

基于改进神经网络算法的医疗锂电池 PHM 系统设计

何成¹, 刘长春², 武洋², 吴涛², 陈童³

(1. 上海第二工业大学 智能制造与控制工程学院, 上海 201209;

2. 上海第二工业大学 环境与材料工程学院, 上海 201209; 3. 上海第一人民医院, 上海 200080)

摘要: 针对医疗电子设备锂电池不确定性发生故障耽误病人救治的问题, 提出了一套医疗电子设备锂电池故障预测与健康管理系统 (Prognostics and Health Management—PHM); 搭建了一套医疗电子设备锂电池数据测试与退化状态模拟的实验平台; 为了反映医疗电子设备锂电池健康状态, 将锂电池四个健康因子作为医疗电子设备锂电池退化状态的特征进行提取, 并通过非线性自回归 (Nonlinear Autogressive with Exogenous Inputs—NARX) 神经网络, 对四个健康因子的数据进行训练, 训练后用于容量估计, 得出等间隔放电时间序列能够较好地表征锂电池健康状态; 为了提高基本粒子滤波算法 (Particle Filter—PF) 的精度从而更精确地预测锂电池剩余寿命 (Remaing Useful Life—RUL), 通过人工免疫粒子滤波算法 (Artificial Immune Particle Filter—AIPF) 与经验模型对锂电池进行剩余寿命预测, 并将 PF 预测的结果与 AIPF 预测的结果进行对比, 发现 AIPF 预测更加准确, 说明 AIPF 有效抑制了 PF 重采样过程中粒子退化问题, 验证了医疗电子设备锂电池故障预测与健康管理系统可行性与可实施性。

关键词: 医疗锂电池; 故障预测与健康管理系统; 非线性自回归神经网络; 人工免疫粒子滤波算法; 经验模型

Electromedical Lithium Battery PHM System Based on Improved Neural Network Algorithm

He Cheng¹, Liu Changchun², Wu Yang², Wu Tao², Chen Tong³

(1. School of Intelligent Manufacturing and Control Engineering, Shanghai Polytechnic University, Shanghai 201209, China;

2. School of Environmental and Material Engineering, Shanghai Polytechnic University, Shanghai 201209, China;

3. Shanghai First People's Hospital, Shanghai 200080, China)

Abstract: In order to solve the problem of failure of patients with failures caused by the uncertainty of lithium-ion batteries in medical electronic equipments, a set of prognostics and health management (PHM) systems for lithium-ion batteries in medical electronic equipment was proposed. An experiment platform for data testing and degradation status simulation of lithium batteries for medical electronic equipment was built. In order to reflect the health status of lithium-ion batteries for medical electronic devices, the four health factors of lithium batteries are extracted as characteristics of the degradation status of lithium-ion batteries for medical electronic devices, and they are passed through a nonlinear auto-regressive with exogenous inputs (NARX) neural network. The data of the health factors were trained and used for capacity estimation after training, and the equal interval discharge time series could be used to better characterize the lithium battery health status. In order to improve the precision of the Particle Filter—PF and more accurately predict the Reamaling Useful Life—RUL, the Artificial Immune Particle Filter (AIPF) and the Empirical Model for Lithium The battery performs the remaining life prediction, and compares the PF prediction result with the AIPF prediction result, and finds that the AIPF prediction is more accurate, indicating that AIPF effectively inhibits the particle degradation problem in the PF re-sampling process, and verifies the failure prediction of the lithium ion battery for medical electronic equipment. Health management system feasibility and enforceability.

Keywords: medical lithium battery; prognostics and health management system; NARX neural network; artificial immune particle filter algorithm; empirical model

0 引言

近年来, 随着医疗电子设备技术的不断发展, 人民群众对医疗生活水平要求的不断提高, 都表明了对电子设备

的健康发展有着更高水平的要求。当前, 医疗电子设备大多都是由单独的电路所控制, 一旦给电路供电的锂电池的性能不良, 就会引起医疗电子设备中的电路甚至整个设备的启动都不正常, 这种状况下, 很有可能会出现报错信息或者显示器上没有任何的显示与提示, 给医院的工作带来了极大的消极影响。对于心脏起搏器一类的生命支持类医疗电子设备而言, 如图 1 所示, 一旦给电路供电的锂电池发生故障, 将会给患者带来生命危险。医疗电子设备锂电池退化状态可以表征锂电池能否正常可靠工作的运行状态,

收稿日期: 2018-07-09; 修回日期: 2018-08-25。

基金项目: 上海第二工业大学研究生项目基金 (EGD18YJ0003)。

作者简介: 何成 (1976-), 男, 江苏盐城人, 博士研究生, 副教授, 主要从事故障诊断与寿命预测方向的研究。

不仅能够定量地显示出锂电池内部状态, 而且也是锂电池能否进行剩余寿命预测 (RUL) 的前提条件, 因而构建一套医疗电子设备锂电池的故障预测与健康管理系统对医疗电子设备有着重要的意义^[1]。



图 1 生命支持类医疗电子设备

标准粒子滤波算法存在的主要问题是无法避免退化现象, 主要表现为在经过几次递推之后, 除了很少几个粒子以外, 大部分粒子的权值几乎等于零, 从而使得大量的计算工作都被浪费在用来更新那些几乎不起作用的粒子上^[2]。本文针对上述问题, 提出了一种基于人工免疫粒子滤波算法与非线性自回归网络相结合的医疗电子设备锂电池故障预测与健康管理系统, 有效的避免了粒子退化现象, 同时还保证了粒子的多样性。

1 锂离子电池退化状态特征提取

由于锂离子电池在充放电刚开始和快结束时其充放电电压变化趋势较大且变化速度较快, 而在充放电中间过程充放电电压变化趋势较小且变化速度较慢。根据医疗电子设备锂电池监测数据, 提取出与医疗电子设备锂电池健康状态相关的特征参量, 作为医疗电子设备锂电池的健康因子^[3]。

1.1 电池内阻

通过搭建的医疗电子设备锂电池实验平台, 在很短的时间内让医疗电子设备锂电池接入一个比较大的恒定直流电流, 测量此时的医疗电子设备锂电池两端电压的变化。该方法测量时间短以至于医疗电子设备锂电池没有来得及产生电极极化效应, 因而这个时候测量计算得到的医疗电子设备锂电池的内阻应为欧姆内阻 R_0 ^[4]。

$$R_0 = \frac{\Delta U_1}{I} \quad (1)$$

式 (1) 中, U_1 为欧姆内阻引起的压降, I 为负载电流。在此之后, 由于极化电阻 R_p 作用, 医疗电子设备锂电池电压逐渐变化, 从而使得内部极化作用逐渐消失。

$$R_p = \frac{\Delta U_2}{I} \quad (2)$$

式 (2) 中, U_2 为极化内阻所引起的压降。

1.2 放电电压样本熵

样本熵方法是近似熵的改进方法, 它计算的是和的对数, 在不依赖于样本数据的长度的同时还能够有效降低误差, 用于度量时间序列复杂度^[5]。

对于长度为 N 的时间序列 $\{x_i\}$, 我们构造 $N-m+1$ 个 m 维矢量 $x_m(i)$:

$$x_m(i) = [x(i), x(i+1), \dots, x(i+m-1)], \quad i = 1, 2, \dots, N-m+1 \quad (3)$$

定义矢量 $x_m(i)$ 与 $x_m(j)$ 之间的距离为两者对应元素距离的最大值。

$$d_m[x_m(i), x_m(j)] = \max[x_m(i+k) - x_m(j+k)], \quad 0 \leq k \leq m-1 \quad (4)$$

根据给定阈值 r , 计算对于每个 i 值, $d_m[x_m(i), x_m(j)] \leq r, i \neq j$ 的总数, 记作 v^m 。

由此得到函数 $B_i^m(r)$ 如下:

$$B_i^m(r) = \frac{1}{N-m+1} v^m(i), i = 1, 2, \dots, N-m+1 \quad (5)$$

于是, 我们可以得到匹配点概率的表达式:

$$B^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^m(r) \quad (6)$$

类似的将维数加 1, 得到函数 $B_i^{m+1}(r)$ 与 $B^{m+1}(r)$ 。

$B^m(r)$ 表示两个序列在 m 个点上匹配的概率, B^{m+1} 表示在 $m+1$ 个点上两个序列匹配的概率。

于是可以得到样本熵的表达式:

$$\text{SampEn}(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \frac{B^{m+1}(r)}{B^m(r)} \right\} \quad (7)$$

当 N 取有限值时, 样本熵的近似值为:

$$\text{SampEn}(m, r, N) = \ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \quad (8)$$

1.3 等压降放电时间

由于等压降放电时间随电池循环次数的增加而缩短, 根据这一结论得出等压降放电时间与医疗电子设备锂电池性能健康状态之间的映射关系, 从而建立医疗电子设备锂电池退化状态退化状态健康因子^[6]。

$$\Delta t_i = |t_{\text{th}}^i - t_{\text{tl}}^i|, i = 1, 2, \dots, N \quad (9)$$

Δt_i 为第 i 周期处于等压降状态时的放电时间, t_{th}^i 对应第 i 个周期处于高电位状态时的放电时间, t_{tl}^i 表示第 i 个周期处于低电位状态时的放电时间。

1.4 等间隔放电时间序列

由式 (9) 可知, 由于实际放电过程的中间段曲线斜率较小和数据获得的不完备性, 当 ΔV 取值较小时可能导致 Δt 值误差较大, 从而导致 Δt 值误差较大^[7]。我们选择在 ΔV 压降范围内, n 个时间 t 的范围内以等间隔 Δv 的放电时间序列, 如表 1 所示。

表 1 等间隔放电时间序列

放电电压/V	V_H	$V_H - \Delta v$	$V_H - 2\Delta v$...	V_L
k 周期放电时间/s	t_1	t_2	t_3	...	t_n

2 基于医疗电子设备锂电池的 NARX 神经网络的健康因子构建

由于 NARX 神经网络由静态神经元和网络输出反馈构成, 所以其模型在序列的学习方面应用较广泛。NARX 全

称为带外部输入的非线性自回归模型，其 Matlab 网络模型如图 2 所示。式 (10) 为递归网络的输出公式^[8]。




图 2 NARX 神经网络模型

$$y(t) = f(x(t-1), \dots, x(t-d), y(t-1), \dots, y(t-d)) \quad (10)$$

式中， x 为输入向量， y 为输出向量， d 为延迟步长。

NARX 神经网络健康因子构建的流程图如下图 3 所示，分为以下 4 个步骤：

1) 提取特征参量：提取出与医疗电子设备锂电池性能状态有关的锂离子电池特征参量和对应的锂离子电池容量值，作为 NARX 的输入样本和目标样本。

2) 建立 NARX 神经网络：通过设定神经网络的初始状态参数的值来建立一个 NARX 神经网络，将隐含层节点数设定为 10 个，tansig 作为输入层激励函数，pureline 作为输出层激励函数^[9]。

3) NARX 神经网络训练：通过提取出的医疗锂离子电池的样本数据进行分类，将样本划分为训练集和测试集，通过模型的训练之后，将容量的估计值与实际值作对比，当医疗电子设备锂电池容量的估计值与医疗电子设备锂电池容量的实际值之间的误差达到设定值时停止训练。

4) NARX 健康因子验证：将医疗电子设备锂离子电池测试集输入到训练好的 NARX 神经网络模型中，得到医疗电子设备锂离子电池容量的估计值，计算医疗电子设备锂电池容量估计值与医疗电子设备锂电池容量实际值的偏差，验证 NARX 神经网络模型的可行性。

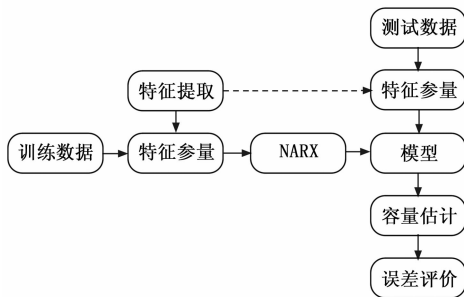


图 3 基于 NARX 神经网络构建健康因子的流程图

3 电池模型的建立

由于经验模型阶数低，结构简单而且利于工程实现，所以医疗电子设备锂电池 PHM 系统采用经验模型来建立锂电池的状态空间方程^[10]。

3.1 状态方程

由于主要是对医疗电子设备锂电池的 SOC (State of

Charge—荷电状态) 进行预测，所以具体计算公式如下：

$$SOC = SOC_0 - \int_0^t \frac{n_i i(\tau)}{C_n} d\tau \quad (11)$$

式中， $SOC(t)$ 为 t 时刻医疗电子设备锂电池的荷电状态值， SOC_0 为医疗电子设备锂离子电池荷电状态初值， C_n 为额定容量， $i(\tau)$ 为瞬时总电流， $i(\tau)$ 在医疗电子设备锂电池放电时为正、充电时为负， n_i 为医疗电子设备锂离子电池的库仑效率， $n_i=1$ 时为医疗电子设备锂离子电池充电状态， $n_i \leq 1$ 时为医疗电子设备锂离子电池放电状态。将上式进行离散化后，其计算公式变为：

$$x_k = x_{k-1} - \left(\frac{n_i \Delta t}{c_n}\right) i_{k-1} \quad (12)$$

式中， x_k 代表 k 时刻的 SOC 值，代表 $k-1$ 时刻的电流， Δt 表示时间间隔。

3.2 观测方程

为了使医疗电子设备锂电池模型更加符合医疗电子设备的实际工况，选择参数收敛效果理想的 Nernst 模型作为状态空间的观测方程。由此得到医疗电子设备锂电池的状态空间模型为：

状态方程：

$$x_k = x_{k-1} - \left(\frac{n_i \Delta t}{c_n}\right) i_{k-1} + \omega_k \quad (13)$$

观测方程：

$$y_k = k_0 - R i_k + k_1 \ln(x_k) + k_2 \ln(1 - x_k) + V_k \quad (14)$$

式中， y_k 代表 k 时刻的医疗电子设备锂电池的端电压， k_0 代表医疗电子设备锂电池荷电状态为 100% 时的电动势， x_k 代表医疗电子设备锂电池 k 时刻的 SOC 值， i_k 代表 k 时刻的医疗电子设备锂电池电流， R 代表医疗电子设备锂电池内阻， k_1, k_2 为医疗电子设备锂电池模型匹配参数， ω_k, V_k 为权重值。该模型结构简单，只要获得 N 组医疗电子设备锂电池数据 $\{y_k, i_k, x_k\}$ ，模型中的参数就可以最小二乘法辨识方法得到。

4 基于人工免疫粒子滤波算法的剩余寿命预测

针对基本的粒子滤波算法 (PF) 在重采样的过程中会出现失去粒子多样性甚至粒子耗尽等现象，提出人工免疫粒子滤波 (AIPF) 算法，通过这种算法可以使得粒子集保持一定的多样性，从而达到减轻粒子退化现象的影响^[11]。

4.1 人工免疫粒子滤波算法相关公式

设抗原为 1，抗体为粒子 (x_k^i, ω_k^i) ，有如下公式：

$$fit_k(i) = 1 - \omega_k^i \quad (15)$$

式中， $fit_k(i)$ 表述为粒子 (ω_k^i, ω_k^i) 中第 i 个抗体在 k 时刻的亲和能力，如果 $fit_k(i)$ 越小，表明抗体和抗原之间的匹配关系越好。

$$off_k(i, j) = |x_k^i - x_k^j| \quad (16)$$

$off_k(i, j)$ 为医疗电子设备锂电池第 i 个抗体与第 j 个抗体之间在 k 时刻的排斥力， $off_k(i, j)$ 值越小，就说明第 i 个抗体与第 j 个抗体之间的相似程度越高。

$$CLnum_k(i) = \text{round}\left(N \times \cos \frac{\pi \cdot fit_k(i)}{2}\right) \quad (17)$$

式中, $CLnum_k(i)$ 为医疗电子设备锂电池 k 时刻第 i 个抗体的克隆数, $round(\cdot)$ 表示向最近的整数取整。

$$x_k^i = x_k^i + fit_k(i) \times randn \quad (18)$$

式 (18) 为变异方程, $randn$ 代表一个满足 $N(0, 1)$ 分布的随机数。免疫系统的变异方程进行变异的规则是对亲和力大的抗体所进行的变异量大, 而对亲和力小的抗体所进行的变异量小。

4.2 人工免疫粒子滤波算法流程

人工免疫粒子滤波 (AIPF) 算法的步骤如下:

Step1: 设置 AIPF 算法初始参数;

Step2: 根据 AIPF 算法, 由初始概率密度函数 $p(x_0)$ 生成的粒子集 $\{x_0^i, \omega_0^i\}_{i=1}^N$ 中, $\omega_0^i = 1/N$;

Step3: 在 k 时刻, 利用式 (11) 得出粒子的值 $\tilde{x}_k^i \{i=1, 2, \dots, N\}$; 并用式 (12) 计算出 \tilde{x}_k^i 对应的 y_k^i ;

Step4: 粒子权值用公式:

$$w_k^i = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(y_k^i - \tilde{y}_k^i)^2}{2\sigma^2}} \quad (19)$$

计算并归一化权值:

$$\tilde{w}_k^i = w_k^i / \sum_{i=1}^N w_k^i \quad (20)$$

Step5: 医疗电子设备锂电池人工免疫算法:

1) 把求得的粒子集 $\{\tilde{x}_k^i, \tilde{w}_k^i\}_{i=1}^N$ 作为初始抗体群, 根据式 (15) 计算每个抗体的亲和力;

2) 克隆抗体;

3) 变异;

4) 选优;

Step6: 重新计算粒子权值, 返回 Step3, Step4, 得出新的医疗电子设备锂电池粒子集 $\{x_k^i, \omega_k^i\}_{i=1}^N$, 并归一化权值:

$$\tilde{w}_k^i = \omega_k^i / \sum_{i=1}^N \omega_k^i \quad (21)$$

Step7: 若 $N_{eff} > N_{thres}$, $\omega_k^i = \tilde{w}_k^i$, 转到 Step6; 若 $\sum_{j=1}^{m-1} \tilde{w}_k^j < u_i < \sum_{j=1}^m \tilde{w}_k^j$, 结果为: $x_k^i = x_k^m, \omega_k^i = \omega_k^m$. 将重采样后的医疗电子设备锂电池粒子权值进行归一化^[12];

Step8: 输出预测值:

$$\hat{x}_k = \sum_{i=1}^N \omega_k^i x_k^i \quad (22)$$

并将粒子权值更新为:

$$\omega_k^i = 1/N \quad (23)$$

Step9: 若 $k=M$, 则 AIPF 算法结束, 否则 $k = k+1$, 返回 Step3。

5 实验结果

5.1 基于 NARX 神经网络的医疗锂电池退化状态识别结果

图 4 所示为 4 种健康因子构建的容量输出值与真实容量输出值对比图, 在搭建的医疗电子设备锂电池实验平台上所测得的充放电数据采样有间隔, 因而实际获得的数据是离散的从而导致测量误差的产生。此时, 可以使用 RMSE (均方根误差—Root Mean Square Error) 与 R (相关系数—Correlation coefficient) 来体现健康因子的有效性。根据图

4 四种健康因子构建的容量输出值与真实容量输出值对比, 得出 4 种健康因子与电池性能退化状况的 R 和 RMSE, 如表 2 所示。




图 4 4 种健康因子构建的容量输出值与真实容量输出值对比图

表 2 4 种健康因子误差对比

健康因子种类	R	RMSE
电池内阻	0.8642	0.0758
放电电压样本熵	0.9672	0.2932
等压降放电时间	0.9929	0.0301
等间隔放电时间序列	0.9948	0.0217

结合图 4 和表 2 可得: 通过医疗电子设备锂电池性能指标 R 和 RMSE 来对比四种不同的健康因子, 从而直观表示出医疗电子设备锂电池性能退化状况与健康因子的关系, 其中, 等间隔放电时间序列的 R 为 0.9948, 相关性最高; RMSE 为 0.0217, 误差最小。得出更适合作为表征医疗电子设备锂电池性能退化状态的健康因子是等间隔放电时间序列, 具有比其他三种健康因子更优的结论。

5.2 基于人工免疫粒子滤波算法的 RUL 预测结果

取医疗电子设备锂电池容量的 70% 作为其充放电循环寿命的失效阈值, 即锂电池容量衰减到额定容量的 70% (即 60 mAh) 时所对应的锂电池充放电循环周期次数。利用锂电池的前 80 Cycle 的退化样本数据更新 PF, AIPF 的经验模型参数, 然后以 80 Cycle 为预测起始时刻进行 RUL 预测。在锂离子电池经验模型更新的同时, 将基于 AIPF 和 PF 的 RUL 预测结果进行对比和误差分析, 验证基于 AIPF 的锂离子电池剩余循环寿命预测方法的优势。

从图 5、图 6 可以看出, 基于 AIPF 算法的医疗锂电池剩余寿命预测结果更接近真实的最终寿命。从图 7 可以看出基于 AIPF 算法的医疗锂电池剩余寿命预测结果的相对误差小于基于 PF 算法的医疗锂电池剩余寿命预测结果的相对误差, 且随着循环周期的增加, 基于 PF 算法的医疗锂电池




图 5 基于 PF 算法的医疗锂电池剩余寿命预测结果图

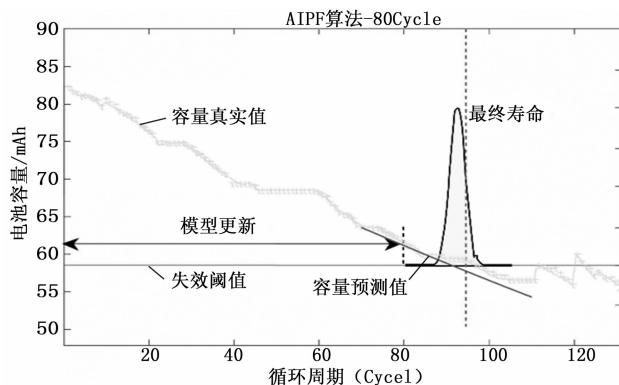


图 6 基于 AIPF 算法的医疗锂电池剩余寿命预测结果图

剩余寿命预测结果的相对误差越来越大，而基于 AIPF 算法的医疗锂电池剩余寿命预测结果的相对误差在 0.01~0.02 之间，变化较小，与真实情况更加贴合。

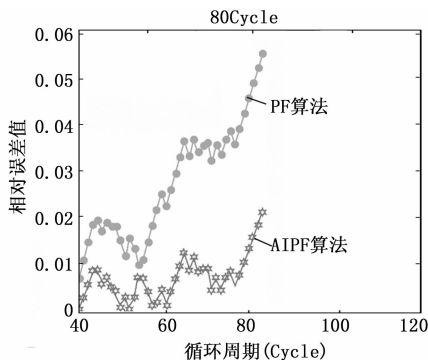


图 7 PF 与 AIPF 算法剩余寿命预测相对误差对比图

6 结论

通过选择医疗电子设备锂电池内阻、医疗电子设备锂电池放电电压样本熵、医疗电子设备锂电池等压降放电时间和医疗电子设备锂电池等间隔放电时间序列作为医疗电子设备锂电池性能退化相关的健康因子，并进行 NARX 神经网络的健康因子构建，训练所测数据后，根据与锂电池实际退化状态对比，通过医疗电子设备锂电池性能指标 R 和 RMSE 来对比四种不同的健康因子，从而直观表示出医疗电子设备锂电池性能退化状况与健康因子的关系，得出

更适合作为表征医疗电子设备锂电池性能退化状态的健康因子是等间隔放电时间序列，即可用等间隔放电时间序列的状态变化来监测医疗电子设备锂电池性能退化状态。通过对比基于 AIPF 算法和 PF 算法的医疗锂电池剩余寿命预测结果，得出基于 AIPF 算法的医疗锂电池剩余寿命预测结果的相对误差小于基于 PF 算法的预测结果的相对误差的结论，从而证明了 AIPF 算法有效抑制了 PF 算法重采样过程中粒子退化问题，提高了预测精度，验证了医疗电子设备锂电池故障预测与健康管理系统的可行性与可实施性，对于医疗电子设备的稳定发展具有推动作用。

参考文献:

- [1] 王苏湘, 彭驭风, 赵有璠. 医用电子设备传统电池升级为锂离子电池的可行性研究 [J]. 医疗卫生装备, 2014, 35 (9): 46-48.
- [2] 杨洁, 曾云, 杨艳军. 基于 TFT-LCD 显示的高精度线性锂电池库仑计 [J]. 重庆师范大学学报 (自然科学版), 2015 (4): 118-122.
- [3] Landau I. Agreement at PF: an argument from partial control [J]. Syntax, 2016, 19 (1): 79-109.
- [4] Mishra M, Martinsson J, Rantatalo M, et al. Bayesian hierarchical model-based prognostics for lithium-ion batteries [J]. Reliability Engineering & System Safety, 2018, 172: 25-35.
- [5] Dalal M, Ma J, He D. Lithium-ion battery life prognostic health management system using particle filtering framework [J]. Journal of Risk & Reliability, 2015, 225 (1): 81-90.
- [6] Alshurafa N, Eastwood J A, Nyamathi S, et al. Battery optimization in smartphones for remote health monitoring systems to enhance user adherence [A]. International Conference on Pervasive Technology [C]. 2014: 8.
- [7] Dudézert CAB, et al. Application of a mechanical methodology for lithium-ion battery life prediction [A]. 24th International Battery, Hybrid and Fuel Cell Electric Vehicle Symposium and Exhibition 2009 [C]. EVS 24, 2009, 3: 2043-2053.
- [8] Li X, Miao J, Ye J. Lithium-ion battery remaining useful life prediction based on grey support vector machines [J]. Advances in Mechanical Engineering, 2015, 7 (12): 1-8.
- [9] Challa S, Wazid M, Das A K, et al. Authentication protocols for implantable medical devices: taxonomy, analysis and future directions [J]. IEEE Consumer Electronics Magazine, 2017, 7 (1): 57-65.
- [10] Wang D, Yang F, Zhao Y, et al. Prognostics of Lithium-ion batteries based on state space modeling with heterogeneous noise variances [J]. Microelectronics Reliability, 2017, 75: 1-8.
- [11] Tao L, Ma J, Cheng Y, et al. A review of stochastic battery models and health management [J]. Renewable & Sustainable Energy Reviews, 2017, 80: 716-732.
- [12] 常海涛. 基于人工免疫粒子滤波的纯电动汽车锂电池 SOC 估计研究 [J]. 北京: 北京交通大学, 2013.