

DOI:10.11918/202104137

自适应模型与改进粒子滤波的电池 RUL 预测

贺 宁^{1,2}, 钱 成¹, 李若夏³

(1.西安建筑科技大学 机电工程学院,西安 710055;2.智能网络与网络安全教育部重点实验室(西安交通大学),西安 710049; 3.西安建筑科技大学 信息与控制工程学院,西安 710055)

摘要:为提高锂电池运行的安全性和可靠性并维护系统稳定运行,提出一种自适应混合模型与改进粒子滤波(particle filter, PF)算法的锂电池剩余使用寿命(remaining useful life, RUL)预测方法。采用经验模型与神经网络模型结合建立自适应混合模型描述电池容量退化趋势,并使用天牛须搜索(beetle antennae search, BAS)算法优化PF重采样步骤解决粒子多样性丧失问题,从而提高估计精度进而实现RUL的精准预测。应用NASA和CALCE公开的两组不同类型锂电池作为实验对象,验证模型的有效性并通过对比PF与改进PF算法验证RUL预测的准确性。结果表明:自适应混合模型对于电池容量变化的表达能力更强,既能考虑电池内部的参数变化又能反应电池外部环境的变化,基于BAS改进的PF(BAS-PF)方法相较于传统PF算法的估计精度更高而且RUL预测更准确,对于不同的预测起点,两块测试电池的RUL预测误差分别为5.88%、3.92%、1.96%和3.75%、1.25%、0%。自适应混合模型能更加有效地描述电池容量特征,基于自适应混合模型的BAS-PF算法的电池RUL预测能力更好,可靠性更强,有助于提高RUL预测的精度和表现。

关键词: 粒子滤波; 剩余寿命; 优化算法; 神经网络; 锂电池; 混合模型

中图分类号: TM912

文献标志码: A

文章编号: 0367-6234(2022)09-0111-11

RUL prediction for lithium-ion batteries via adaptive modeling and improved particle filter

HE Ning^{1,2}, QIAN Cheng¹, LI Ruoxia³

(1.School of Mechanical and Electrical Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; 2.Ministry of Education Key Laboratory for Intelligent Networks and Network Security (Xi'an Jiaotong University), Xi'an 710049, China; 3.College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: To improve the safety and reliability of lithium-ion battery operation and maintain the stable operation of the system, we proposed a prediction method for remaining useful life (RUL) of lithium-ion batteries based on adaptive hybrid model and improved particle filter (PF) algorithm. An adaptive hybrid model was established by combining empirical model and neural network model to describe the degradation trend of battery capacity, and beetle antennae search (BAS) algorithm was used to optimize the PF resampling step to solve the problem of loss of particle diversity, so as to improve the estimation accuracy and achieve accurate RUL prediction. Two groups of different types of lithium-ion batteries published by NASA and CALCE were selected as the research objects to verify the validity of the model and the accuracy of RUL prediction via comparing PF and improved PF algorithms. Experimental results show that the adaptive hybrid model was more expressive in terms of battery capacity change, which can reflect the variation of the internal parameters as well as the external environment of the battery. Compared with the traditional PF algorithm, the BAS-based improved PF (BAS-PF) method had higher estimation accuracy and more accurate RUL prediction results with the prediction errors of 5.88%, 3.92%, 1.96%, and 3.75%, 1.25%, 0%, respectively, for the two test batteries from different prediction points. The adaptive hybrid model can describe the characteristics of battery capacity more effectively, and the BAS-PF algorithm based on adaptive hybrid model has better prediction ability and greater reliability for battery RUL, which is helpful to improve the prediction accuracy and performance for RUL.

Keywords: particle filter; remaining useful life; optimization algorithm; neural network; lithium-ion battery; hybrid model

收稿日期: 2021-04-29

基金项目: 国家自然科学基金(61903291);

中国博士后科学基金(2019M660257)

作者简介: 贺 宁(1989—),男,副教授,硕士生导师

通信作者: 钱 成, qiancheng@xauat.edu.cn

锂离子电池凭借其能量密度高、循环寿命长、自放电率低等优点在生产生活中具有广泛的应用,但是锂电池在长期的使用过程中,随着充放电次数的不断增加,电池性能衰减影响着电池的寿命,造成电

池故障等问题,更严重的会威胁使用者的安全。锂电池的故障会造成巨大的经济损失及环境破坏^[1]。因此可靠的电池 RUL 预测方法可以保证更加规范有效地使用电池和降低故障率,能改善电池管理水平、提供维修策略和延长电池寿命^[2-7]。

目前,对电池 RUL 的预测方法主要包括模型法和数据法。基于数据的方法不需要电池的具体描述,只需要通过大量实验数据和经验就能大致地预测出电池的 RUL。此类方法只需要获取电池外部环境数据就能建立电池的退化趋势,从而评估电池性能和预测电池寿命^[13]。基于数据的预测方法主要包括:人工神经网络、长短记忆循环神经网络、深度置信网、深度学习、支持向量机等^[8-15]。此类方法虽然都能预测出电池的 RUL,但是当电池内部变化不规律或发生明显变化时,其可行性和有效性将大大降低。而且,此类方法的精度依赖数据规模,当测量数据不足或者数据不准确时,预测性能也会受到明显影响。

基于模型的方法主要采用状态估计法,与数据方法不同,状态估计法主要依靠建立精确的电池模型,模型的准确性将直接影响估计性能。目前的电池模型大致可分为机理模型和经验模型,机理模型通过电池内部化学参数的关系而建立,其模型精度较高,但内部参数较多,关系较为复杂,使用困难较大。由于机理模型建立在实时的化学描述的基础上,所以对于电池未来容量的变化趋势的应用较为困难,而且此模型受到客观因素的影响很难适应性地反应电池退化过程,模型求解复杂,鲁棒性需要进一步提升也是此方法的局限性。不仅如此,机理模型与经验模型相比应用较为困难。而经验模型结构较为简单,描述电池容量的退化趋势也能得到保证,与现有的技术结合更加容易,应用更为广泛。由于电池退化过程表现出较强的非线性和非高斯特征,PF 算法被广泛应用在基于经验模型的电池寿命预测研究中。文献[16]基于双指数退化模型使用扩展 H_∞ PF 算法获得相对精确的动力电池 RUL。文献[17]使用扩展卡尔曼滤波优化 PF 算法采样过程提高估计精度,并实现较为准确的电池 RUL 预测。同样,文献[18-19]使用基于线性优化组合重采样的无迹 PF 算法进一步提升估计精度,并结合马尔科夫链蒙特卡洛方法和无迹卡尔曼滤波来解决粒子退化问题。此外,为了同时获得基于数据和模型方法的优势,相关的融合方法正逐渐成为研究热点。文献[20]提出一种基于支持向量机和自适应卡尔曼滤波算法的电池 RUL 预测方法,实现了多步预测,并取得良好效果。文献[21]使用多层感知机作为描述电池退化行为的工具,并结合改进 PF 算法

更新神经网络参数对电池寿命进行预测。同样,文献[22]使用 PF 训练神经网络参数,并采用长短记忆神经网络对参数进行更新,得到了较好的 RUL 预测结果。

虽然上述方法能够保证一定的预测精度,但是仍存在固有问题:1) 电池模型的精度问题,当电池外部环境如充电电压、充电电流和温度环境温度等发生改变的情况下,电池容量易受影响并发生突变,现有模型无法准确描述电池退化趋势,因此会直接影响到电池寿命的预测结果;2) PF 自身估计精度问题,PF 经多次迭代,其粒子将出现多样性丧失和精度下降的问题,也会影响寿命预测的精度。因此本文提出了一种自适应混合模型来表征电池退化行为,以提高外部环境因素变化的工况下模型的精度和适应性,同时使用 BAS 提升 PF 的粒子多样性,以避免粒子多样性丧失,从而实现更准确的寿命估计。

1 锂电池容量退化模型

本节提出了一种新型电池退化模型,将经验模型与神经网络模型相结合。首先介绍标准经验模型,然后提出一种新型自适应混合模型。

1.1 经验模型

电池容量是反映电池退化的重要指标,经验模型包括线性模型、对数线性模型、多项式模型和指数模型,其中最常用的是指数模型。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,而到了后期下降速率变快,其下降呈现非线性凹凸的退化趋势。对于线性模型,随着循环次数增加,此模型只能描述电池容量递减的趋势,难以捕捉容量的非线性退化特征,对于变化趋势的细节部分,其描述能力较差。对于对数线性模型其描述的容量变化速率较小,只能保证描述电池容量退化的其中一个阶段,对于另外一个阶段此模型将无法精确描述,因此,对数线性模型无法描述两阶段的容量退化趋势。对于多项式模型,其能描述容量退化的非线性特征,但不能保证更好的曲线逼近,特别地,其无法准确地捕捉到两阶段的非线性拐点。对于双指数模型,其使用两个指数形式的结构,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。综上所述,本文选择双指数模型作为电池的经验模型,使得模型的描述能力更强,更能准确表现电池容量退化趋势与特征。双指数模型为

$$Q_1 = f(k) = a_k e^{b_k k} + c_k e^{d_k k} \quad (1)$$

式中: Q_1 表示电池容量, a_k 、 b_k 、 c_k 、 d_k 为电池内部参


数, a_k, c_k 与电池的内阻有关, b_k, d_k 与电池的退化率有关, k 是周期数。

需要注意的是, 该模型虽然可以表现出电池退化的一般特征, 但没有考虑电池外部因素的变化。这会严重影响对电池退化行为的描述。因此, 本文将神经网络模型与经验模型相结合, 此混合模型既考虑了电池内部参数又考虑了环境的变化对电池容量的影响, 因此, 此模型能更好地表征电池的具体退化行为。


1.2 自适应混合模型

神经网络可以有效处理复杂系统内难以解析描述的规律性, 具有很好的泛化能力。为了得到所需的混合模型, 引入人工神经网络模型来描述电池外部环境 with 电池容量之间的关系, 并描述此时的容量退化过程。需要强调的是, 虽然在实际应用中电池容量可以直接测量, 但在工作状态下, 一般无法获得电池的实时容量。文献[13]基于外部数据建立了电池容量的退化模型, 表明电池的容量退化过程与电池的充放电时间、电流、电压、温度等外界因素有着密切的联系。因此, 本文采用神经网络训练获得电池退化模型。

由于径向基(radial basis function, RBF)神经网络具有最佳逼近、训练简洁、学习收敛速度快等特点, 因此使用径向基神经网络作为描述电池外部变量与容量之间非映射关系的模型。图1展示了RBF神经网络的具体结构。



(a) RBF 外部结构



(b) RBF 内部结构

图1 RBF神经网络原理图

Fig.1 Schematic diagram of RBF neural network

如图1所示, 径向基神经网络模型包括3层: 输入层、隐含层和输出层。 $\| \text{dist} \|$ 表示求取输入向量和权值向量的距离, 神经元 radbas 的输入为输入向量和权值向量的距离乘以阈值 b , 高斯函数 radbas 是典型的径向基函数。输入层与隐藏层之间的表达式为

$$\| \text{dist} \| = \| IW_j - X \| = \sqrt{\sum_{i=1}^n (IW_{j,i} - x_i)^2} \quad (2)$$

$$h = \text{radbas}(\| IW_j - X \| b_1) = e^{-(\| IW_j - X \| b_1)^2} \quad (3)$$

隐藏层与输出层的计算关系为

$$y = \text{purelin}(LW_j h + b_2) \quad (4)$$

式中: IW 为输入向量的加权矩阵, LW_j 为隐藏层与输出层之间的权重, b_2 为偏差。

神经网络对电池容量与外部因素的关系表示为

$$Q_2 = \text{NN}(I, U, W, T) \quad (5)$$

式中: Q_2 为电池容量, I, U, W, T 分别为电池充放电电流、电压、外部环境温度和充放电时间。

式(1)描述了电池容量与电池内部参数的关系, 式(5)描述了电池容量与充放电电流等外部变量之间的映射关系。因此, 根据式(1)和式(5), 本文提出使用上述两个容量的综合表达作为电池容量的退化模型, 因此定义容量表达式为

$$Q = \alpha Q_1 + \beta Q_2 \quad (6)$$

式中: α 为经验模型的置信度, β 为神经网络模型置信度, 且 $\alpha + \beta = 1$ 。

式(6)中的混合模型由参数 α 和 β 决定, 在 PF 算法中, 被用作观测方程, 因此, 参数的选取直接决定了预测的精度程度。通过求解优化问题的方法定义模型参数值以期获取最佳的容量表达式。假设上一周期 $k = i$ 的估计容量为

$$Q_L(i) = \alpha Q_1(i) + \beta Q_2(i) \quad (7)$$

通过求解估计容量 Q_L 与真实容量 Q_T 之间的最小均方误差(mean square error, MSE)获得下一时刻所需的混合模型参数 α 和 β :

$$\text{Min}(\text{MSE}) \quad (8)$$

$$\text{MSE} = \frac{1}{t} \sum_{i=1}^t [(Q_L(i) - Q_T(i))^2] \quad (9)$$

在 PF 的每次执行后, 通过计算式(9)获得的模型参数 α 和 β 更新混合模型从而实现模型的自适应调整。其具体过程如下: 1) 输入初始 α 和 β 值, 电池容量真实值 Q_T , 电池充放电电流 I 、电压 U 、外部环境温度 W 和充放电时间 T ; 2) 由式(1)计算经验模型容量 $Q_1(i)$, 由式(5)计算经验模型容量 $Q_2(i)$, 由式(7)得到混合模型容量 $Q_L(i)$; 3) 求解优化问

题式(9);4)得到最优解 α 和 β 作为下一时刻混合模型参数。

2 电池 RUL 预测方法

基于上一节提出的混合模型,本节提出了一种基于 BAS-PF 的 RUL 预测方法。

2.1 BAS-PF

基于 PF 的状态估计所需动态系统模型为

$$x_j = f(x_{j-1}, u_{j-1}) + v_j \quad (10)$$

$$y_j = h(x_j, u_j) + \eta_j \quad (11)$$

其中: x_j 表示系统在 j 时刻的状态, u 表示系统的输入, y_j 表示 j 时刻系统的测量值, f 与 h 分别表示系统的状态转移函数和测量函数, v_j 和 η_j 表示系统的状态噪声和测量噪声。

x_j 的后验概率密度函数 $p(x_j | y_{1:j})$ 的计算分为两步,包括预测和更新^[23-24],预测步为

$$p(x_j | y_{1:j-1}) = \int p(x_j | x_{j-1})p(x_{j-1} | y_{1:j-1})dx_{j-1} \quad (12)$$

根据贝叶斯滤波算法,更新步为

$$p(x_j | y_{1:j}) = \frac{p(y_j | x_j)p(x_j | y_{j-1})}{\int p(y_j | x_j)p(x_j | y_{1:j-1})dx_j} \quad (13)$$

为避免复杂的积分运算,使用一组加权的随机样本(粒子) $\mathcal{X}_j = \{x_j^i, w_j^i\}_{i=1:P}$ 近似后验概率密度函数,其后验概率密度的近似表示为

$$p(x_j | y_{1:j}) \approx \sum_{i=1}^P w_j^i \delta(x_j - x_j^i) \quad (14)$$

其中: P 为一组随机样本中的样本的个数(粒子数), i 为该组样本的第 i 个样本, δ 为狄拉克函数。

在概率密度函数 $p(x_j | y_{1:j})$ 中抽取粒子集较难,因此定义重要性概率密度函数 $q(x_j^i) = p(x_j^i | x_{j-1}^i)$ 并从其中抽取粒子,此时,粒子权重 w_j^i 的更新由式(15)给出:

$$w_j^i \propto w_{j-1}^i p(y_j | x_j^i) \quad (15)$$

其中 w_j^i 是归一化权重,

$$w_j^i = w_{j-1}^i / \sum_{i=1}^P w_{j-1}^i \quad (16)$$

重采样后,各个粒子的权重为 $1/P$,此时, j 时刻的状态估计值由各个粒子加权而获得

$$\tilde{x} = \sum_{i=1}^P w_j^i x_j^i \quad (17)$$

需要强调的是,PF 算法在经过数次迭代之后,会出现粒子退化,其主要表现为粒子集的权重集中于某个或数个粒子上,导致粒子多样性丧失,从而严重影响估计精度。目前常用的解决粒子退化的方案是重采样,但该方法也会带来粒子贫化问题并影响估计精度。

为了解决上述问题,引入基于 BAS 的重采样过

程,将退化的粒子集优化至高似然值,根据优化阈值条件,产生新粒子集,从而在保证粒子群贴近真实后验分布的同时,增强了粒子的多样性。PF 的估计状态由各个粒子加权获得,然而,在 PF 中,粒子的贫化问题降低了算法的性能。粒子贫化是由于重采样过程中不合理使得粒子多样性丧失,即重采样过程中,高权重粒子会被保留,低权重的粒子会被丢弃,虽然低权重粒子对状态估计影响小,但是其仍包含有用的状态信息。因此使用 BAS 优化 PF 的重采样过程。BAS 优化 PF 的思想是将每个粒子作为天牛个体,通过目标函数分别计算天牛个体的适应度,然后将适应度最高的个体选为最优值。经过一定次数的迭代,使得每个天牛向最优位置靠近,最终得到全局最优解。这样,粒子集不断靠近高似然区,从而提高粒子的多样性和滤波算法的性能。BAS 算法的具体步骤如下:

1)对于 n 维空间优化问题, x_L 表示天牛的左须坐标, x_R 表示右须坐标, x 表示质心坐标, d_0 表示两须距离,天牛朝向位置为 d_{ir} 。则左右须表达式分别为

$$x_L = x + d_0 \cdot d_{ir}/2 \quad (18)$$

$$x_R = x - d_0 \cdot d_{ir}/2 \quad (19)$$

2)对于优化问题 f , 定义天牛前进步长 S_1 , $\tilde{\omega}$ 为调整因子,求取左右两须的值:

$$f_L = f(x_L) \quad (20)$$

$$f_R = f(x_R) \quad (21)$$

如果 $f_L < f_R$, 则天牛向左方向移动 S_1 :

$$x = x + S_1 \cdot (x_L - x_R) + \tilde{\omega} \quad (22)$$

如果 $f_L > f_R$, 则天牛向右方向移动 S_1 :

$$x = x - S_1 \cdot (x_L - x_R) + \tilde{\omega} \quad (23)$$

结合上述算法,具体的 BAS-PF 步骤如下:

步骤 1 设置 PF 算法以及 BAS 算法参数。参数包括:粒子个数 P , 最大迭代次数 T_{\max} , 迭代阈值 L , 移动步长 S_1 , 初始方向 d_0 , 调整因子 $\tilde{\omega}$ 。

步骤 2 从重要性概率密度函数中抽样产生 N 个粒子 $\{x_j^i\}_{i=1}^N$ 作为初始粒子。

步骤 3 更新粒子位置计算各个粒子的适应度,将粒子集作为种群,更新当前个体最优值 p_B 和种群最优值 g_B 。通过引入最新观测量 z 到优化函数中,本文定义似然函数为适应度函数:

$$\text{Min}(\Theta(x_j^i)) = e^{-\frac{(y_j^i - z)^2}{2\sigma^2}} \quad (24)$$

步骤 4 种群移动,更新 p_B 和 g_B 。根据式(22)、(23)计算种群移动位置,并根据式(24)更新个体与种群最优值。

步骤 5 判断循环是否停止。当迭代时间 t 满足 $t < T_{\max}$ 或者种群最优值满足迭代阈值 $g_B < L$

时,则循环结束,否则转到步骤4。

步骤6 根据式(15)、(16)计算各个粒子权重,由式(17)得出估计状态。

2.2 电池 RUL 预测过程

为了实现电池寿命的在线预测,提出一种新型

电池寿命预测算法和电池退化模型,在所提出的模型的基础上更新电池参数,利用 BAS-PF 在线滚动估计电池内部参数。所提出的电池寿命预测方法流程如图2所示。

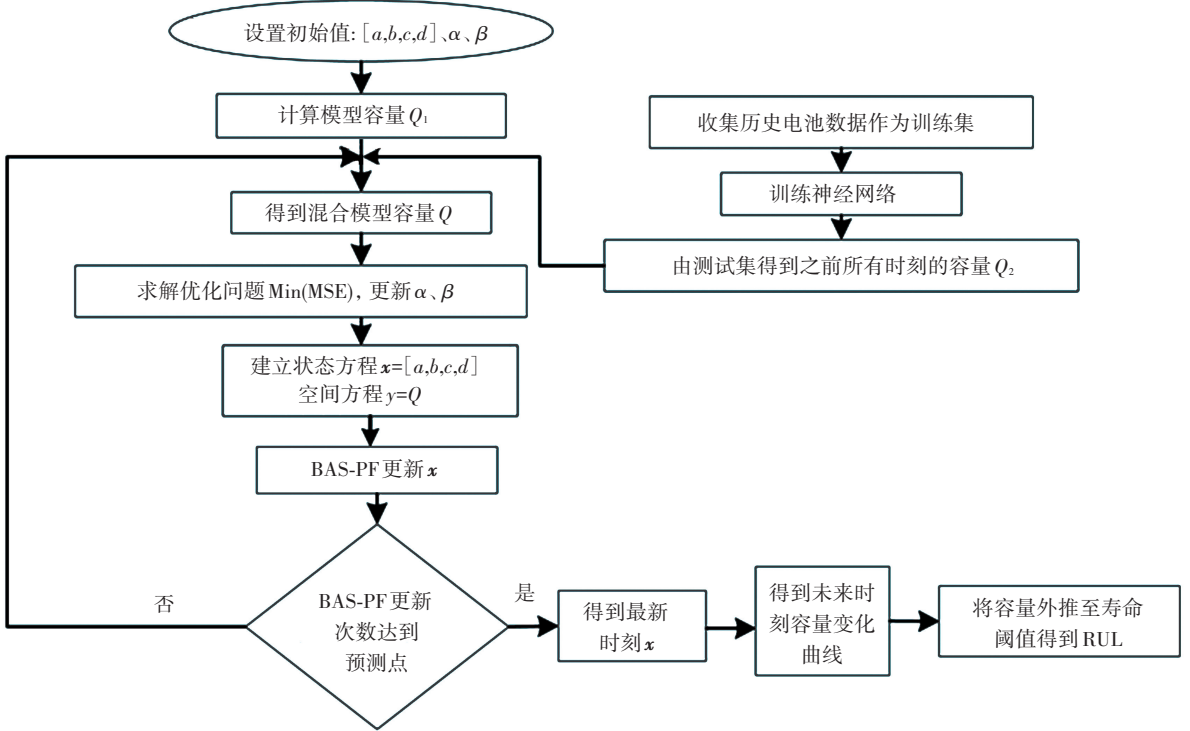


图2 电池寿命预测方法流程图

Fig.2 Flow chart of RUL prediction method

根据上述提出的电池退化模型建立电池的状态空间方程,其中电池的内部参数作为状态量,电池容量作为观测量,状态空间方程表示如下:

$$\mathbf{x}_k = [a_k, b_k, c_k, d_k] \quad (25)$$

$$\begin{cases} a_k = a_{k-1} + \omega_a, & \omega_a \sim N(0, \sigma_a) \\ b_k = b_{k-1} + \omega_b, & \omega_b \sim N(0, \sigma_b) \\ c_k = c_{k-1} + \omega_c, & \omega_c \sim N(0, \sigma_c) \\ d_k = d_{k-1} + \omega_d, & \omega_d \sim N(0, \sigma_d) \end{cases} \quad (26)$$

$$y_k = Q_k = \alpha Q_{1k} + \beta Q_{2k} + \nu_k, \quad \nu_k \sim N(0, \sigma) \quad (27)$$

式中 $N(0, \sigma)$ 表示均值为 0 标准差为 σ 的高斯噪声。

结合上述建立的电池状态空间模型以及提出的 BAS-PF 算法,可以对电池 RUL 进行估计,具体步骤如下:

1) 利用测试电池可用的容量数据,在估计出当前周期电池的内部参数 \mathbf{x}_k 后,电池的容量可以表示为

$$Q_k = \sum_{i=1}^N w_k^i Q_k^i \quad (28)$$

2) 通过外推经验模型,获取 $k + l$ 周期的电池

容量

$$Q_{k+l} = \sum_{i=1}^N w_k^i Q_{k+l}^i \quad (29)$$

3) 在 k 个周期,通过第 i 个粒子的电池寿命可以得出

$$f(x_k^i, L_k^i) = Q_s \quad (30)$$

式中 Q_s 为使用寿命阈值的容量。

4) k 循环周期,电池寿命的后验概率密度为

$$p(L_k | Q_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(L_k - L_k^i) \quad (31)$$

5) 最终,电池的 RUL 可以被估计为

$$L_k = \sum_{i=1}^N w_k^i L_k^i \quad (32)$$

式中 L_k^i 为第 i 个粒子预测的 RUL。

3 实验验证结果

3.1 实验数据集

为了验证所提出的方法预测电池 RUL 的准确性,首先使用来自美国航空航天局的钴酸锂电池数据。使用标号为 B0005、B0006 的电池数据来验证本文的电池寿命预测方法。电池的测试环境条件如下:1) 锂电池被放置在大约 24 °C 的温度环境下进

行充放电实验。锂离子电池(B0005、B0006)在室温下通过3种不同的操作模式(充电、放电和阻抗)。2)用电流为1.5 A的恒定电流和变化的充电电压充电,充电电压直到电池电压达到4.2 V,然后在恒定电压和可变电流条件下充电,直到充电电流降至20 mA。之后,用2 A左右大小的电流放电,直到电池电压分别降至2.7、2.5 V,电池阻抗测量采用电化学阻抗谱0.1~5 000 Hz进行扫描。3)当电池容量下降到额定容量的70%左右时,实验停止。

本次实验中,使用电池容量作为衡量电池健康状态的指标,当电池充放电容量达到额定容量的70%时,可认为电池达到最终寿命。B0005和B0006号电池的退化曲线如图3所示。

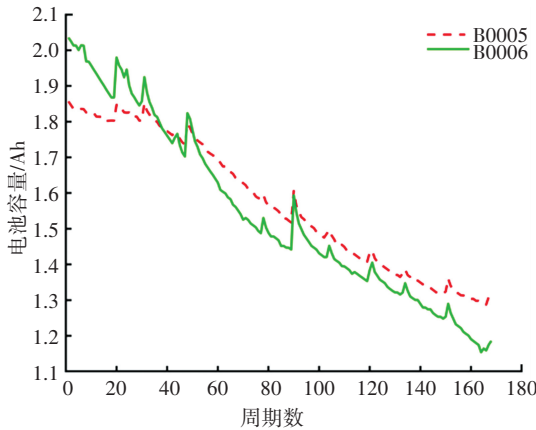




图3 B0005和B0006号电池的退化曲线

Fig.3 Degradation curves of B0005 and B0006 batteries

为进一步考察本文模型和所提算法的普适性,除上述的钴酸锂电池外,还增加了对于磷酸铁锂电池的验证。实验对象为CALCE电池数据组,标号为K2-06的数据组,其中两块电池标号为8-1和10-3,测试条件:1)以2.6 A的恒定电流将电池放电;2)放电直到电压为4.2 V;3)在恒定电压下充电,直到电流小于0.08 A;4)放置2 min,测量内阻;5)放置1 min。两块电池的容量退化曲线如图4所示。



(a)8-1号电池容量退化



(b)10-3号电池容量退化

图4 8-1和10-3号电池的退化曲线

Fig.4 Degradation curves of 8-1 and 10-3 batteries

3.2 锂电池模型验证

首先,验证所提出的电池退化模型的有效性,然后在此模型的基础上对电池RUL进行估计。对于神经网络模型,选取B0005号电池作为神经网络的训练数据,B0006号电池作为测试对象,同样,10-3号电池为训练数据,8-1为测试对象。在神经网络中,充放电电流、电压,实验温度和充放电时间作为输入,输出是电池容量。将测试电池作为参考,混合模型参数的初始值 α 和 β 分别为0.8和0.2。图5展示了钴酸锂电池4种模型的退化曲线。图6描述了描述磷酸铁锂电池4种模型的退化曲线。

首先实验结果如图5所示,其中,神经网络模型容量曲线较真实值相差较大,但能有效描述电池的突变行为;经验模型曲线较神经网络模型更加接近实际,但其描述电池突变的能力相对较差;相较上述两种模型,所提出混合模型不论是固定参数还是自适应参数,其描述电池容量变化的能力都更加准确。




图5 钴酸锂电池不同模型容量退化曲线

Fig.5 Capacity degradation curves of different models for lithium cobaltate batteries




图6 磷酸铁锂电池不同模型容量退化曲线

Fig.6 Capacity degradation curves of different models for lithium iron phosphate batteries

上述实验结果的原因是,神经网络只考虑了外部环境因素的变化,而不能描述电池内部参数变化;而经验模型是通过内部参数描述电池退化趋势,忽略了外部环境变化量的影响。所提出自适应混合模型兼顾了上述两种模型的优势,因而获得性能的提升,此外,由于自适应法通过每一时刻的测量值求解优化问题实时获得模型参数,其性能优于固定参数

模型。

表1给出了上述4种模型与真实值的误差比较,此外,还增加了两组固定参数模型的对比数据。为衡量模型的精确度,使用平均绝对误差(mean absolute error, MAE)和MSE作为衡量模型的指标,可以看出,对于钴酸锂电池,神经网络模型的误差分别为7.1%和0.7%,远高于其他3种模型的误差。其次,经验模型的精确度相较神经网络模型的精确度有较大的提升,误差分别为4.7%和0.37%。而3种固定参数混合模型精度相差较小,其精度都比经验模型高。最后,自适应混合模型的MAE和MSE分别为3.39%和0.29%,其精度对比固定参数模型又有了明显的提升。对于磷酸铁锂电池的模型验证结果如图6所示,可以看出本文所提出的混合模型更加接近于真实状态,从表中的误差结果可以得出,自适应混合模型的MSE和MAE分别为0.141%和1.12%,其误差均小于其他的模型。从模型结果和误差表现可以看出本文所提模型具有更高的精度而且适用于磷酸铁锂电池。综上可以得出,所提出的自适应混合模型具有更好的精度和描述电池容量退化的能力。

表1 不同模型误差对比

Tab.1 Error comparison of different models

| 模型 | MAE/% | | MSE/% | |
|--|-------|--------|-------|--------|
| | 钴酸锂电池 | 磷酸铁锂电池 | 钴酸锂电池 | 磷酸铁锂电池 |
| 经验 | 4.7 | 3.80 | 0.370 | 0.250 |
| 神经网络 | 7.10 | 5.23 | 0.700 | 0.533 |
| 固定参数 ($\alpha = 0.75, \beta = 0.25$) | 4.47 | 2.79 | 0.362 | 0.166 |
| 固定参数 ($\alpha = 0.8, \beta = 0.2$) | 4.45 | 3.31 | 0.354 | 0.192 |
| 固定参数 ($\alpha = 0.85, \beta = 0.15$) | 4.44 | 2.97 | 0.354 | 0.178 |
| 自适应混合 | 3.39 | 1.12 | 0.290 | 0.141 |

3.3 电池 RUL 预测结果

在长时间的循环使用中,锂电池容量会出现明显的退化现象,与其他机械和电气设备相同,锂电池的退化过程是不可逆的,由于锂电池内部存在复杂的物理和化学反应变化,而且化学成分在重复的充放电过程中会发生降解,这导致锂电池性能逐渐下降和可用容量不断减少^[25-26]。由于复杂和非线性的电化学机理和各类应用场景的不同,电池可用容量衰减呈现锯齿状,这是电池容量再生现象所导致的,因此电池容量的衰减变化呈现出非平滑的下降趋势,由于此问题的出现导致对电池剩余使用寿命预测成为的热点和难点问题。

根据预测点之前数据拟合得出经验模型参数并作为PF的初始状态,在PF算法中,粒子的数量设置为100,电池的寿命阈值为1.42 Ah。基于自适应

混合模型,使用改进PF算法对电池状态进行参数估计,其中 $\omega_a \sim \omega_c$ 服从 $N(0, 0.1 \times 10^{-4})$, ν_k 服从 $N(0, 0.1)$ 。钴酸锂电池的PF状态的初始参数为 $[1.57, -0.005\ 576, 0.489, 0.009\ 449]$,磷酸铁锂电池 $[1.823, -0.000\ 134\ 8, -0.010\ 63, -0.168\ 9]$,PF每次更新的参数都作为新的经验模型参数,PF算法和神经网络算法在MATLAB仿真实验平台上实现。为验证所提方法的有效性,分别选取预测开始时间为第50、第70、第90周期。同时使用PF和BAS-PF算法对电池RUL进行预测,并且得到预测点处粒子的概率分布,其预测效果如图7~10所示。图中,分别给出了代表锂电池实际的衰退曲线,预测点之前的估计容量曲线,容量预测值曲线以及锂电池的寿命阈值曲线,并且在图7~9中还标注出不同预测的时间点和预测结果附近的概率密度,图中剩余寿命

指的是周期个数。

对于钴酸锂电池,图 7(a)、7(b)展示了基于自适应混合模型的前 50 个周期的容量数据更新的模型参数,误差由表 2 给出。其中,基于 PF 算法的锂电池 RUL 预测结果为 89 个周期,误差为 12.75%,而基于 BAS-PF 算法的预测结果为 96 个周期,误差为 5.88%。图 8(a)、8(b)是前 70 个周期的数据的预测结果,PF 的预测结果为 109 个周期,误差为 6.86%,BAS-PF 的预测结果分别为 106 个周期和 3.92%。同样,90 个周期数据的预测结果如图 9 所示,基于 PF 方法预测结果是 99 个周期,2.94%的误差,BAS-PF 预测为 104 个周期,误差为 1.96%。由此看出基于 BAS-PF 的预测效果比 PF 的好。由于文章篇幅限制,本文给出了磷酸铁锂电池 50 周期的 RUL 预测结果,如图 10 所示,相较于 PF 算法,所提出的改进 PF 算法在电池容量

的预测准确性上更高,更能反应真实状态,误差分析由表 3 给出,改进 PF 算法的 RUL 误差分别为 3、1、0 个周期而 PF 算法的误差为 7、4、2 个周期,改进算法误差均小于未改进算法。从结果上看,本文所提算法的 RUL 预测精度更高。而且预测表现和钴酸锂电池相同,即改进 PF 算法预测精度更高。

随着预测点周期的增加,钴酸锂电池基于 PF 算法的锂电池 RUL 预测误差分别为 12.75%、6.86%、2.94%,BAS-PF 的预测误差则为 5.88%、3.92%、1.96%。而磷酸铁锂电池的 PF 误差从 8.75%下降到 2.5%,基于 BAS-PF 的误差从 3.75%下降到 0。从表 2、3 中可以观察到,随着预测周期的增加,RUL 的预测结果越精确,而且 BAS-PF 比 PF 方法具有更准确的估计精度和预测结果。综合上述实验结果,本文所提模型和算法对于不同类型的锂电池有较好的适用。

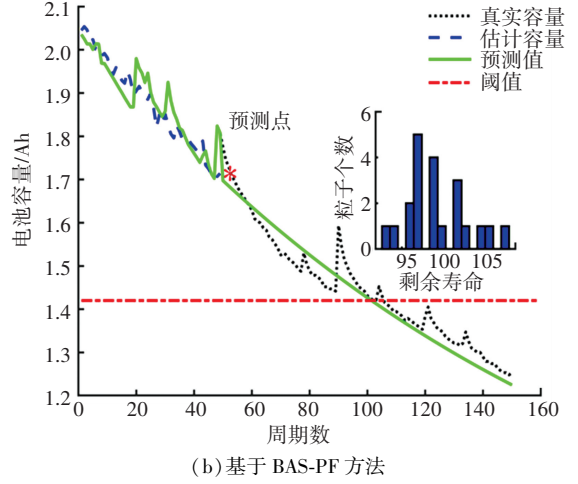



图 7 钴酸锂电池 50 个周期的预测结果

Fig.7 Prediction results for 50 cycles of lithium cobaltate batteries

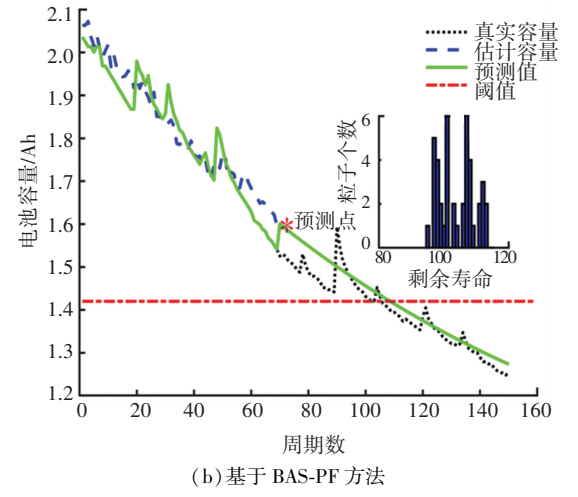



图 8 钴酸锂电池 70 个周期的预测结果

Fig.8 Prediction results for 70 cycles of lithium cobaltate batteries

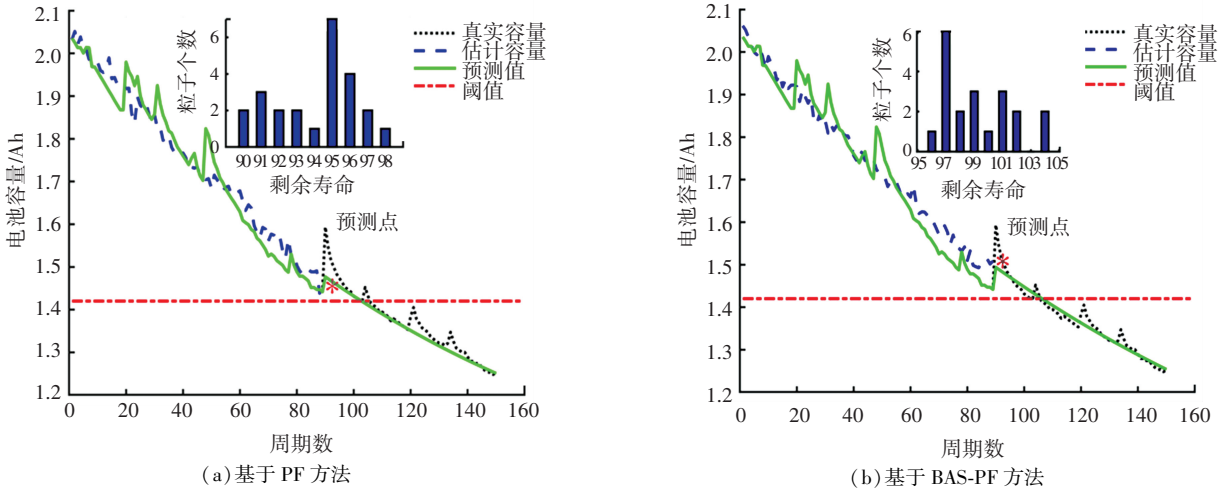


图 9 钴酸锂电池 90 个周期的预测结果

Fig.9 Prediction results for 90 cycles of lithium cobaltate batteries




图 10 磷酸铁锂电池 50 个周期的预测结果

Fig.10 Prediction results for 50 cycles of lithium iron phosphate batteries

表 2 钴酸锂电池 RUL 预测结果

Tab.2 RUL prediction results for lithium cobaltate batteries

| 预测方法 | 预测开始时间 | 实际寿命/周期 | 预测寿命/周期 | 误差/周期 | 相对误差/% |
|-----------|---------|---------|---------|-------|--------|
| PF 算法 | 第 50 周期 | 102 | 89 | 13 | 12.75 |
| | 第 70 周期 | 102 | 109 | 7 | 6.86 |
| | 第 90 周期 | 102 | 99 | 3 | 2.94 |
| BAS-PF 算法 | 第 50 周期 | 102 | 96 | 6 | 5.88 |
| | 第 70 周期 | 102 | 106 | 4 | 3.92 |
| | 第 90 周期 | 102 | 104 | 2 | 1.96 |

表 3 磷酸铁锂电池 RUL 预测结果

Tab.3 RUL prediction results for lithium iron phosphate batteries

| 预测方法 | 预测开始时间 | 实际寿命/周期 | 预测寿命/周期 | 误差/周期 | 相对误差/% |
|-----------|---------|---------|---------|-------|--------|
| PF 算法 | 第 50 周期 | 80 | 87 | 7 | 8.75 |
| | 第 70 周期 | 80 | 84 | 4 | 5 |
| | 第 90 周期 | 80 | 82 | 2 | 2.5 |
| BAS-PF 算法 | 第 50 周期 | 80 | 83 | 3 | 3.75 |
| | 第 70 周期 | 80 | 79 | 1 | 1.25 |
| | 第 90 周期 | 80 | 80 | 0 | 0 |

本文所提出的电池寿命预测方法从原理上能够拓展应用到其他类型的电池。本方法主要包含建模及状态估计两个部分,首先,本文中所提出的混合模型是由神经网络模型和经验模型组合而成,并且模型参数通过求解优化问题实现自适应调整。其中,神经网络模型是使用采集到的外部数据(比如电流和电压)预测当前的电池容量,对于不同的电池模型系统,神经网络模型具有一般性和普适性并能直接使用。而对于经验模型,不同类型的锂电池随着充电次数的增加其容量都是出现逐渐下降的非线性趋势,并且下降速率具有明显的先慢后快的特点,本文使用的双指数模型对于描述此类非线性变化趋势和特点具有较强的能力,所以经验模型对不同类型的锂电池容量下降趋势都有较好的适应性。因此,本文所建立的混合模型对于不同的锂电池都拥有较好的适用性。其次,由于寿命预测所使用的粒子滤波算法是结合所建立的模型基于状态估计获得电池寿命的预测值,一旦模型成功建立,粒子滤波算法便可以基于其自身的收敛特性对不同类型的锂电池进行状态估计,获得其寿命预测结果。因此,基于粒子滤波的寿命预测算法对于不同的锂电池也都具有较好的可行性。综上,本文所提出模型和方法对于不同类型的锂电池有较好的适用性。在后续的研究中,还将针对更多种类的常用锂电池,如三元锂电池、锰酸锂电池等,考察本文方法的普适性。

4 结 论

本文提出了一种自适应混合模型和改进的 PF 算法预测锂电池的 RUL。并通过两组实验验证所提出方法的有效性,主要结论如下:

1) 所提出的自适应混合模型能精确表示电池容量退化特征,拥有更小的误差,MAE 和 MSE 分别为 3.39%、0.29% 和 1.12%、0.141%,远优于其他模型,说明此模型具有更好的描述电池退化趋势的能力。

2) 在建立模型的基础上,使用 BAS 算法对 PF 进行改进,改进 PF 算法具有更佳的估计精度和 RUL 预测结果。对于不同类型锂电池,BAS-PF 的预测误差分别为 5.88%、3.92%、1.96% 和 3.75%、1.25%、0,其误差均低于同期的 PF 算法的误差。说明基于 BAS-PF 算法的估计精度和锂电池的 RUL 预测结果较 PF 更加准确。

3) 预测周期数据越多其 RUL 预测结果越准确,选取 50、70 和 90 个周期为预测点,对于钴酸铁锂电池,其实际的使用寿命为 102 周期,在不同的预测点,预测结果分别为 96、106 和 104 个周期对于磷酸铁锂电池其实际使用寿命为 80 周期,预测结果为 83、79

和 80 个周期。

4) 本文提出的混合模型是神经网络模型与经验模型的组合,采用传统的神经网络模型,考虑改用估计性能更好精确度更高的神经网络代替现有的模型以提高模型精度。更加精确理想的经验模型也有助于提升性能,实现对锂电池 RUL 的精准预测。

参考文献

- [1] 石伟杰,王惠民.基于锂离子电池热特性的 SOH 在线诊断模型研究[J].仪器仪表学报, 2020, 41(8):206
SHI Weijie, WANG Haimin. On-line diagnosis model of SOH based on thermal characteristics of lithium-ion battery[J]. Chinese Journal of Scientific Instrument, 2020, 41(8): 206. DOI: 10.19650/j.cnki.cjsi.J2006393
- [2] ZHANG Lijun, MU Zhongqiang, SUN Changyan. Remaining useful life prediction for lithium-ion batteries based on exponential model and particle filter[J]. IEEE Access, 2018, 6: 17729. DOI: 10.1109/ACCESS.2018.2816684
- [3] MO Baohua, YU Jingsong, TANG Diyin, et al. A remaining useful life prediction approach for lithium-ion batteries using Kalman filter and an improved particle filter[C]// 2016 IEEE International Conference on Prognostics and Health Management (ICPHM). Ottawa: IEEE, 2016: 1. DOI:10.1109/ICPHM.2016.7542847
- [4] LIU Datong, LUO Yue, LIU Jie, et al. Lithium-ion battery remaining useful life estimation based on fusion nonlinear degradation AR model and RPF algorithm[J]. Neural Computing and Applications, 2014, 25(3/4): 557. DOI: 10.1007/s00521-013-1520-x
- [5] GUHA A, VAISAKH K V, PATRA A. Remaining useful life estimation of lithium-ion batteries based on a new capacity degradation model[C]// 2016 IEEE Transportation Electrification Conference and Expo, Asia-Pacific. Busan: IEEE, 2016: 555. DOI: 10.1109/ITEC-AP.2016.7513015
- [6] MA Guijia, ZHANG Yong, CHENG Cheng, et al. Remaining useful life prediction of lithium-ion batteries based on false nearest neighbors and a hybrid neural network [J]. Applied Energy, 2019, 253: 113626. DOI: 10.1016/j.apenergy.2019.113626
- [7] WEI Jingwen, DONG Guangzhong, CHEN Zonghai. Remaining useful life prediction and state of health diagnosis for lithium-ion batteries using particle filter and support vector regression[J]. IEEE Transactions on Industrial Electronics, 2018, 65 (7):5634. DOI: 10.1109/TIE.2017.2782224
- [8] WU Ji, ZHANG Chenbin, CHEN Zonghai. An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks [J]. Applied Energy, 2016, 173: 134. DOI: 10.1016/j.apenergy.2016.04.057
- [9] LI Xiaoyu, ZHANG Lei, WANG Zhenpo, et al. Remaining useful life prediction for lithium-ion batteries based on a hybrid model combining the long short-term memory and Elman neural networks[J]. Journal of Energy Storage, 2019, 21:510. DOI:10.1016/j.est.2018.12.011
- [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. DOI:10.1016/j.jpowsour.2020.228069
- [11] ZHANG Yongzhi, XIONG Rui, HE Hongwen, et al. A LSTM-RNN

- method for the lithium-ion battery remaining useful life prediction [C]// 2017 Prognostics and System Health Management Conference (PHM-Harbin). Harbin: IEEE, 2017;1. DOI: 10.1109/PHM.2017.8079316
- [12] ZHANG Yongzhi, XIONG Rui, HE Hongwen, et al. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries[J]. IEEE Transactions on Vehicular Technology, 2018, 67(7): 5695. DOI: 10.1109/TVT.2018.2805189
- [13] QIN Wei, LYU Huichun, LIU Chengliang, et al. Remaining useful life prediction for lithium-ion batteries using particle filter and artificial neural network[J]. Industrial Management & Data Systems, 2019, 120(2): 312. DOI:10.1108/IMDS-03-2019-0195
- [14] ZHAO Guangquan, ZHANG Guohui, LIU Yuefeng, et al. Lithium-ion battery remaining useful life prediction with deep belief network and relevance vector machine[C]//2017 IEEE International Conference on Prognostics and Health Management (ICPHM). Dallas: IEEE, 2017; 7. DOI: 10.1109/ICPHM.2017.7998298
- [15] SHEN Sheng, SADOUGHI M, CHEN Xiangyi, et al. A deep learning method for online capacity estimation of lithium-ion batteries[J]. Journal of Energy Storage, 2019, 25: 100817. DOI: 10.1016/j.est.2019.100817
- [16] 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
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
- [17] DUAN Bin, ZHANG Qi, GENG Fei, et al. Remaining useful life prediction of lithium-ion battery based on extended Kalman particle filter[J]. International Journal of Energy Research, 2020, 44: 1724. DOI: 10.1002/er.5002
- [18] ZHANG Heng, MIAO Qiang, ZHANG Xin, et al. An improved unscented particle filter approach for lithium-ion battery remaining useful life prediction[J]. Microelectronics Reliability, 2018, 81: 288. DOI: 10.1016/j.microrel.2017.12.036
- [19] ZHANG Xin, MIAO Qiang, LIU Zhiwen. Remaining useful life prediction of lithium-ion battery using an improved UPF method based on MCMC[J]. Microelectronics Reliability, 2017, 75: 288. DOI: 10.1016/j.microrel.2017.02.012
- [20] 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. DOI: 10.1016/j.neucom.2019.09.074
- [21] WU Yi, LI Wei, WANG Youren, et al. Remaining useful life prediction of lithium-ion batteries using neural network and bat-based particle filter[J]. IEEE Access, 2019, 7: 54843. DOI: 10.1109/ACCESS.2019.2913163
- [22] XIE Renyou, MA Rui, PU Sicheng, et al. Prognostic for fuel cell based on particle filter and recurrent neural network fusion structure[J]. Energy and AI, 2020, 2: 100017. DOI:10.1016/j.egyai.2020.100017
- [23] 李天成,范红旗,孙树栋.粒子滤波理论、方法及其在多目标跟踪中的应用[J].自动化学报,2015, 41(12):1981
LI Tiancheng, FAN Hongqi, SUN Shudong. Particle filtering: theory, approach, and application for multitarget tracking[J]. Acta Automatica Sinica, 2015, 41(12):1981. DOI:10.16383/j.aas.2015.c150426
- [24] 贺宁,陈奕昕,贺利乐,等.基于粒子滤波与压缩感知的管道泄漏定位[J].仪器仪表学报,2019,40(12):36
HE Ning, CHEN Yixin, HE Lile, et al. Pipeline leak location based on particle filter and compressed sensing[J]. Chinese Journal of Scientific Instrument, 2019, 40(12): 36. DOI:10.19650/j.cnki.cjsi.1905596
- [25] BARRÉ A, DEGUILHEM B, GROLLEAU S, et al. A review on lithium-ion battery ageing mechanisms and estimations for automotive applications[J]. Journal of Power Sources, 2013, 241: 680. DOI: 10.1016/j.jpowsour.2013.05.040
- [26] LI Yi, LIU Kailong, FOLEY A M, et al. Data-driven health estimation and lifetime prediction of lithium-ion batteries: a review[J]. Renewable and Sustainable Energy Reviews, 2019, 113: 109254. DOI: 10.1016/j.rser.2019.109254

(编辑 魏希柱)

封面图片说明

封面图片来自本期论文“石灰岩矿粉性质对沥青胶浆性能的影响因素及其技术标准”,图片揭示了不同矿粉沥青胶浆冻融前后的微观形貌、微观力学性质的变化特征,通过不同矿粉沥青胶浆冻融前后性能的变化,建立了化学组分、微观形貌、微观力学性质和流变特性与矿粉主要物理化学性质的关系,根据其变化幅度,采用随机森林方法进行了系统的分析。结果表明:矿粉的掺入能够改善沥青胶浆的冻融老化性能,冻融循环后,胶浆粗糙度下降幅度、表面模量提升幅度与矿粉 CaCO_3 含量呈抛物线下降趋势,沥青胶浆黏附力与矿粉 CaCO_3 含量呈直线下降关系,为保持沥青胶浆冻融后性能的稳定,建议矿粉中 CaCO_3 含量不应低于 85%;季冻区的沥青路面比非季冻区更容易发生水损害,与非季冻区相比,季冻区矿粉中 CaCO_3 含量应提高 10%左右。随机森林方法分析表明,矿粉的物理化学性质对胶浆性能影响的主要因素排序:比表面积> CaCO_3 含量>细度指标>塑性指数,比表面积影响沥青与矿粉的反应速度,而 CaCO_3 含量影响其反应的充分性。所提出的石灰岩矿粉母岩技术要求与矿粉的综合分级技术标准,对季冻区沥青路面路用矿粉的分级、选用和生产控制具有重要作用,并能大幅度降低沥青面层的材料损伤。

(图文提供:王龙.哈尔滨工业大学 交通科学与工程学院)