

基于粒子滤波算法的锂离子电池剩余寿命预测方法研究^①

张 凝^{②***} 徐皑冬^{*} 王 锐^{*} 韩晓佳^{***} Seung Ho Hong^{***}

(^{*}中国科学院沈阳自动化研究所 沈阳 110016)

(^{**}中国科学院大学 北京 100049)

(^{***} Department of Electronic Systems Engineering, Hanyang University, Ansan 15588, Korea)

摘要 运用粒子滤波算法,进行了锂离子电池剩余寿命(RUL)的预测,提出了一种基于模型法和数据驱动法相融合的简单有效的RUL预测方法。该方法通过模型法和数据驱动法的融合,将双指数组经验退化模型进行变形,以减少模型参数,降低参数训练难度,利用粒子滤波算法跟踪电池容量衰退的过程;为提高预测精确度,引入自回归(AR)时间序列模型修正状态空间方程的观测值。实验证实,该方法可以有效地预估出锂电池的剩余寿命。

关键词 锂离子电池, 剩余寿命(RUL), 粒子滤波, 双指数组经验模型

0 引言

目前飞机、电动汽车、笔记本电脑、智能手机都广泛使用了锂离子电池。由于锂离子电池具有高能量密度特点,相比于铅酸电池、镍镉电池或者镍氢电池,其单位体积存储电能最高,加上其容量大,放电平稳等优势^[1,2],因此锂离子电池将成为新能源发展的重点。

电池在使用过程中,固体电解质界面(solid electrolyte interface, SEI)膜的形成、电池内部电解液分解以及电极材料分解、剥落或被腐蚀等,都会造成电池性能的退化^[3,4],致使电池的安全性、可靠性下降。而电池性能退化的主要特点是电池容量的下降,因而在实际应用中,需要在电池寿命结束之前更换电池。理论上规定,当电池容量达到额定容量的80%时,就认为该电池无法满足其性能要求,应该被更换。在许多应用中,如航空航天系统、电动汽车、不间断电源系统中,电池性能的衰退可能带来毁灭性的后果,据艾默生网络能源进行的一项调查显示,

数据中心宕机最大的原因是不间断电源的失效,而对于数据中心来说,一个小时的宕机会导致数百万美元的损失^[5]。这些情况往往要通过严格的维护计划来避免,而这些维护计划通常价格昂贵,也需要系统定期停止工作,接受检查。故障预测与健康管理(prognostic and health management, PHM)致力于寻找一种高效的方法,该方法通过评估电池的某些指标预测其剩余寿命(remaining useful life, RUL),RUL可以定义为在电池寿命达到终止之前,电池所能经历的充放电循环次数^[6]。通过预估RUL,可使电池性能在衰退之前提前更换,以确保系统安全可靠的运行。本研究基于粒子滤波算法,提出了一种变形的双指数组经验退化模型和数据驱动方法相结合的锂离子电池RUL预测方法,并通过实验证证了其可行性及预测的准确性。

1 相关研究

针对锂电池RUL预测研究的主要方法有模型

① 国家自然科学基金(71651147005)资助项目。

② 女,1995年生,硕士生;研究方向:电池剩余寿命、嵌入式系统等;联系人,E-mail: zhangning@sia.cn
(收稿日期:2017-03-22)

法、数据驱动法和融合型方法。其中模型法主要有基于电池退化机理的模型、等效电路模型和经验退化模型。基于电池退化机理的模型又叫做电化学第一原理模型^[7],这类模型通过分析影响电池性能的内外部因素(内部因素如电阻、SEI 膜厚度、电解液浓度等,外部因素如温度、压强等),利用这些因素的变化规律构建。这类模型的优势是可以很好地反映出电池性能的实际退化过程,缺点是模型参数较多,而且此类参数多难以测量,建模过程复杂。等效电路模型是依据电池表现出来的电流或电压特性,利用电压源、电流源、电阻、电容等搭建电路描述电池特性。精确的等效电路模型中含有大量电路元件,只能利用阻抗谱识别参数,计算复杂度高。经验退化模型的构建是通过对大量实验数据拟合,获得描述电池性能退化过程的数学公式。该模型较上面两类模型参数更少,计算简单。

对于锂电池这样复杂的电化学系统,建模过程通常较为复杂,数据驱动方法不需要考虑电池内部的反应机理,利用大量的历史数据挖掘电池的寿命信息,在一定程度上可以克服模型法对于不同电池要建立不同模型的弱点。数据驱动方法主要有:自回归(autoregressive, AR)类的时间序列模型、高斯过程回归(gaussian process regression, GPR)和统计随机滤波算法。AR 类的时间序列模型将系统中某一变量的观测值按相同的时间间隔排列成一个数值序列,利用过去的观测值预测该变量未来的发展趋势。该类模型计算简便,适合实际工程中样本量小的情况,但是当针对系统做长期的预测时,容易产生偏差;高斯过程回归(GPR)方法将过去离散的状态用高斯过程拟合,利用回归函数预测未来的状态,由于涉及到超参数的调整,GPR 方法的计算量较大,且超参数的确定难度也较大;统计随机滤波算法主要有卡尔曼滤波(KF)、扩展卡尔曼滤波(EKF)、粒子滤波(PF)、无损粒子滤波(UPF)等,其中卡尔曼滤波适合扰动满足高斯分布的系统状态估计,粒子滤波针对受到的扰动为非高斯非线性的系统给出其状态估计值,其他算法都是基于 KF 和 PF 的改进和优化。

融合型方法是目前 RUL 预测的研究趋势,通过

融合多种方法来弥补单一方法的不足。常用的融合类型有两类,一类是将数据驱动法和模型法融合;另一类是多种数据驱动方法的融合。

目前国内外对于锂电池 RUL 的预测都展开了相关研究,美国宇航局(NASA)、马里兰大学是研究锂离子电池的代表性机构,我国的很多高校、企业也展开了相关研究,比如哈尔滨工业大学主要开展关于卫星锂离子电池、空间电源系统和卫星电源的剩余寿命预测及健康状态诊断等方面的研究^[8-10],北京交通大学主要研究电动汽车电池管理系统^[11]。重庆长安汽车股份有限公司则通过建立电池内阻与 RUL 之间的关系在线估计电池剩余寿命。

Guha^[12]等提出了基于高斯分布的双指数组经验退化模型,该模型有较好的收敛性,然而模型训练参数繁多,且每一步迭代都要更新参数值,增加了计算复杂性;Peng^[13]等提出了支持向量机(support vector machine, SVM)与无损粒子滤波融合的 RUL 预测方法,尽管 SVM 对于高维数据分类有着很好的表现,然而核函数必须满足 Mercer 条件以及 SVM 不能给出预测结果的不确定性表达仍然是 SVM 方法的不足。基于此,本文提出了一种新的锂离子电池 RUL 预测方法。该方法是采用经过变形的双指数组经验退化模型和数据驱动方法相结合的融合型方法。本文提出的模型相比传统的双指数组经验退化模型参数更少,训练复杂度更低,经过变形的模型更符合状态转移方程的形式,且适合与统计随机滤波算法配合使用。由于经验退化模型仅采用某一变量衡量电池寿命,为了减少对经验模型的过度依赖,采用粒子滤波算法跟踪锂离子电池这类非高斯非线性系统的容量衰退过程,并利用 AR 时间序列模型修正 PF 算法的跟踪过程。最后,以 NASA PCoE 发布的锂离子电池数据集为测试对象,验证该方法可以准确地估计出锂电池的剩余寿命。

2 基于粒子滤波算法的 RUL 预测方法步骤

该算法选取前 N 个充放电周期的实验数据做训练,训练数据主要用来构建经验退化模型,且 AR 时间序列模型基于训练数据更新电池容量的观测值

(电池容量的测量值),其中,当电池容量达到额定容量的 80% 时电池达到其失效阈值。算法步骤如下:

输入:前 N 个充放电周期的电池容量数据 $\{C_k\}$ ($k = 1, 2, \dots, N$)。

输出:电池剩余寿命的估计值和预测结果的后验概率密度(probability density function, PDF)分布。

步骤 1:将电池容量数据经非线性最小二乘拟合训练得到模型参数,完成对变形的双指数组经验模型的构建。

步骤 2:利用构建好的模型建立状态空间方程。

步骤 3:利用输入的数据训练 AR 时间序列模型,得出 AR 模型的阶数 p 和模型相关的自回归系数 ϕ_i ($i = 1, \dots, p$)。

步骤 4:采用 PF 算法对训练周期 ($k = 1, \dots, N$) 电池容量的衰退进行跟踪,利用 AR 时间序列模型预测下一个充放电周期的电池容量的观测值 Z_{k+1} , 利用 PF 算法产生在状态空间中传播的大量粒子预测下一周期的电池容量值 C_{k+1} 。

步骤 5:重复步骤 4,使电池容量的预测值 C_{k+1} 不断逼近其失效阈值,直至确定该电池的剩余寿命 k ,并给出该预测结果的 PDF 分布。

3 经过变形的双指数组经验退化模型的参数训练与构建

电池的老化过程通过模型来描述,模型的构建基于电池内部的物理化学反应和电池负载条件,或基于大量实验数据拟合、训练得到。双指数组经验退化模型^[14]对于电池容量的非线性退化有很好的拟合效果,它由大量实验数据拟合得出,形式如下:

$$C_k = a \cdot \exp(b \cdot k) + c \cdot \exp(d \cdot k) \quad (1)$$

其中, a, b, c, d 是模型参数, k 为周期数,电池的一次充放电是一个循环周期, C_k 为第 k 周期的电池容量。该模型含有 4 个未知参数,通过变形,可以减少模型参数个数,降低参数估计复杂度。 $k - 1$ 时刻的模型表达式是:

$$C_{k-1} = a \cdot \exp(b \cdot (k - 1)) + c \cdot \exp(d \cdot (k - 1)) \quad (2)$$

消去式(1)、(2)的公共项 $a \cdot \exp(b \cdot k)$, 得

$$\begin{aligned} C_k &= C_{k-1} \exp(b) \\ &+ c \cdot \exp(d \cdot k) (1 - \exp(b - d)) \end{aligned} \quad (3)$$

式(3)即为变形后的双指数模型。相比原始的双指数模型,变形后的模型参数个数减少,参数估计难度降低,且更符合下文介绍的粒子滤波状态转移方程的形式。

本文采用的实验数据是 NASA PCoE 电池数据集,包含 4 组电池充放电实验数据,分别是 05#电池数据、06#电池数据、07#电池数据和 18#电池数据,该数据在室温下测得,部分原始实验数据见表 1。图 1 显示了四组电池数据的电池容量衰退情况,在电池容量达到 1.38Ah 时认为电池失效,可以看到,07#电池没有到达划定的截止阈值,所以剔除 07#电池的实验数据。

选择每组实验数据的前若干周期作为训练数据集,其余的周期用于跟踪预测电池 RUL。通过 Matlab 曲线拟合工具中的非线性最小二乘拟合,起始预测周期分别为 60, 70, 80 的模型参数拟合结果和实验数据拟合效果分别见表 2 和图 2。

表 1 NASA PCoE 电池数据集前 15 个充放电周期的电池容量数据(单位:Ah)

充放电周期 (cycle)	05#	06#	07#	18#
1	1.8565	2.0353	1.8911	1.8550
2	1.8463	2.0251	1.8806	1.8432
3	1.8353	2.0133	1.8807	1.8396
4	1.8353	2.0133	1.8808	1.8307
5	1.8346	2.0005	1.8795	1.8327
6	1.8357	2.0139	1.8807	1.8285
7	1.8351	2.0131	1.8799	1.8212
8	1.8258	1.9688	1.8815	1.8152
9	1.8248	1.9682	1.8697	1.8043
10	1.8246	1.9572	1.8701	1.8231
11	1.8246	1.9456	1.8700	1.8212
12	1.8142	1.9348	1.8597	1.8047
13	1.8138	1.9233	1.8591	1.7908
14	1.8134	1.9119	1.8590	1.7835
15	1.8026	1.9011	1.8591	1.7809

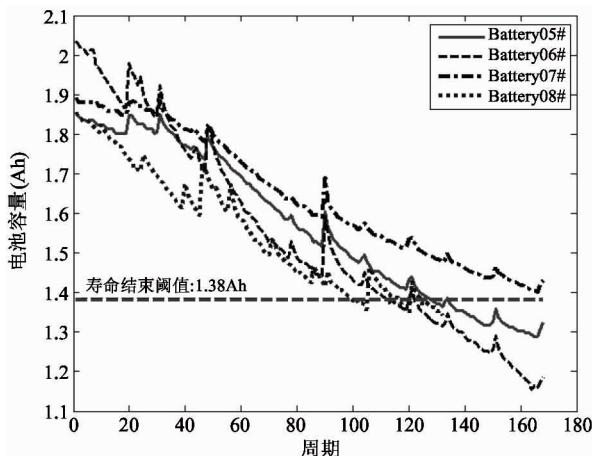


图 1 电池容量退化曲线

表 2 模型参数训练结果

电池 编号	模型 参数	60	70	80
05#	b	0.03675	0.02011	0.006806
	c	1.855	1.981	-1.234e+04
	d	0.0004882	0.001771	0.006807
06#	b	0.001997	-0.01171	-0.006467
	c	-1.207	-941.2	-0.6081
	d	0.008405	-0.01173	-0.02483
18#	b	-0.003977	-0.04943	0.1094
	c	0.02517	1.816	1.842
	d	0.03183	-0.002338	-0.002498

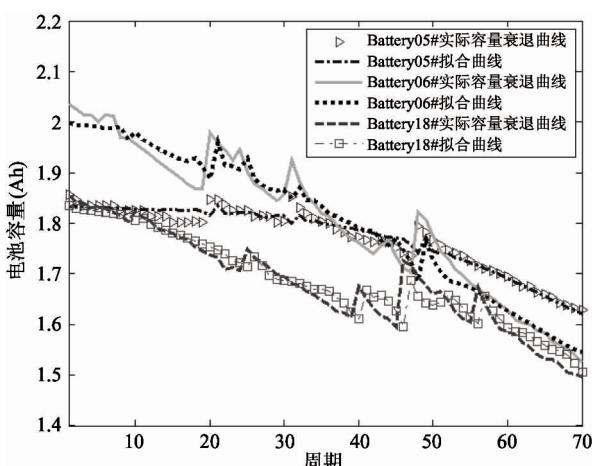


图 2 前 60 周期实验数据拟合曲线

4 粒子滤波算法

4.1 粒子滤波算法原理

建立模型后,要对电池容量衰退过程进行跟踪。

针对电池这类非线性非高斯的复杂系统,粒子滤波(PF)算法是一种有效的状态跟踪方法,它基于贝叶斯-蒙特卡洛框架。

动态系统的状态转移过程由状态空间方程描述,其形式为

$$x_k = f(x_{k-1}) + u_k \quad (4)$$

$$y_k = h(x_k) + v_k \quad (5)$$

x_k 表示系统当前时刻的状态值, y_k 表示系统当前时刻的观测值, 它由系统当前时刻的状态决定。 $f(\cdot)$ 是状态转移函数, 表征系统前一时刻状态和当前时刻状态之间的函数关系; $h(\cdot)$ 是观测函数, 表征系统状态和观测值之间的函数关系, 两函数至少一个为非线型^[15]。 u_k 是系统噪声, 表示系统在 k 时刻受到的扰动; v_k 是 k 时刻的观测噪声。通常假设状态转换过程服从一阶马尔科夫模型, 即当前时刻的状态 x_k 只与前一时刻状态 x_{k-1} 有关。

为方便描述, 用 $X_k = x_{0:k} = \{x_0, x_1, \dots, x_k\}$ 和 $Y_k = y_{0:k} = \{y_1, y_2, \dots, y_k\}$ 分别表示从 0 到 k 时刻所有的状态值与观测值。由贝叶斯滤波得到先验概率密度:

$$p(x_k | Y_{k-1}) = \int p(x_k | x_{k-1}) p(x_{k-1} | Y_{k-1}) dx_{k-1} \quad (6)$$

得到最新的观测值 y_k 后, 利用贝叶斯公式更新先验概率密度得到后验概率密度:

$$p(x_k | Y_k) = \frac{p(y_k | x_k) p(x_k | Y_{k-1})}{p(y_k | Y_{k-1})} \quad (7)$$

将后验概率密度的条件均值作为系统状态的估计值:

$$\bar{x}_k = E[f(x_k) | Y_k] = \int f(x_k) p(x_k | Y_k) dx_k \quad (8)$$

蒙特卡洛模拟的核心思想是利用大量的样本点逼近待估计变量的后验概率分布。从后验概率密度函数中抽取 N 个独立同分布的随机样本 $x_k^{(i)}$ ($i = 1, 2, \dots, N$), 后验概率密度 $p(x_k | Y_k)$ 近似逼近为

$$p(x_k | Y_k) \approx \frac{1}{N} \sum_{i=1}^N \delta(x_k - x_k^{(i)}) \quad (9)$$

其中 $\delta(x - x_k)$ 为狄拉克函数, 在 $x \neq x_k$ 时 $\delta(x - x_k) = 0$, 且 $\int \delta(x) dx = 1$, 估计系统状态值时用求和代

替换积分:

$$\begin{aligned}\bar{x}_k &= E[f(x_k) | Y_k] = \int f(x_k) p(x_k | Y_k) dx_k \\ &= \frac{1}{N} \sum_{i=1}^N f(x_k^{(i)})\end{aligned}\quad (10)$$

在实际中是无法直接从后验概率密度中取样的,因为无法知道后验概率密度的具体形式,粒子滤波的重要性采样方法引入一个易于采样的重要性概率密度函数 $q(x_k | Y_k)$,从中采样粒子,随着采样数的增大,随机样本的加权和逐渐逼近真实的后验概率密度 $p(x_k | Y_k)$ 。系统状态的估计值为

$$\begin{aligned}E[f(x_k) | Y_k] &= \frac{1}{N} \sum_{i=1}^N f(x_k^{(i)}) \frac{p(x_k^{(i)} | Y_k)}{q(x_k^{(i)} | Y_k)} \\ &= \frac{1}{N} \sum_{i=1}^N f(x_k^{(i)}) \omega_k^{(i)}\end{aligned}\quad (11)$$

$$\omega_k^{(i)} = \frac{p(Y_k | x_k) p(x_k)}{q(x_k | Y_k)} \propto \frac{p(x_k | Y_k)}{q(x_k | Y_k)}\quad (12)$$

$\omega_k^{(i)}$ 为第 i 个粒子的权重,为避免每次有了新的观测值都要重新计算整个 $p(x_k | Y_k)$ 和 $q(x_k | Y_k)$,将式(12)写成递推形式:

$$\omega_k^{(i)} = \omega_{k-1}^{(i)} \frac{p(y_k | x_k^{(i)}) p(x_k^{(i)} | x_{k-1}^{(i)})}{q(x_k^{(i)} | X_{k-1}^{(i)}, Y_k)}\quad (13)$$

在计算权重时,通常选取状态转移概率密度函数 $p(x_k | x_{k-1})$ 作为重要性概率密度函数,则权重的计算形式为

$$\omega_k^{(i)} = \omega_k^{(i-1)} p(y_k | x_k^{(i)})\quad (14)$$

粒子的权重要进行归一化。 k 时刻状态的估计值为

$$\bar{x}_k = \sum_{i=1}^N x_k^{(i)} \omega_k^{(i)}\quad (15)$$

随着采样的多次迭代,粒子的权重方差增大^[15],多数粒子权重趋于 0,导致粒子集中,多数粒子由于其权重过小,对于状态估计的贡献甚微。这就是粒子衰退现象。重采样的思想是剔除权重小的粒子,将粒子集中权重较大的粒子依据其权值大小加以繁殖,即权重大者多繁殖,所有繁殖后代构成新的粒子集,各粒子权重均为 $1/N$ 。

判断粒子退化程度可采用如下公式估计:

$$\bar{N}_{\text{eff}} = \frac{1}{\sum_{i=1}^{N_s} (\tilde{\omega}_k^{(i)})^2}\quad (16)$$

$\tilde{\omega}_k^{(i)}$ 是归一化权重。可预先设定一个阈值 N_{th} ,当 $\bar{N}_{\text{eff}} \leq N_{\text{th}}$ 时认为退化严重,需要进行重采样。重采样后的状态估计采用式(15),后验概率密度计算形式如下:

$$p(x_k | Y_k) = \sum_{i=1}^N \omega_k^{(i)} \delta(x_k - x_k^{(i)})\quad (17)$$

4.2 粒子滤波算法跟踪电池的容量衰退

粒子滤波(PF)算法能很好地跟踪电池容量的衰退趋势,但它需要给出粒子传播的状态空间方程。经过变形的双指数经验模型可作为 PF 的状态转移方程,观测方程则是在状态值的基础上加观测噪声得到的。具体形式为

$$\begin{aligned}C_k &= C_{k-1} \exp(b) + c \cdot \exp(d \cdot k) \\ &\quad \cdot (1 - \exp(b - d)) + \mu_k\end{aligned}\quad (18)$$

$$Z_k = C_k + v_k$$

其中, C_k 是第 k 周期电池的实际容量, Z_k 是针对电量的观测值, μ_k 和 v_k 均服从零均值的高斯分布。PF 算法的流程如下:

(1) PF 参数初始化:

设置采样粒子数 N , 噪声方差,由先验 $p(x_0)$ 生成采样粒子集 $\{x_0^{(i)}\}_{i=1}^N$, 设置 $\omega_0 = 1/N$; for $k = 1, \dots, T$

(2) 重要性采样:

for $i = 1, \dots, N$, 从重要性概率密度函数 $q(x_k | Y_k)$ 中采样生成粒子集 $\{x_k^{(i)}\}_{i=1}^N$, 利用式(13)计算粒子权重并归一化;

(3) 重采样:

If $\bar{N}_{\text{eff}} \leq N_T$: 将当前粒子集中权值较小的粒子剔除,抽取 N 个粒子构成新的粒子集 $\{x_k^{(i)}\}_{i=1}^N$, 权值设为 $1/N$;

(4) 电量估计和后验概率密度计算:

利用式(15)估计电量 \bar{x}_k , 如果 $\bar{x}_k \leq 0.8C_0$: 循环结束, k 即为该锂电池的 RUL 估计值,并利用式(17)计算后验概率密度;否则重复步骤(1)~(4)。

以 18#电池为例,基于 PF 算法的锂电池 RUL 预测结果如图 3 所示,设定预测起始点为 cycle = 70。

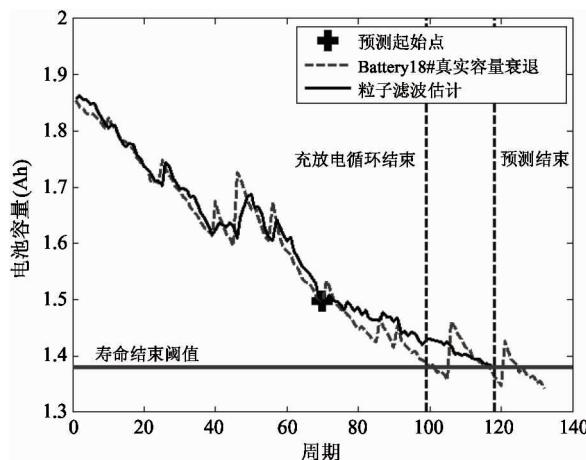


图 3 基于 PF 算法的电池 RUL 预测曲线

由于 PF 算法利用式(18)中的观测方程得到观测值的先验估计,为了减少 PF 算法对经验模型的过度依赖,引入自回归(AR)模型,该模型基于过去若干周期的电池容量值预测下一周期的电池容量观测值,以校正观测值的先验估计,得到后验估计的粒子集 $\{\tilde{x}_k^{(i)}\}_{i=1}^N$,利用该粒子集在状态空间方程(18)中传播以修正经验模型的不足,提高预测准确性。

5 AR 时间序列模型

5.1 AR 时间序列模型原理

AR 时间序列模型将系统中某一变量的观测值按时间顺序(时间间隔相同)排列成一个数值序列,展示研究对象在一定时期的变动过程,从中寻找和分析事物的变化特征、发展趋势和规律,并估计未来时刻的值^[16]。AR 模型的时间序列表示形式如下^[17]:

$$\begin{cases} x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \cdots + \phi_p x_{t-p} + \alpha_t \\ \phi_p \neq 0 \end{cases} \quad (19)$$

其中, p 是 AR 模型的阶数,模型可以记作 AR(p), ϕ_i 是自回归系数, x_{t-i} 是时间序列值, α_t 是均值为零、方差为 σ^2 的高斯白噪声。因此 x_t ($t = 1, 2, \dots, N$) 的估计值可以由之前 p 个时刻的观测值的线性求和加上 t 时刻的噪声求得。

5.2 AR 时间序列模型的参数确定

AR 时间序列模型的参数有阶数 p , 自回归系数 $\phi_1, \phi_2, \dots, \phi_p$ 和噪声方差 σ^2 。自回归系数的估计方

法有 Burg 法、最小二乘法、解 Yule-Walker 法等,本文采用最小二乘法确定自回归系数。可令

$$\begin{aligned} \mathbf{Y} &= [x_{p+1} \ x_{p+2} \ \cdots \ x_N] \\ \mathbf{X} &= \begin{bmatrix} x_p & x_{p-1} & \cdots & x_1 \\ x_{p+1} & x_p & \cdots & x_2 \\ \vdots & \vdots & \ddots & \vdots \\ x_{N-1} & x_{N-2} & \cdots & x_{N-p} \end{bmatrix} \end{aligned}$$

利用最小二乘法估计自回归系数 ϕ_i 的表达式为 $\phi = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$ 。阶数 p 的确定方法通常有最终预测误差(final prediction error, FPE)准则,赤池信息准则(Akaike information criterion, AIC)和贝叶斯信息准则(Bayesian information criterion, BIC),本文采用 BIC,计算公式为:

$$BIC(n) = N \ln \sigma^2 + n \ln N \quad (20)$$

在该准则取最小值时即为模型合适的阶数。三组电池数据的 BIC 准则曲线图如图 4 所示,模型阶数通常不超过 $10^{[18]}$,十字型标记点表示该电池最合适的 AR 模型阶数。

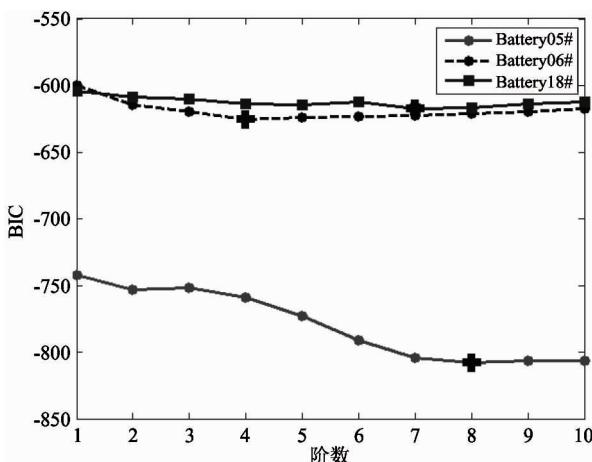


图 4 三组电池数据利用 BIC 准则确定 AR 模型阶数曲线图

AR 时间序列模型建立后,可基于过去若干周期的电池容量数据估计下一周期的电池容量值,将该值作为 PF 状态空间方程中电池容量的观测值以提高 PF 算法状态估计的准确性。

6 实验结果及分析

NASA PCoE 电池数据集的实验过程是:首先以

恒定电流1.5A充电至电压达到4.2V,然后以恒定电压充电至电流降至20mA,至此充电完成。放电过程是以2A恒定电流放电至电池电压下降到2.7V,2.5V,2.2V,2.5V(分别对应05#,06#,07#和18#电池),按照本文提出的RUL预测方法,以05#电池为例,图5和图6分别显示了在不同的起始预测周期下RUL预测实验结果和后验概率密度分布。

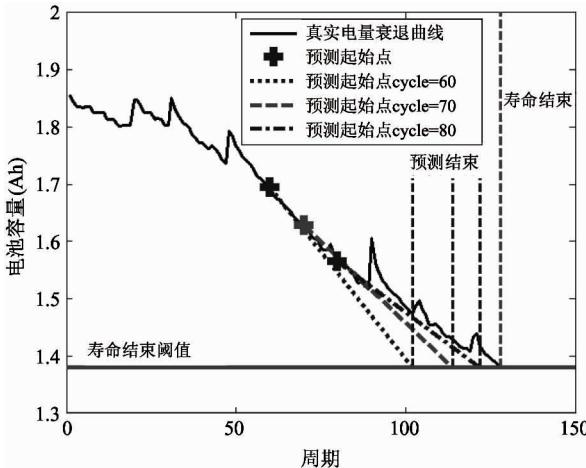


图5 05#电池不同起始预测周期的RUL预测结果

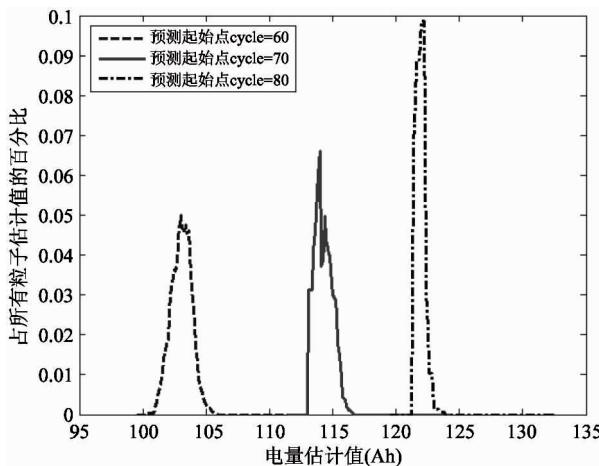


图6 05#电池预测的后验概率密度分布

通过分析图5给出的05#电池实验结果,它的实际循环寿命是128周期,当训练周期分别为60,70和80时,预测结果分别为102,119和126,预测的绝对误差分别为26,14和6,可以看出训练周期越长,该算法的预测误差就越小。从图6给出的后验概率密度分布可以看出,随着训练周期的增大,PDF分布图的峰值呈增高趋势,在横坐标轴上的分

布宽度变窄,说明训练周期越长,给出的预测值精度越高,且峰值中心在逐渐靠近真实的寿命结束值。

表3、表4和表5分别给出了不同训练周期下,仅使用PF算法和PF+AR融合算法的RUL预测结果对比。可以看出,仅使用PF算法的预测误差高于PF+AR融合算法的预测误差,且两种算法的预测误差均会随着训练周期的增长而减小。表6以06#电池为例,在预测起始周期为80周期的条件下,给出了两种方法的预测误差对比,这里用到了两种性能分析方法:平均绝对误差(MAE)和均方根误差(RMSE),定义如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |x(i) - \bar{x}(i)| \quad (21)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [x(i) - \bar{x}(i)]^2} \quad (22)$$

这说明引入AR模型修正PF状态空间方程的观测值可以极大地提高预测准确性,也证实了本方法的可行性。

表3 训练60周期的PF和PF+AR方法RUL预测结果对比

(注:\表示训练周期较短,PF算法无法给出预测结果)

电池	实际寿命 (cycle)	方法	训练周期 60 (cycle)	
			预测结果 (cycle)	误差 (cycle)
05#	128	PF	89	39
		PF + AR	102	26
06#	112	PF	85	27
		PF + AR	88	24
18#	99	PF	\	\
		PF + AR	113	14

表4 训练70周期的PF和PF+AR方法RUL预测结果对比

电池	实际寿命 (cycle)	方法	训练周期数 70 (cycle)	
			预测结果 (cycle)	误差 (cycle)
05#	128	PF	95	33
		PF + AR	114	14

(续表 4)

06#	112	PF	89	23
		PF + AR	95	17
18#	99	PF	117	18
		PF + AR	94	5

表 5 训练 80 周期的 PF 和 PF + AR 方法 RUL
预测结果对比

电池	实际寿命 (cycle)	方法	训练周期数 80 (cycle)	
			预测结果 (cycle)	误差 (cycle)
05#	128	PF	97	31
		PF + AR	122	6
06#	112	PF	96	16
		PF + AR	107	5
18#	99	PF	88	11
		PF + AR	102	3

表 6 两种预测算法的电池 RUL 预测误差对比

方法	MAE(Ah)	RMSE(Ah)
PF	0.036859	0.009888
PF + AR	0.023503	0.005850

7 结论

本文提出了一种融合型的锂离子电池剩余寿命(RUL)预测方法,该方法将传统的双指数经验模型加以变形,降低模型参数估计的复杂度,且使其更符合粒子滤波(PF)状态转移方程的形式。使用 PF 算法对电池的容量衰退过程进行跟踪,并引入自回归(AR)时间序列模型修正 PF 算法所需要的观测值。实验结果表明,相较单一的 PF 算法,PF + AR 的融合算法可以提升预测准确度,该方法简单可行,可用于锂离子电池 RUL 的预测。

参考文献

- [1] 王云甘,王忠锋,于海斌等. 基于 MIMO 模糊控制的锂离子电池参数自适应等效电路模型及 SOC 估计. 信息与控制, 2015, 44(3):263-269

- [2] 张磊,朱云龙,王驰远等. 太阳电池超细栅电极喷印控制系统设计与实现. 信息与控制, 2016, 45(3): 377-384
- [3] 吴贊,蒋新华,解晶莹. 锂离子电池循环寿命快速衰减的原因. 电池, 2009, 39(4):34-35
- [4] Zhang Q, White R E. Capacity fade analysis of a lithium ion cell. *Journal of Power Sources*, 2008, 179(2):793-798
- [5] Bagul Y G, Zeid I, Kamarthi S V. Overview of remaining useful life methodologies. In: Proceedings of the ASME 2008 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference, New York, USA, 2008. 1391-1400
- [6] 王红. 卫星锂离子电池剩余寿命预测方法及应用研究:[硕士学位论文]. 哈尔滨:哈尔滨工业大学电气工程及自动化学院, 2013. 19-30
- [7] 闫晓华. 空间电源系统仿真及锂离子电池剩余寿命预测研究:[硕士学位论文]. 深圳:哈尔滨工业大学深圳研究生院, 2014. 21-23
- [8] 周建宝,王少军,马丽萍等. 可重构卫星锂离子电池剩余寿命预测系统研究. 仪器仪表学报, 2013, 34(9):2034-2044
- [9] 时玮. 动力锂离子电池组寿命影响因素及测试方法研究:[博士学位论文]. 北京:北京交通大学电气工程及自动化学院, 2014. 32-35
- [10] 罗伟林,张立强,吕超等. 锂离子电池寿命预测国外研究现状综述. 电源学报, 2013, 1:140-144
- [11] Waag W, Käbitz S, Sauer D U. Application-specific parameterization of reduced order equivalent circuit battery models for improved accuracy at dynamic load. *Measurement*, 2013, 46(46): 4085-4093
- [12] Guha A, Vaisakh K V, Patra A. Remaining useful life estimation of lithium-ion batteries based on a new capacity degradation model. In: Proceedings of the IEEE Transportation Electrification Conference and Expo, Asia-Pacific, Busan, Korea, 2016. 555-560
- [13] Peng X, Zhang C, Yu Y, et al. Battery remaining useful life prediction algorithm based on support vector regression and unscented particle filter. In: Proceedings of the IEEE International Conference on Prognostics and Health Management, Ottawa, Canada, 2016. 1-6
- [14] He W, Williard N, Osterman M, et al. Remaining useful performance analysis of batteries. In: Proceedings of the

- IEEE Conference on Prognostics and Health Management,
Montreal, Canada, 2011. 1-6 822-826
- [15] 程水英,张剑云. 粒子滤波评述. 宇航学报,2008, 29 (4):1099-1111 [17] 王燕. 应用时间序列分析. 北京: 中国人民大学出版社,2005. 42-46
- [16] 豆金昌. 锂离子电池健康评估及剩余使用寿命预测方法研究. 太赫兹科学与电子信息学报,2013, 11(5): [18] 罗悦. 基于粒子滤波的锂离子电池剩余寿命预测方法研究:[硕士学位论文]. 哈尔滨:哈尔滨工业大学电气工程及自动化学院,2012. 52-54

Research on prediction of the remaining useful life of lithium-ion batteries based on particle filtering

Zhang Ning^{* ***}, Xu Aidong^{*}, Wang Kai^{*}, Han Xiaojia^{* ***}, Seung Ho Hong^{***}

(^{*} Industrial Control Networks and Systems Department, Shenyang Institute of Automation,
Chinese Academy of Sciences, Shenyang 110016)

(^{**} University of Chinese Academy of Sciences, Beijing 100049)

(^{***} Department of Electronic Systems Engineering, Hanyang University, Ansan 15588, Korea)

Abstract

The particle filtering is used to study the prediction of the remaining useful life (RUL) of lithium-ion batteries, and a simple and effective algorithm fusing the model method and the data-driven method for RUL predicting is proposed. The algorithm uses the fusion of the model method and the data-driven method to modify the double exponential empirical degradation model to reduce the model parameters and the parameter training difficulty, uses the particle filter algorithm to track the battery capacity degradation process, and uses the auto regression model to modify the observation value of the state space equation to improve the prediction accuracy. The experimental results show that the proposed algorithm can effectively predict the remaining useful life of lithium batteries.

Key words: lithium-ion battery, remaining useful life (RUL), particle filter, double exponential empirical model