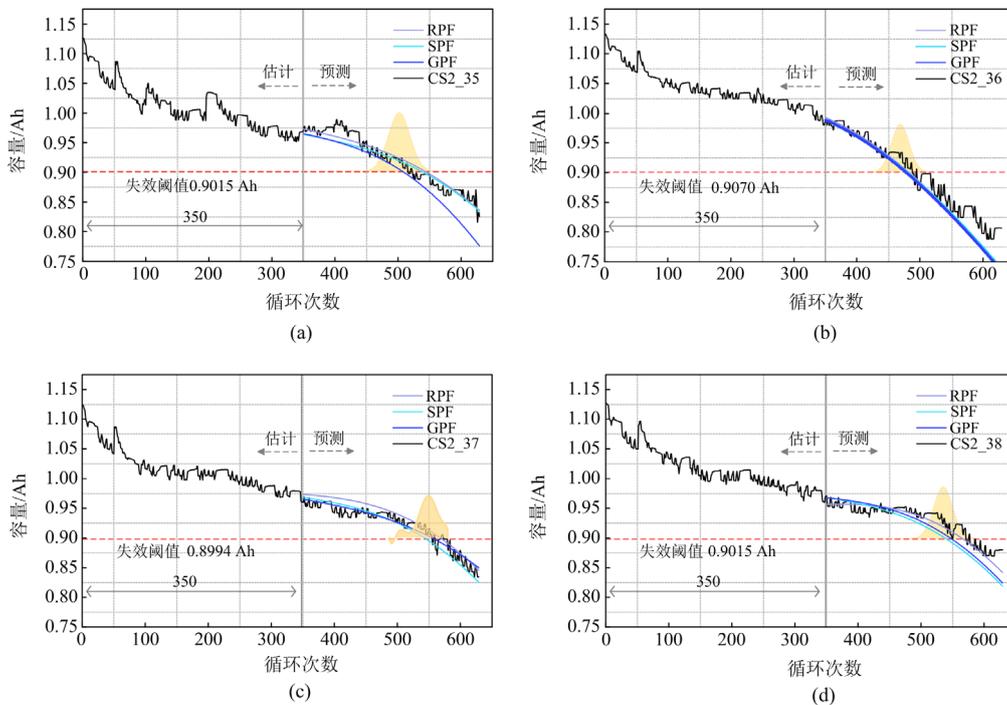


图 4 循环周期为 350 时的 RUL 预测

Fig. 4 RUL prediction of 350th cycle

与真实退化阈值相隔 13 个循环周期，预测结果的 PDF 区间为[527.11, 530.14]，离真实的失效周期 516 相差较近，并且其  $P_{re}$  为 0.0252，低于 RPF 算法的 0.0368 和 SPF 算法的 0.0523。在 4 组预测任务中，GPF 算法的最小预测误差可以达到 3 个循环周期，最大预测误差为 13 个循环周期，这样的误差对于循环寿命达到几百次的锂离子电池来说是可以接受的。分析 3 种方法的预测时间，GPF 所用时间最长，SPF 所用时间最短，由于电池 RUL 预测任务属于离线预

测，对于时效性要求较低，所以预测时间符合实验要求。鉴于电池退化过程是动态的，增设其他的预测起点进行实验验证是有必要的，表 5 为预测起点为 450 次循环时运行 10 次的平均结果，图 5 为具体的退化情况。

以第 450 次循环为预测起点进行预测时 GPF 算法依然具有更高的精度，最小 RE 误差可达 2 次循环，并且整体的 PDF 区间更窄，稳定性更高。通过分析算法原理可知：

表 5 预测起点为第 450 次循环时的实验结果

Table 5 Experimental results when prediction start point is 450th cycle

No.	方法	$E_R$	$E_{MA}$	$E_{RMS}$	$R^2$	$P_{re}$	预测阈值	90%置信区间	$t/s$
CS2_35 (516)	RPF	6	0.0258	0.0341	-0.3551	0.0116	522	[521.10, 523.12]	35.3106
	SPF	12	0.0172	0.0237	0.3475	0.0233	528	[526.97, 528.61]	32.9158
	GPF	5	0.0179	0.0251	0.269	0.0097	511	[510.30, 512.45]	39.1606
CS2_36 (484)	RPF	5	0.0206	0.0259	0.6681	0.0103	489	[488.24, 480.96]	36.4744
	SPF	13	0.0267	0.0312	0.5191	0.0269	497	[496.24, 498.17]	32.8683
	GPF	2	0.0183	0.0238	0.7204	0.0041	486	[485.08, 486.90]	39.2859
CS2_37 (555)	RPF	7	0.0064	0.0079	0.9427	0.0126	562	[561.64, 562.73]	37.7158
	SPF	8	0.0069	0.0085	0.9333	0.0144	547	[545.89, 547.84]	37.1779
	GPF	7	0.0087	0.0105	0.8977	0.0126	548	[546.74, 548.90]	38.2466
CS2_38 (549)	RPF	5	0.0203	0.0234	0.3105	0.0091	544	[543.04, 545.12]	34.3271
	SPF	5	0.0199	0.0227	0.3533	0.0091	544	[543.40, 544.95]	32.8204
	GPF	4	0.0197	0.0231	0.3274	0.0073	545	[544.84, 546.10]	35.9732

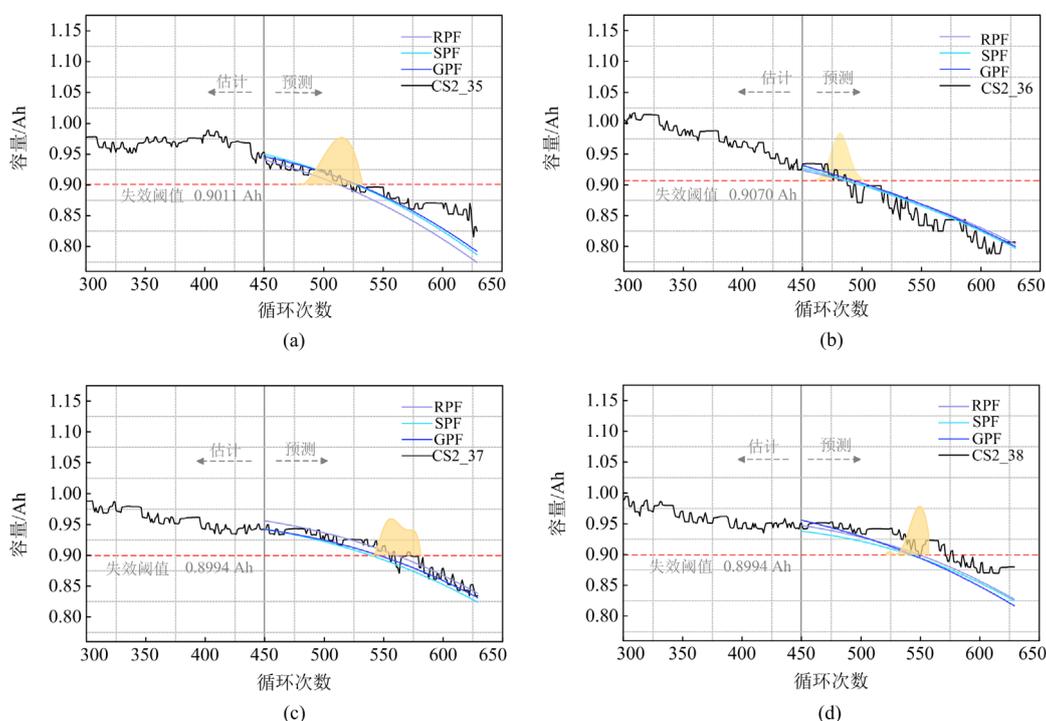


图 5 循环周期为 450 时的 RUL 预测

Fig. 5 RUL prediction of 450th cycle

在生命中期, 电池的剩余寿命相对较长, 系统的状态可能相对稳定。在这种情况下, 高斯重采样可以更好地适应系统的状态分布, 根据粒子的权重计算出高斯混合分布, 从该高斯混合分布中采样新的粒子。这样可以准确地反映系统状态的分布, 提高预测的精度。

在生命后期, 其剩余寿命已经减少到较低的值。这种情况下, 由于电池接近失效, 系统的状态可能变得更加不确定, 高斯混合模型展现出较强的鲁棒性, 更广泛的粒子分布范围及更高的采样效率保证

预测结果的精度。

随着预测起点的后移, 预测精度也逐渐变高, 说明真实数据越多参数估计越准确。另外, RPF 和 SPF 方法分别在不同的预测任务中出现了粒子退化现象, 预测结果 PDF 部分不够均匀, 预测结果会集中在权重比较大的几个粒子上, 从而导致误差结果偏差较大, 部分结果如图 6 所示。而 GPF 方法在全部的预测任务中预测结果 PDF 分布更加集中, 可靠性更高。

此外, 为进一步证明本文所提方法的有效性,

在 NASA 数据集<sup>[21]</sup>上与现有的 3 种不同领域的预测方案进行实验对比, 分别为 UPF-OCS<sup>[22]</sup>、ALF-PF-LSTM<sup>[23]</sup>和 AUKF-GASVR<sup>[24]</sup>。粒子数设为 200, 预测起点设为 60, 失效阈值定为初始容量的 80%, 评价指标选择 RE、RMSE 和  $P_{re}$ , 结果取 10 次重复实验的均值, 对比结果如表 6 所示。观察对比结果可以发现, 本文所提方法具有较好的预测精度。并且本文提出的方案在不同的实验数据集上, 都能给出较为精准的点估计值和区间估计值, 证明

本文所提方法可靠性较高, 可以为锂离子电池的健康管理提供有效帮助。

### 4 结论

本文采用了改进粒子滤波算法对锂离子电池 RUL 进行预测。首先选定双高斯退化模型来描述锂离子电池容量退化趋势, 并且以最大  $R^2 = 0.9801$  的拟合优度验证了所选模型的有效性。然后利用粒子滤波算法对退化模型进行参数估计, 并采用高斯混合模型改进粒子重采样过程。最后对比不同粒子重采样方法的预测误差及 RUL 的概率分布情况, 证明所提出的改进方法具有更高的精度, 全阶段实验误差可以控制 RE 在 13 以内, 最小实验误差可以达到 RE 值为 2, 并且预测结果的 PDF 分布更加均匀且集中。同时在不同数据集上的横向对比结果表明, 本文提出的改进粒子滤波算法在保证鲁棒性的同时, 能够有效提高锂离子电池剩余寿命的预测效果, 并且预测耗时满足任务要求, 可以为锂离子电池的 RUL 预测提供参考。

### 参考文献

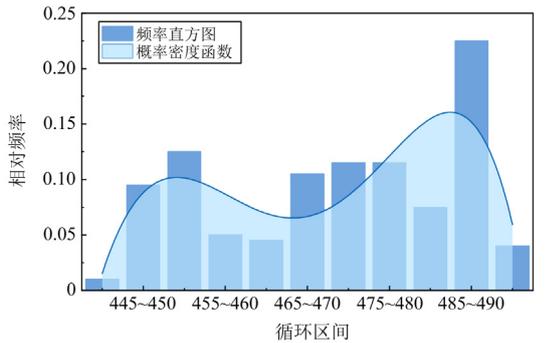
[1] 张朝龙, 赵筛筛, 何怡刚. 基于集成经验模态分解与集成机器学习的锂离子电池剩余使用寿命预测方法[J]. 电力系统保护与控制, 2023, 51(13): 177-186.  
ZHANG Chaolong, ZHAO Shaishai, HE Yigang. Remaining useful life prediction method for lithium-ion batteries based on ensemble empirical mode decomposition and ensemble machine learning[J]. Power System Protection and Control, 2023, 51(13): 177-186.

[2] 晋殿卫, 顾则宇, 张志宏. 锂电池健康和剩余寿命预测算法研究[J]. 电力系统保护与控制, 2023, 51(1): 122-130.  
JIN Dianwei, GU Zeyu, ZHANG Zhihong. Lithium battery health degree and residual life prediction algorithm[J]. Power System Protection and Control, 2023, 51(1): 122-130.

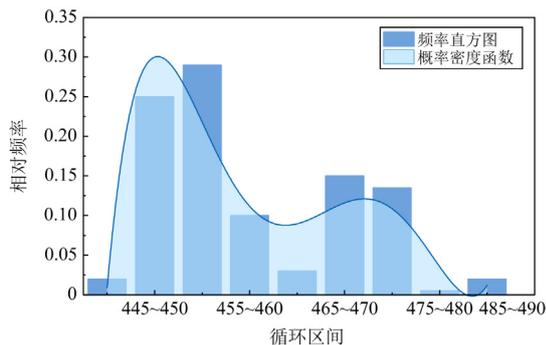
[3] 蔡涛, 张钊诚, 袁奥特, 等. 锂离子电池储能安全管理中的机器学习方法综述[J]. 电力系统保护与控制, 2022, 50(24): 178-187.  
CAI Tao, ZHANG Zhaocheng, YUAN Aote, et al. Review of machine learning for safety management of li-ion battery energy storage[J]. Power System Protection and Control, 2022, 50(24): 178-187.

[4] XIE Qilong, LIU Rongchuan, HUANG Jihao, et al. Residual life prediction of lithium-ion batteries based on data preprocessing and a priori knowledge-assisted CNN-LSTM[J]. Energy, 2023, 281: 128232.

[5] LÜ Guangzheng, ZHANG Heng, MIAO Qiang. Parallel state fusion LSTM-based early-cycle stage lithium-ion



(a) RPF在CS\_36的350起点的RUL预测



(b) SPF在CS\_38的350起点的RUL预测

图 6 RPF 和 SPF 的部分预测结果

Fig. 6 Partial forecast results for RPF and SPF

表 6 其他方法的预测结果比较

Table 6 Comparison of prediction results of other methods

No.	方法	$E_R$	$E_{RMS}$	$P_{re}$
B0005	UPF-OCS	2	0.040	0.971
	ALF-PF-LSTM	2	0.018	0.971
	AUKF-GASVR	0	0.023	1
	<b>GPF</b>	1	0.016	0.990
B0006	UPF-OCS	3	0.044	0.944
	ALF-PF-LSTM	7	0.029	0.868
	AUKF-GASVR	10	0.051	0.689
	<b>GPF</b>	1	0.016	<b>0.992</b>
B0007	UPF-OCS	7	0.048	0.911
	ALF-PF-LSTM	3	0.005	0.961
	AUKF-GASVR	3	0.013	0.961
	<b>GPF</b>	2	0.014	<b>0.976</b>

- battery RUL prediction under Lebesgue sampling framework[J]. Reliability Engineering & System Safety, 2023, 236: 109315.
- [6] WANG Shunli, FERNANDEZ C, FAN Yongcun, et al. A novel safety assurance method based on the compound equivalent modeling and iterate reduce particle-adaptive Kalman filtering for the unmanned aerial vehicle lithium ion batteries[J]. Energy Science & Engineering, 2020, 8: 1484-1500.
- [7] WU Jiaju, KONG Linggang, CHENG Zheng, et al. RUL prediction for lithium batteries using a novel ensemble learning method[J]. Energy Reports, 2022, 8: 313-326.
- [8] XU Zhicheng, WANG Jun, LUND P D, et al. Co-estimating the state of charge and health of lithium batteries through combining a minimalist electrochemical model and an equivalent circuit model[J]. Energy, 2022, 240: 122815.
- [9] YANG Jufeng, CAI Yingfeng, MI C C. State-of-health estimation for lithium-ion batteries based on decoupled dynamic characteristic of constant-voltage charging current[J]. IEEE Transactions on Transportation Electrification, 2022, 8(2): 2070-2079.
- [10] LI Penghua, ZHANG Zijian, XIONG Qingyu, 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.
- [11] 王学远, 李日康, 魏学哲, 等. 基于传荷电阻的锂离子电池剩余寿命预测研究[J]. 机械工程学报, 2021, 57(14): 105-117.
- WANG Xueyuan, LI Rikang, WEI Xuezhe, et al. Study on remaining useful life prediction of lithium-ion batteries based on charge transfer resistance[J]. Journal of Mechanical Engineering, 2021, 57(14): 105-117.
- [12] MENG Fanbing, YANG Fangfang, YANG Jun, et al. A power model considering initial battery state for remaining useful life prediction of lithium-ion batteries[J]. Reliability Engineering & System Safety, 2023, 237: 109361.
- [13] YE Lihua, CHEN Sijian, SHI Yefan, et al. Remaining useful life prediction of lithium-ion battery based on chaotic particle swarm optimization and particle filter[J]. International Journal of Electrochemical Science, 2023, 18(5): 100122.
- [14] HE Wei, WILLIARD N, OSTERMAN M, et al. Prognostics of li-ion batteries based on Dempster-Shafer theory and the Bayesian Monte Carlo method[J]. Power Sources, 2011, 196(23): 10314-10321.
- [15] WANG Haiyang, SONG Wanqing, ZIO E, et al. Remaining useful life prediction for lithiumionbatteries using fractional brownian motion and fruit-fly optimization algorithm[J]. Measurement, 2020, 161: 1-9.
- [16] SUN Yongquan, HAO Xueling, PECHT M, et al. Remaining useful life prediction for lithium-ion batteries based on an integrated health indicator[J]. Microelectronics Reliability, 2018, 88: 1189-1194.
- [17] MO'ATH E D, MAHER A G, MA'D E D, et al. Physics-based model informed smooth particle filter for remaining useful life prediction of lithium-ion battery[J]. Measurement, 2023, 214: 112838.
- [18] LI Penghua, ZHANG Zijian, XIONG Qingyu, 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.
- [19] 焦自权, 范兴明, 张鑫, 等. 基于改进粒子滤波算法的锂离子电池状态跟踪与剩余使用寿命预测方法[J]. 电工技术学报, 2020, 35(18): 3979-3993.
- JIAO Ziquan, FAN Xingming, ZHANG Xin, et al. State tracking and remaining useful life predictive method of li-ion battery based on improved particle filter algorithm[J]. Transactions of China Electrotechnical Society, 2020, 35(18): 3979-3993.
- [20] DOUCET A, GODSILL S J, ANDRIEU C. On sequential Monte Carlo sampling methods for Bayesian filtering[J]. Statistics and Computing, 2000, 10(3): 197-208.
- [21] YANG Jinsong, FANG Weiguang, CHEN Jiayu, et al. A lithium-ion battery remaining useful life prediction method based on unscented particle filter and optimal combination strategy[J]. Journal of Energy Storage, 2022, 55: 105648.
- [22] ZHANG Yong, CHEN Liaogehua, LI Yi, et al. A hybrid approach for remaining useful life prediction of lithium-ion battery with adaptive levy flight optimized particle filter and long short-term memory network[J]. Journal of Energy Storage, 2021, 44: 103245.
- [23] XUE Zhiwei, ZHANG Yong, CHENG Cheng, et al. Remaining useful life prediction of lithium-ion batteries with adaptive unscented Kalman filter and optimized support vector regression[J]. Neurocomputing, 2020, 376: 95-102.

收稿日期: 2023-08-11; 修回日期: 2023-10-03

作者简介:

刘博(1979—), 男, 通信作者, 博士, 副教授, 研究方向为复杂系统可靠性与机器学习; E-mail: liubo1900@hrbust.edu.cn

尹杰(1999—), 男, 硕士研究生, 研究方向为复杂系统可靠性与机器学习。

(编辑 魏小丽)