

1-3-2019

Approach for Lithium-ion Battery RUL Prognostics Based on CPSO-RVM

Chaolong Zhang

1. *School of Physics and Electronic Engineering, Anqing Normal University, Anqing 246011, China;* ;2. *School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;*

Yigang He

2. *School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;*

Lifen Yuan

2. *School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Approach for Lithium-ion Battery RUL Prognostics Based on CPSO-RVM

Abstract

Abstract: On account of the measured battery state of health (SOH) data are often subject to different levels of noise pollution, a battery remaining useful life (RUL) prognostics approach is presented based on wavelet denoising and CPSO-RVM in the paper. Wavelet denoising is performed twice with different thresholds in order to weaken the strong noise and remove the weak noise. Relevance vector machine (RVM) improved by chaos particle swarm optimization (CPSO) algorithm is utilized to estimate the trend of battery SOH variation trajectory and predict the battery RUL based on the denoised data. RUL prognostic experiments using battery data provided by NASA are conducted and the effectiveness of the presented approach is validated.

Keywords

lithium-ion battery, RUL, SOH, wavelet denoising, RVM, CPSO

Recommended Citation

Zhang Chaolong, He Yigang, Yuan Lifan. Approach for Lithium-ion Battery RUL Prognostics Based on CPSO-RVM[J]. Journal of System Simulation, 2018, 30(5): 1935-1940.

基于 CPSO-RVM 的锂电池剩余寿命预测方法

张朝龙^{1,2}, 何怡刚², 袁莉芬²

(1. 安庆师范大学物理与电气工程学院, 安庆 246011; 2. 合肥工业大学电气与自动化工程学院, 合肥 230009)

摘要: 针对锂电池健康状况测量数据中经常伴随着各种类型及大小的噪声, 本文提出了一种基于小波去噪和混沌粒子群-相关向量机的锂电池剩余寿命预测方法。执行小波二次降噪, 削弱测量数据中的大噪声信号及消除测量数据中的小噪声信号, 从而提取原始数据; 将经混沌粒子群算法优化的相关向量机算法用于估计锂电池各个充放电周期健康状况的变化轨迹, 并预测锂电池的剩余寿命。基于美国国家航空航天局提供的锂电池测量数据, 对提出的方法进行了有效性验证。

关键词: 锂电池; 剩余寿命; 健康状况; 小波降噪; 相关向量机; 混沌粒子群

中图分类号: TM933.4 文献标识码: A 文章编号: 1004-731X (2018) 06-1935-06

DOI: 10.16182/j.issn1004731x.joss.201805040

Approach for Lithium-ion Battery RUL Prognostics Based on CPSO-RVM

Zhang Chaolong^{1,2}, He Yigang², Yuan Lifen²

(1. School of Physics and Electronic Engineering, Anqing Normal University, Anqing 246011, China;

2. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

Abstract: On account of the measured battery state of health (SOH) data are often subject to different levels of noise pollution, a battery remaining useful life (RUL) prognostics approach is presented based on wavelet denoising and CPSO-RVM in the paper. Wavelet denoising is performed twice with different thresholds in order to weaken the strong noise and remove the weak noise. Relevance vector machine (RVM) improved by chaos particle swarm optimization (CPSO) algorithm is utilized to estimate the trend of battery SOH variation trajectory and predict the battery RUL based on the denoised data. RUL prognostic experiments using battery data provided by NASA are conducted and the effectiveness of the presented approach is validated.

Keywords: lithium-ion battery; RUL; SOH; wavelet denoising; RVM; CPSO

引言

锂电池是当前电子设备中常用的储能和供能部件, 相对于其他充电电池, 锂电池具有能量密度高、质量轻和充放电周期长的特点。然而, 锂电池

在使用过程中内部发生着不可预知的物理及化学变化, 引起锂电池的性能下降乃至失效, 进一步地影响所在电子设备的性能和功能, 因此锂电池的预测与健康管理的(prognostics and health management, PHM)是当前研究的一个研究热点^[1-6]。

锂电池的 PHM 包括了评估锂电池的健康状态(state of health, SOH), 以及对锂电池的剩余寿命(remaining useful life, RUL)进行预测。锂电池的 RUL 为该锂电池在失效前剩余的充放电周期^[1-6], 常见的锂电池 RUL 预测方法分为两类: 基于模型



收稿日期: 2017-04-01 修回日期: 2017-07-25;
基金项目: 国家自然科学基金(51607004, 51577046, 51637004); 国家重点研发计划(2016YFF0102200), 安徽省自然科学基金(1608085QF157);
作者简介: 张朝龙(1982-), 男, 安徽明光, 博士生, 副教授, 研究方向为复杂电气和电子系统故障诊断与预测。

<http://www.china-simulation.com>

• 1935 •

方法和数据驱动方法。基于模型方法通过分析被测对象的性能下降和失效机制,建立该被测对象的数学物理模型,从而预测其 RUL。卡夫曼滤波^[1]、非线性模型^[2]和粒子滤波^[3]等是常用的基于模型方法,并取得了较好的研究成果。然而,由于电子系统的复杂性、噪声、数据的可用性和不确定的环境变化及约束,为锂电池的 SOH 下降过程建立一个精确表征并普遍适用的数学物理模型,并不易于实现。数据驱动方法通过机器学习的方法分析性能数据进行预测,已应用于锂电池的 RUL 预测^[4-6]。人工神经网络、支持向量机(support vector machine, SVM)^[7]和相关向量机(relevance vector machine, RVM)^[8]算法是较为常用的数据驱动方法,其中 RVM 是一种基于贝叶斯推理的机器学习方法,相对于 SVM 算法, RVM 算法采用更少的相关向量,并在预测方面表现出更高的精度,在锂电池的 RUL 预测中取得了积极的效果^[6]。

锂电池 SOH 数据在测量的过程中,由于受到电磁干扰、测量误差、随机负载和电池内不可预知的行为影响,经常包含有各种类型和大小的噪声,这增加了锂电池 RUL 精确预测的难度。在此,本文提出了基于小波二次降噪和 RVM 算法的锂电池 RUL 精确预测方法。该方法首先对测量的锂电池 SOH 数据进行小波二次降噪,两次降噪的目的分别在于削弱大噪声信号和消除小噪声信号。应用经混沌粒子群(chaos particle swarm optimization, CPSO)算法优化后的 RVM 算法对锂电池的 SOH 进行连续地估计,并预测锂电池的 RUL。最后,基于两种锂电池的真实测量数据进行了 RUL 预测实验,验证了本文提出方法的有效性和普适性。

1 问题描述

锂电池在使用的过程中,随着充放电周期的增加,其 SOH 一般呈下降趋势,一般应用锂电池的容量来表征 SOH,在此,SOH 可定义为:

$$\text{SOH} = \frac{C_T}{C_N} \times 100 \quad (1)$$

式中: C_T 表示锂电池在第 T 个充放电周期时的容量; C_N 表示该锂电池容量的标称值。

2 小波去噪

小波分析是一种新颖的信号分析方法,它能有效地从混杂噪声的数据中分离噪声信号,提取有效数据。小波分析首先应用母小波的伸缩和平移所构成的小波族,将数据分解为逼近部分和细节部分。设 $H(x)$ 为测量得到的混杂噪声信号的数据,在母小波 $\psi(x)$ 中的小波变换为:

$$c(a,b) = \langle H(x), \psi_{a,b}(x) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} H(x) \psi\left(\frac{x-b}{a}\right) \quad (2)$$

其中: a, b 分别为母小波的伸缩和平移系数; $c(a,b)$ 为数据 $H(x)$ 的小波系数。

在小波分析应用于降噪的过程中,若细节系数的模低于预设的阈值,则认定该系数为噪声信号分解而成,需要将该系数置零,随后将所有剩余的系数重构,还原成原始数据。然而在应用的过程中,一般的小波降噪方法较难有效地提取原始数据,本文提出一种小波二次降噪方法,对测量的数据进行两次降噪,第一次降噪采用 Sqrtwolog 方法生成阈值,其公式为:

$$\text{Threshold}_{\text{sqrtwolog}} = \sqrt{2 \log n} \quad (3)$$

第二次降噪采用 Minimax 方法,该方法通过极大值极小原理生成阈值,其公式为:

$$\text{Threshold}_{\text{minimax}} = c + d \frac{\log(n)}{\log(2)} \quad (4)$$

式中: c 和 d 为调节参数; n 为数据 $H(x)$ 的大小。

Sqrtwolog 方法生成的阈值远大于 minimax 方法,第一次降噪阈值较大可以去除数据中较大的噪声信号,而第二次降噪阈值较小可以消除测量数据中的较小的噪声信号。小波二次降噪方法可有效地消除或减弱锂电池容量测量数据中噪声信号,还原原始数据。

3 CPSO-RVM

3.1 RVM

RVM 算法是一种基于贝叶斯推理的稀疏概率机器学习模型, 已应用于各类预测问题^[6,9]。

设 $\{\mathbf{x}_u\}_{u=1}^N$ 和 $\{t_u\}_{u=1}^N$ 分别是输入和输出向量, 目标 t 可通过带噪声的回归模型获得:

$$t_u = y(\mathbf{x}_u; \mathbf{w}) + \varepsilon_u \quad (5)$$

式中: \mathbf{w} 是权重向量; ε_u 是零均值, 方差为 σ^2 的噪声。

设是 t_u 独立的, 则其概率可表示为:

$$p(\mathbf{t} | \mathbf{w}, \sigma^2) = (2\pi\sigma^2)^{-N/2} \exp\left\{-\frac{1}{2\sigma^2} \|\mathbf{t} - \boldsymbol{\varphi}\mathbf{w}\|^2\right\} \quad (6)$$

式中: $\mathbf{t} = (t_1, t_2, \dots, t_N)^T$; $\boldsymbol{\varphi}$ 是 $N \times (N+1)$ 的核函数矩阵。

为了避免式(6)中的 \mathbf{w} 和 σ^2 的过拟合, 常使用下列零均值高斯先验概率分布约束参数:

$$p(\mathbf{w} | \boldsymbol{\alpha}) = \prod_{u=0}^N N(w_u | 0, \alpha_u^{-1}) \quad (7)$$

其中: $\boldsymbol{\alpha}$ 是一个 $N+1$ 超参数向量。

基于贝叶斯公式, 后验分布的权重被描述为:

$$p(\mathbf{w} | \mathbf{t}, \boldsymbol{\alpha}, \sigma^2) = (2\pi)^{-(N+1)/2} |\boldsymbol{\Sigma}|^{-1/2} \times \exp\left\{-\frac{1}{2}(\mathbf{w} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{w} - \boldsymbol{\mu})\right\} \quad (8)$$

式中: $\boldsymbol{\mu} = \sigma^{-2} \boldsymbol{\Sigma} \boldsymbol{\varphi}^T \mathbf{t}$; $\boldsymbol{\Sigma} = (\sigma^{-2} \boldsymbol{\varphi}^T \boldsymbol{\varphi} + \mathbf{A})^{-1}$; $\mathbf{A} = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$ 。

为了建立统一的超参数, $p(\mathbf{t} | \boldsymbol{\alpha}, \sigma^2)$ 给出如下定义:

$$p(\mathbf{t} | \boldsymbol{\alpha}, \sigma^2) = \int p(\mathbf{t} | \mathbf{w}, \sigma^2) p(\mathbf{w} | \boldsymbol{\alpha}) d\mathbf{w} = (2\pi)^{-N/2} |\sigma^2 \mathbf{I} + \boldsymbol{\varphi} \mathbf{A}^{-1} \boldsymbol{\varphi}^T|^{-1/2} \times \exp\left\{-\frac{1}{2} \mathbf{t}^T (\sigma^2 \mathbf{I} + \boldsymbol{\varphi} \mathbf{A}^{-1} \boldsymbol{\varphi}^T)^{-1} \mathbf{t}\right\} \quad (9)$$

$\boldsymbol{\alpha}_{\text{MP}}$ 和 σ_{MP}^2 可通过最大化边缘似然获得。设 \mathbf{x}_* 是新的输入, 则输出 t_* 的均值和方差分别为:

$$y_* = \boldsymbol{\mu}^T \boldsymbol{\varphi}(\mathbf{x}_*) \quad (10)$$

$$\sigma_*^2 = \sigma_{\text{MP}}^2 + \boldsymbol{\varphi}(\mathbf{x}_*)^T \boldsymbol{\Sigma} \boldsymbol{\varphi}(\mathbf{x}_*) \quad (11)$$

高斯径向基函数非线性处理能力较强, 常用作核函数:

$$K(\mathbf{x}, \mathbf{x}_u) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_u\|^2}{2d^2}\right) \quad (12)$$

式中: d 是宽度因子, 需要被预先设定。

3.2 CPSO 算法及其优化步骤

粒子群优化(particle swarm optimization, PSO)算法是一种新颖的启发式算法^[10], 通过模仿鸟类的觅食行为进行寻优。针对 PSO 算法易陷入局部极值、收敛慢的缺点, 混沌方法被引入 PSO 算法中, 即为 CPSO 算法^[11]。本文采用 CPSO 算法对 RVM 的宽度因子进行寻优, 此时 RVM 算法为 CPSO-RVM 方法。

3.2.1 CPSO 算法

PSO 算法依靠粒子进行寻优, 而每个粒子通过个体最优和群体最优调整寻优的速度, PSO 算法在每次迭代中选举出位置最好的粒子作为全局最优粒子, 在算法结束时输出全局最优粒子的位置。

混沌是自然界中普遍存在的一种非线性现象, 用于描述随机且具有统计规律的运动状态, 本文应用的是 Logistic 映射式:

$$Z_{n+1} = \mu Z_n (1 - Z_n) \quad \mu \in [0, 4] \quad (13)$$

式中: μ 为 Logistic 映射参数; Z_n 为混沌变量; Z_0 为混沌变量初始值。

CPSO 算法对于种群中具有全局最优粒子进行混沌遍历, 然后将混沌遍历的结果随机替换种群中的一个粒子。相比于传统的 PSO 算法, CPSO 算法中混沌的遍历性、随机性, 可有助于改善粒子群后期易陷入局部极值的特点, 并保持了 PSO 算法前期搜索的快速性。

3.2.2 参数优化步骤

本文将 RVM 算法的宽度因子映射为 CPSO 算法的粒子位置进行优化选择, 利用 CPSO 算法为 RVM 算法寻优得到一个适合的参数, 在之后的 RUL 预测中可表现出较高的性能, 优化步骤为:

Step 1: 初始化 CPSO 算法。

Step 2: 计算各个粒子的适应度, 确定各个粒子的个体最优位置和群体的全局最好位置。

Step 3: 对每个粒子进行速度与位置的更新。

Step 4: 对全局最好位置的粒子进行混沌优化, 并随机替换一个粒子。

Step 5: 重复 Step2 至 Step5 直至满足结束条件。

Step 6: 将最优粒子的位置输出, 即为相关向量机算法的宽度因子。

优化过程中选择均方误差 (Mean Squared Error, MSE) 为适应度函数, 可用于表征预测数据与真实数据的误差程度。

4 仿真实验及分析

为展示本文提出的基于小波二次降噪和 RVM 算法的锂电池 RUL 预测方法的过程和性能, 在此进行实验。实验对象选自于美国国家航空航天局艾姆斯研究中心提供的编号为 5 和编号为 18 的锂电池容量测量数据^[12]。图 1 中展示了编号为 5 和编号为 18 的锂电池的 SOH 随充放电周期的变化, 其中锂电池 5 和锂电池 18 分别表示编号为 5 和编号为 18 的锂电池。由图中可以看出, 锂电池的 SOH 均随着充放电周期有下降的趋势, 但在部分周期, 锂电池的 SOH 有快速而短暂的上升, 原因可归结为噪声干扰。选择编号 5 和编号 18 的锂电池 166 个和 132 个充放电周期的 SOH 进行实验, 这两种型号的锂电池的容量下降至标称容量的 70%, 即 SOH 下降至 70 时, 可认为锂电池失效, 故编号 5 和编号 18 的锂电池的有效生存周期分别为 123 个和 96 个充放电周期。现分别选择两种锂电池的前 80 个和前 70 个充放电周期的 SOH 数据作为训练数据, 之后 86 个和 62 个充放电周期的 SOH 数据作为测试数据, 进行锂电池的 RUL 预测实验。

分别对两种锂电池的 SOH 数据进行小波二次降噪, 应用 Sqtwolog 阈值小波降噪后锂电池 SOH 数据如图 2 所示, 而随后应用 Minimax 阈值小波降噪后锂电池 SOH 数据如图 3 所示。由图 3 可见, 本文提出的小波二次降噪方法生成的锂电池的 SOH 数据, 在随着充放电周期的增加, 一直在平稳地下降, 吻合于锂电池实际的 SOH 变化, 即更

加接近于原始数据。




图 1 两种锂电池的 SOH 测量数据
Fig. 1 Measured SOH data of two batteries




图 2 应用 Sqtwolog 阈值小波降噪后两种锂电池的 SOH 数据
Fig. 2 SOH data of two batteries by wavelet denosing with Sqtwolog threshold




图 3 进一步应用 Minimax 阈值小波降噪后两种锂电池的 SOH 数据
Fig. 3 SOH data of two batteries by wavelet denosing with Minimaxthreshold further

现分别选择两种锂电池的前 80 个和前 70 个充放电周期的 SOH 数据作为训练数据, 之后 86 个和 62 个充放电周期的 SOH 数据作为测试数据, 进行锂电池的 RUL 预测实验。混沌粒子群算法中种群

规模和迭代次数分别设置为 10 和 100, Logistic 映射参数设置为 4。图 4(a)和(b)分别对应于基于两种锂电池的训练数据应用 CPSO 算法优化选择 RVM 算法的宽度因子的过程, 优化获得的宽度因子分别为 0.4106 和 0.2780。编号 5 和编号 18 的锂电池的有效生存周期分别为 123 个和 96 个充放电周期, 由于分别选择两种锂电池的前 80 个和前 70 个充放电周期的 SOH 数据作为训练数据, 故需要预测得出的 RUL 真实值分别为 43 和 26。




图 4 应用 CPSO 算法优化宽度因子的过程
Fig. 4 Width factor optimization procedures by using CPSO

以优化得到的 0.4106 和 0.2780 作为宽度因子, 应用于 RVM 算法中, 分别对编号为 5 和编号为 18 的锂电池测试数据进行 SOH 的预测, 并与真实的测试数据进行对比, 结果如图 5(a)和(b)所示。在两个实验中 CPSO-RVM 方法均对测试数据 SOH 在未来充放电周期中的变化轨迹进行了精确预测。两个实验中预测结果的绝对误差和 MSE 在表 2 中给出。MSE 值较小也说明了预测数据与原始数据之间误

差较小。编号为 5 的锂电池实验绝对误差是 -4 个充放电周期, 编号为 18 的锂电池实验绝对误差是 1 个充放电周期, 可以认为 CPSO-RVM 方法准确预测出编号为 5 和编号为 18 的锂电池失效周期, 对锂电池 RUL 的预测是比较精确的。




图 5 锂电池测试数据的 SOH 估计结果
Fig. 5 Estimated SOH results of test data of batteries

表 1 两个实验预测结果的绝对误差与 MSE

实验	RUL	RUL 估计值	绝对误差	MSE
锂电池 5	43	39	-4	0.145 7
锂电池 18	26	27	1	0.081 0

SVM 算法在预测中有着广泛的应用, 在锂电池 RUL 预测的研究工作中有着积极的研究成果^[5], 在此以编号为 5 和编号为 18 的锂电池 SOH 数据为实验对象, 基于训练数据应用 CPSO 算法优化 SVM 算法的惩罚因子与宽度因子, 然后使用优化后的 SVM 算法预测锂电池的 RUL。训练数据与测试数据的选择与之前的实验相同, RUL 预测的绝对误差与 MSE 如表 2 所示。

表2 应用支持向量机的预测结果绝对误差与MSE
Tab. 2 Prediction's absolute errors and MSEs produced by using SVM

实验	RUL	RUL 估计值	绝对误差	MSE
锂电池 5	43	37	-6	0.216 3
锂电池 18	26	24	-2	0.150 7

由表2可以看出,基于本文提出的小波二次降噪后的锂电池SOH数据,应用SVM算法亦可精确地预测锂电池的RUL,这表明本文提出的小波二次降噪方法提取的原始数据同样适用于其他数据驱动方法。表2中实验的绝对误差分别为-6和-2,绝对值均高于表1中的绝对误差的绝对值,同时表2中根据SVM算法预测的测试数据计算出的MSE亦大于表1中MSE,说明本文提出的RVM算法的预测数据值更接近于实际数据值,也表明RVM算法在应用于锂电池的RUL预测时优于SVM算法。

5 结论

本文提出的锂电池RUL预测方法首先对测量的锂电池SOH数据进行小波二次降噪,削弱大噪声信号和消除小噪声信号,然后应用经CPSO算法优化了宽度因子的RVM算法连续地评估锂电池的SOH数据,并预测锂电池的RUL。实验表明,该方法可精确地预测锂电池的RUL,将RVM算法与SVM算法进行预测结果的对比,RVM算法表现出更优秀的性能。

本文提出的方法通用性强,小波二次降噪方法可引入其他需要消除噪声的信号处理领域,同时提出的基于CPSO优化的RVM方法亦可应用于其他研究领域的预测工作中。

参考文献:

- [1] He W, Williard N, Osterman M, et al. Prognostics of lithium-ion batteries using extended Kalman filtering[C]. Proceedings of IMAPS advanced technology workshop on high reliability microelectronics for military applications, Linthicum Heights, MD, USA. 2011: 17-19.
- [2] Xian W, 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 (S0018-9456), 2014, 63(1): 2-17.
- [3] Miao Q, Xie L, Cui H, et al. Remaining useful life prediction of lithium-ion battery with unscented particle filter technique[J]. Microelectronics Reliability (S0026-2714), 2013, 53(6): 805-810.
- [4] Liu D, Luo Y, Liu J, et al. Lithium-ion battery remaining useful life estimation based on fusion nonlinear degradation AR model and RPF algorithm[J]. Neural Computing and Applications (S0941-0643), 2014, 25(3): 557-572.
- [5] Widodo A, Yang B S. Machine health prognostics using survival probability and support vector machine[J]. Expert Systems with Applications (S0957-4174), 2011, 38(7): 8430-8437.
- [6] Li H, Pan D, Chen C L P. Intelligent prognostics for battery health monitoring using the mean entropy and relevance vector machine[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems (S2168-2216), 2014, 44(7): 851-862.
- [7] Cortes C, Vapnik V. Support-vector networks[J]. Machine learning (S0885-6125), 1995, 20(3): 273-297.
- [8] Tipping M E. Sparse Bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research (S1532-4435), 2001, 1(3): 211-244.
- [9] Zhang C, He Y, Yuan L, et al. A Novel Approach for Analog Circuit Fault Prognostics Based on Improved RVM[J]. Journal of Electronic Testing (S1573-0727), 2014, 30(3): 343-356.
- [10] Kennedy J, Eberhart R. Particle swarm optimization[C]// Proceedings of IEEE international conference on neural networks. 1995: 1942-1948.
- [11] 唐贤伦, 周维, 张衡, 等. 一种基于多目标混沌 PSO 的机器人足球防守策略[J]. 系统仿真学报, 2014, 26(1): 51-55, 61.
Tang Xianlun, Zhou Wei, Zhang Heng, et al. Robot Soccer Defensive Strategy Based on Multi-objective Chaotic PSO[J]. Journal of System Simulation, 2014, 26(1): 51-55, 61.
- [12] Saha B, Goebel K, Poll S, et al. Prognostics Methods for Battery Health Monitoring Using a Bayesian Framework[J]. IEEE Transactions on Instrumentation and Measurement (S0018-9456), 2009, 58(2): 291-296.