



(12) 发明专利申请

(10) 申请公布号 CN 103778280 A

(43) 申请公布日 2014. 05. 07

(21) 申请号 201410008739. 7

(22) 申请日 2014. 01. 08

(71) 申请人 上海交通大学

地址 200240 上海市闵行区东川路 800 号

(72) 发明人 魏岩 张峰华 王毓 杨煜普

(74) 专利代理机构 上海旭诚知识产权代理有限公司 31220

代理人 郑立

(51) Int. Cl.

G06F 17/50 (2006. 01)

G01R 31/36 (2006. 01)

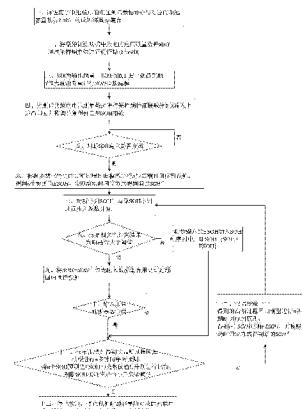
权利要求书3页 说明书9页 附图4页

(54) 发明名称

具有模型主动更新策略的锂离子电池剩余寿命预测方法

(57) 摘要

本发明涉及一种具有模型主动更新策略的锂离子电池剩余寿命预测方法，根据放电曲线的电压范围得出的时间序列进行变换得出每次放电循环等价的放电差异序列，并以此得出锂电池的健康指数时间序列，根据这个放电电压序列与健康指数序列的对应进行时间序列预测以确定电池的剩余寿命。通过对于放电电压曲线进行采样熵特征提取并建模以提供一个完整且精确的充放电过程与电池性能指标的联系。在此性能指标模型的基础上，将短期时间序列预测结果不断地更新到已知性能指标数据序列中，并进行相关性分析，根据相关性程度不同，通过扩充训练集的方式进行重新训练，与原有的迭代更新训练方式有所不同，动态地更新预测模型，从而提高预测精度。



1. 一种锂离子电池剩余寿命预测方法,其特征在于,包括以下步骤:

(1) 建立高斯过程回归模型;

(2) 计算得到 SOH 指数序列;

(3) 根据所述高斯过程回归模型,进行 n 步时间序列预测,得到 n 个 SOH 指数预测值 ESOH,其中 n 为时间序列预测的步数,n 为大于或等于 1 的整数,并根据所述 SOH 指数序列按照滚动时间窗方式得到 SOH' 指数序列;

(4) 对所述 SOH' 指数序列与所述 SOH 指数序列,进行相关系数计算;

(5) 根据步骤(4)得到的所述相关系数进行判断,如果所述相关系数大于或者等于设定值,将 SOH' 指数序列作为新的 SOH 指数序列;如果所述相关系数小于所述设定值,将 n 个所述 SOH 指数预测值 ESOH 加入所述 SOH 指数序列中,得到新的 SOH 指数序列;

(6) 根据步骤(5)得到的 SOH 指数序列,建立 SOH 向量,以所述 SOH 向量作为输入向量,重新建立高斯过程回归模型;

(7) 根据步骤(6)得到的所述高斯过程回归模型,进行 n 步时间序列预测,得到 n 个 SOH 指数预测值 ESOH;

(8) 将步骤(7)得到的 n 个所述 SOH 指数预测值 ESOH,与失效阈值 U 分别进行比较,如果得到的 n 个所述 SOH 指数预测值 ESOH 中的每一个都小于失效阈值,停止预测,停止预测时所对应的充放电循环次数,为锂离子电池剩余寿命预测值;否则,将 n 个所述 SOH 指数预测值 ESOH,根据步骤(5)SOH 指数序列按照滚动时间窗方式,得到新的 SOH' 指数序列,执行步骤(4)。

2. 如权利要求 1 所述的锂离子电池剩余寿命预测方法,其特征在于,步骤(1)中建立所述高斯过程回归模型,包括以下步骤:

(11) 选择锂离子电池放电的电压测量数据集合 X_{init} 及电池容量数据 Y_{init} ,构成训练数据序列集合 $\{X_{init}, Y_{init}\}$;

(12) 分别对所述放电的电压测量数据集合 X_{init} 的每次放电电压数据序列,通过采样熵方法进行特征提取,得到向量 X;

(13) 将所述电池容量数据 Y_{init} 进行归一化处理,得到向量 Y;

(14) 以所述向量 X 为输入向量,以所述向量 Y 作为输出向量,建立所述高斯过程回归模型。

3. 如权利要求 2 所述的锂离子电池剩余寿命预测方法,其特征在于,步骤(12)中对所述放电的电压测量数据集合 X_{init} 的每次放电电压数据序列,通过采样熵方法进行特征提取,计算采样熵的方法包括以下步骤:

(121) 选取由步骤(11)得到的从开始运行时刻 t_1 到当前采样时刻 t_k 对应的充放电循环的锂离子放电电压数据序列集合 $X_{init}=\{X_1, X_2, \dots, X_k\}$,并对其中每个放电电压曲线 X_t ,其中 $t=1, \dots, k$, k 是当前时刻对应数据的序号,构建 $k-m+1$ 维向量 $x_m(i)=[x(i), x(i+1), \dots, x(i+m-1)]$, $i=1, \dots, k-m+1$,其中 m 是与电池降级模型相关的值;

(122) 计算两个不同放电循环之间的距离:

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

(123) 定义函数

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

其中 r 是接受矩阵的容忍度, v^m 是 $d_m[x_m(i), x_m(j)] \leq r$ 的个数;

(124) 定义函数

$$A_i^m(r) = \frac{w^{m+1}(i)}{k-m+1}, \quad i=1, \dots, k-m+1$$

其中 w^{m+1} 是 $d_{m+1}[x_{m+1}(i), x_{m+1}(j)] \leq r$ 的个数;

(125) 计算得到

$$B^m(r) = \frac{\sum_{i=1}^{k-m} B_i^m(r)}{k-m}, \quad A^m(r) = \frac{\sum_{i=1}^{k-m} A_i^m(r)}{k-m};$$

(126) 计算采样熵

$$SampEn(m, r, k) = -\ln \left[\frac{A^m(r)}{B^m(r)} \right].$$

4. 如权利要求 3 所述的锂离子电池剩余寿命预测方法, 其特征在于, 分别对根据步骤(121) 中的每个所述放电电压曲线 X_t , 计算步骤(126) 中的 $SampEn(m, r, k)$, 构成所述向量 X 。

5. 如权利要求 2 所述的锂离子电池剩余寿命预测方法, 其特征在于, 步骤(13) 中将所述电池容量数据 Y_{init} 进行归一化处理, 构成所述向量 Y 的方法为:

$$SOH_i = \frac{Y_i}{Y_n - Y_1},$$

其中 Y_1 为初始时电池容量值, Y_n 为电池失效时容量值。

6. 如权利要求 1 所述的锂离子电池剩余寿命预测方法, 其特征在于, 步骤(3)中根据所述 SOH 指数序列按照滚动时间窗方式得到 SOH' 指数序列的方法包括步骤:

(31) 设定初始 n 值, 利用所述高斯过程回归模型进行 n 步时间序列预测;

(32) 计算每步预测的置信范围 s_i ;

(33) 根据 s_i 是否大于之前 $i-1$ 步的置信范围的均值的 2 倍

$$s_i \geq \frac{2 \cdot \sum_{n=0}^{i-1} s_n}{i-1}$$

判断是否需要停止 n 步时间序列预测, 判断为是, 则根据滚动时间窗准则得到所述 SOH' 指数序列。

7. 如权利要求 1 所述的锂离子电池剩余寿命预测方法, 其特征在于, 步骤(2)中计算 SOH 指数序列, 是通过所述高斯过程回归模型获得。

8. 如权利要求 1 所述的锂离子电池剩余寿命预测方法, 其特征在于, 步骤(2)中计算 SOH 指数序列, 是通过训练样本获得, 选取从电池从开始使用到当前充放电循环的锂离子电池容量与放电电压数据的 k 次循环数据序列 $X_{init} = \{x(1), x(2), \dots, x(k)\}$ 作为 SOH 指数序列。

9. 如权利要求 1 所述的锂离子电池剩余寿命预测方法,其特征在于,步骤(4)中所述相关系数为 Pearson 相关系数。

10. 如权利要求 1 所述的锂离子电池剩余寿命预测方法,其特征在于,步骤(3)中根据所述 SOH 指数序列按照滚动时间窗方式得到所述 SOH' 指数序列,是指在所述 SOH 指数序列中删除从头开始的 n 个元素,并在所述 SOH 指数序列的末尾加入 n 个所述 SOH 指数预测值 ESOH,得到所述 SOH' 指数序列。

具有模型主动更新策略的锂离子电池剩余寿命预测方法

技术领域

[0001] 本发明涉及一种具有模型主动更新策略的锂离子电池剩余寿命预测方法,用于电子设备的可靠性监控,属于蓄电池领域。

背景技术

[0002] 由于锂电池基于其重量轻、能量密度大和使用寿命长等优点,目前已被广泛应用于移动通信装置、电动车辆、军用电子设备以及航空航天电子系统等领域。然而,锂电池在使用过程中随着充放电循环的进行,锂离子电池内阻增大,性能会逐渐衰退,它的失效不仅会带来由于故障停机、更换或维修而产生的巨大经济损失,还可能导致灾难性的事故。因此,锂电池的预测与健康管理(PHM, Prognostics and Health Management)技术,及早准确地预测出锂电池的剩余寿命(RUL, Remain Useful Life),对于电子系统的安全性、稳定性和经济性具有重要意义。

[0003] 剩余寿命预测是个典型的多步时序预测问题,多步预测通常有两种方法:1)直接法,即通过一定的数学模型直接逼近n步的预测公式;2)迭代法,即通过一定的数学模型逼近1步预测公式,然后通过对对其进行迭代操作,进而实现多步预测。

[0004] 目前,剩余寿命预测方法可分为基于模型和数据驱动两类。基于模型的方法从电池内部的电化学反应出发建立电池等效电路模型,预测精度依赖模型的准确性,由于电池锂电池内部物理化学结构非常复杂,难以建立物理失效模型,受此影响,现有的基于模型的方法主要是寻找数学模型去拟合锂电池的退化轨迹,然后运用粒子滤波方法实现预测。

[0005] 数据驱动方法则主要包括神经网络、支持向量机等方法。

[0006] 神经网络预测方法不需要建立系统的数学模型且具有极强的非线性映射能力,但缺点在于缺乏理论基础,过于依靠开发者经验;需要较多的数据进行离线训练,且计算量大;单次预测不包含不确定性信息。

[0007] 支持向量机方法针对小样本、非线性问题具有明显优势,已经被广泛应用于预测领域,但其主要缺点是只能给出单点预测值。更为重要的是,由于在电池的完整生命周期中,会出现能量再生现象使得模型产生明显变化,也就意味着原模型的失效,导致锂离子电池剩余寿命预测的精度不高。

[0008] 因此本领域技术人员致力于寻找一种消除由于不正常的充放电循环带来的偏差的方法。

发明内容

[0009] 针对现有技术中存在的问题,本发明的目的在于提供一种锂离子电池剩余寿命预测方法,解决现有锂离子电池剩余寿命预测方法中存在的依赖经验模型来建立状态转移方程预测精度差、对于模型的失配无法自适应调整的问题。

[0010] 锂离子电池容量退化总体呈下降趋势,局部存在明显的容量再生现象。且锂离子容量数据是典型的小样本数据。直接采用回归预测方法进行迭代预测时,由于较少的数据

样本很难获得较高的精度。另一方面迭代预测依赖于准确的单步预测，单步预测误差会随着迭代过程的进行而逐渐累积，最终导致滚动时间窗迭代预测方法预测精度急剧下降。

[0011] 本发明提供一种具有模型主动更新策略的锂离子电池剩余寿命预测方法，能有效地根据高斯过程回归模型预测置信度的变化，给出对应的反馈，即是否更新模型或继续用此模型进行预测，并因此实现高精度、自适应模型校正的锂离子电池剩余寿命预测方法。由于直接方案对训练数据的要求较高，在实际应用中通常难以满足，故本发明是针对锂离子电池剩余寿命预测实现基于模型主动更新策略的迭代预测方案。

[0012] 高斯过程回归(Gaussian Process Regression, GPR)是近几年发展起来的一种机器学习回归方法，它有着严格的统计学习理论基础，对处理高维数、小样本、非线性等复杂的问题具有很好的适应性，且泛化能力强。与神经网络、支持向量机相比，GPR 具有容易实现、超参数自适应获取、非参数推断灵活以及输出具有概率意义等优点。

[0013] 高斯过程回归是一种非参数贝叶斯回归框架，具有灵活的非参数推断、超参数自适应获取等优点，是一个具有概率意义的核学习机，可对预测输出做出概率解释，应用高斯过程回归进行预测可以很好地克服能量再生预测的困难。

[0014] 本发明提供一种锂离子电池剩余寿命预测方法，其特征在于，包括以下步骤：

[0015] (1) 建立高斯过程回归模型；

[0016] (2) 计算 SOH 指数序列；

[0017] (3) 根据所述高斯过程回归模型，进行 n 步时间序列预测，得到 n 个 SOH 指数预测值 ESOH，其中 n 为时间序列预测的步数，其中 n 为大于或等于 1 的整数，并根据所述 SOH 指数序列按照滚动时间窗方式得到 SOH' 指数序列；

[0018] (4) 对 SOH' 指数序列与所述 SOH 指数序列，进行相关系数计算；

[0019] (5) 根据步骤(4)得到的相关系数进行判断，如果相关系数大于或者等于设定值，将所述 SOH' 指数序列作为新的 SOH 指数序列；如果相关系数小于设定值，将 n 个 SOH 指数预测值 ESOH 加入 SOH 指数序列中，得到新的 SOH 指数序列；

[0020] (6) 根据步骤(5)得到的 SOH 指数序列，建立 SOH 向量，以 SOH 向量作为输入向量，重新建立高斯过程回归模型；

[0021] (7) 根据步骤(6)得到的高斯过程回归模型，进行 n 步时间序列预测，得到 n 个 SOH 指数预测值 ESOH；

[0022] (8) 将步骤(7)得到的 n 个所述 SOH 指数预测值 ESOH，与失效阈值 U 分别进行比较，如果 n 个 SOH 指数预测值 ESOH 中的每一个都小于失效阈值，停止预测，停止预测时对应的充放电循环次数，为锂离子电池剩余寿命预测值；否则，将 n 个 SOH 指数预测值 ESOH，根据步骤(5) SOH 指数序列按照滚动时间窗方式，得到新的 SOH' 指数序列，执行步骤(4)。

[0023] 进一步地，步骤(1)中建立高斯过程回归模型，包括以下步骤：

[0024] (11) 选择锂离子电池放电的电压测量数据集合 X_{init} 及电池容量数据 Y_{init} ，构成训练数据序列集合 $\{X_{init}, Y_{init}\}$ ；

[0025] (12) 分别对所述放电的电压测量数据集合 X_{init} 的每次放电电压数据序列，通过采样熵方法进行特征提取，得到向量 X；

[0026] (13) 将电池容量数据 Y_{init} 进行归一化处理，得到向量 Y；

[0027] (14) 以向量 X 为输入向量，以向量 Y 作为输出向量，建立高斯过程回归模型。

[0028] 进一步地,步骤(12)中对放电的电压测量数据集合 X_{init} 的每次放电电压数据序列,通过采样熵方法进行特征提取,计算采样熵的方法包括以下步骤:

[0029] (121)选取由步骤(11)得到的系统运行当前时刻之前的充放电循环的锂离子放电电压数据序列集合 $X_{init} = \{X_1, X_2, \dots, X_k\}$, 并对其中每个放电电压曲线 X_t , $t=1, \dots, k$, 构建 $k-m+1$ 维向量 $x_m(i) = [x(i), x(i+1), \dots, x(i+m-1)]$, $i=1, \dots, k-m+1$, 其中 m 是与电池降级模型相关的值;其中 X_{init} 是放电电压曲线集合, X_t 表示每个放电电压曲线, x_m 则是 X_t 中的具体时间序列的构建形式。

[0030] (122)计算两个不同放电循环之间的距离:

$$[0031] d_m[x_m(i), x_m(j)] = \max[x_m(i+k) - x_m(j+k)]$$

[0032] 其中, $0 \leq k \leq m-1$

[0033] (123)定义函数

$$[0034] B_i^m(r) = \frac{v^m(i)}{k-m+1}, \quad i=1, \dots, k-m+1$$

[0035] 其中 r 是接受矩阵的容忍度, v^m 是 $d_m[x_m(i), x_m(j)] \leq r$ 的个数;

[0036] (124)定义函数

$$[0037] A_i^{m+1}(r) = \frac{w^{m+1}(i)}{k-m+1}, \quad i=1, \dots, k-m+1$$

[0038] 其中 w^{m+1} 是 $d_{m+1}[x_{m+1}(i), x_{m+1}(j)] \leq r$ 的个数;

[0039] (125)计算得到

$$[0040] B^m(r) = \frac{\sum_{i=1}^{k-m} B_i^m(r)}{k-m}, \quad A^m(r) = \frac{\sum_{i=1}^{k-m} A_i^{m+1}(r)}{k-m};$$

[0041] (126)根据步骤(125)中 $A^m(r)$, $B^m(r)$ 计算采样熵

$$[0042] SampEn(m, r, k) = -\ln \left[\frac{A^m(r)}{B^m(r)} \right].$$

[0043] 进一步地,分别对根据步骤(121)中的每个放电电压曲线 X_t ,计算步骤(126)中的 $SampEn(m, r, k)$,构成向量 X 。

[0044] 进一步地,将电池容量数据 Y_{init} 进行归一化处理,构成向量 Y 的方法为:

$$[0045] SOH_i = \frac{Y_i}{Y_n - Y_1},$$

[0046] 其中 Y_1 为初始时电池容量值, Y_n 为电池失效时容量值。

[0047] 进一步地,步骤(3)中根据 SOH 指数序列按照滚动时间窗方式得到 SOH' 指数序列的方法包括步骤:

[0048] (31)设定初始 n 值,利用高斯过程回归进行 n 步时间序列预测;

[0049] (32)计算每步预测的置信范围 s_i ;

[0050] (33)根据 s_i 是否大于之前 $i-1$ 步的置信范围的均值的 2 倍,

$$[0051] s_i \geq \frac{2 \cdot \sum_{n=0}^{i-1} s_n}{i-1}$$

[0052] 来判断是否需要停止多步预测，判断为是，则根据滚动时间窗准则得到最终更新的数据序列 SOH'。

[0053] 进一步地，步骤(2)中计算 SOH 指数序列，是通过所述高斯过程回归模型获得。

[0054] 进一步地，步骤(2)中计算 SOH 指数序列，是通过训练样本获得，选取从电池从开始使用到当前充放电循环的锂离子电池容量与放电电压数据的 k 次循环数据序列 X(0)={x(0), x(1), …, x(k-1)} 作为 SOH 指数序列。

[0055] 进一步地，步骤(4)中相关系数为 Pearson 相关系数。

[0056] 进一步地，步骤(3)中根据 SOH 指数序列按照滚动时间窗方式得到 SOH' 指数序列，是指在 SOH 指数序列中删除从头开始的 n 个元素，并在 SOH 指数序列的末尾加入 n 个 SOH 指数预测值 ESOH，得到 SOH' 指数序列。

[0057] 与现有技术相比，本发明提供的锂离子电池剩余寿命预测方法具有如下技术效果：

[0058] (1) 采用高斯过程回归模型，对处理高维数、小样本、非线性等复杂的问题具有很好的适应性，且泛化能力强，与神经网络、支持向量机相比，高斯过程回归方法具有容易实现、超参数自适应获取、非参数推断灵活以及输出具有概率意义等优点；

[0059] (2) 提出基于模型主动更新策略的高斯过程回归模型，通过将短期时间序列预测结果以不同策略更新到训练数据序列中，通过扩充训练集的方式进行重新训练，与原有的迭代更新训练方式有所不同，动态地更新预测模型，从而提高预测精度；

[0060] (3) 由于在线应用时通常无法得到电池容量数据，通过电压测量数据进行采样熵特征提取后进行回归得到电池健康状态 SOH 模型，再根据已有的 SOH 模型进行进一步的剩余寿命预测；

[0061] (4) 进行相似度分析并以此为依据，若与原始模型进行相关系数比较时发现变化较大，则原有模型无法对新加入的数据进行正确建模，此时模型训练数据集个数有所变化，因此是通过扩充训练集的方式进行重新训练，与原有的迭代更新训练方式有所不同，动态地更新预测模型，从而提高预测精度。

附图说明

[0062] 图 1 为本发明的一个实施例的模型主动更新策略的锂离子电池剩余寿命预测方法的流程图；

[0063] 图 2 为采样熵与电池容量的对比曲线；

[0064] 图 3 为 4 个电池容量退化曲线图；

[0065] 图 4 为电池 #5 的健康状态 SOH 指数的预测曲线；

[0066] 图 5 为电池 #6 的健康状态 SOH 指数的预测曲线；

[0067] 图 6 为电池 #18 的健康状态 SOH 指数的预测曲线。

具体实施方式

[0068] 图 1 为本发明的一个实施例的模型主动更新策略的锂离子电池剩余寿命预测方法的流程图,本实施例的模型主动更新的锂离子电池剩余寿命预测方法,包括下述步骤:

[0069] 步骤一、选择锂离子电池放电的电压测量数据序列集合 X_0 及电池容量序列 Y_0 , 构成训练数据集合;

[0070] 步骤二、将原始训练数据中放电的电压测量数据序列集合 X_0 通过采样熵方法进行特征提取得到 X ;

[0071] 步骤三、采用高斯过程回归方法,以步骤二中采样熵提取得到的 X 为输入向量,将 Y_0 归一化后得到的 Y 的作为输出向量进行 SOH 指数建模;

[0072] 步骤四、将已有输入向量 X 输入高斯回归模型计算得到 SOH 指数;

[0073] 步骤五、判断训练集数据回归建模是否完成,若是,执行步骤六;若否,则重复预测;

[0074] 步骤六、根据步骤三得到的高斯过程回归模型进行 n 步短期时间序列预测,得到 n 步 SOH 预测值 ESOH, 并按照滚动时间窗方式得到新的 SOH', 即在原 SOH 序列中删除从头开始的 n 个元素, 并在末尾加入这 n 个 SOH 预测值 ESOH, 得到新序列 SOH' ;

[0075] 步骤七、对步骤六得到的新序列 SOH' 与原 SOH 序列进行 Pearson 相关系数计算;

[0076] 步骤八、根据 Pearson 相关系数计算结果进行判断,若相关性大于 0.8,判断为是,将 SOH' 作为新的 SOH 序列,即 $SOH = SOH'$, 执行步骤九的递推预测,否则将步骤六的 ESOH 加入 SOH 序列中,即 $SOH = \{SOH \cup ESOH\}$;

[0077] 步骤九、将新得到的 SOH 作为输入数据序列,建立高斯过程回归模型,并进行预测;

[0078] 步骤十、判断输入数据序列预测是否完成,若是,执行步骤十一;若否,则重复预测;

[0079] 步骤十一、健康指数预测:根据步骤九得到的高斯过程回归模型进行 n 步时间序列预测,将 n 步 SOH 预测值 ESOH 与失效阈值 U 分别进行比较,判断 SOH 预测值是否小于失效阈值 $U = 1.38Ah$,若是执行步骤十三,否则执行步骤十二;

[0080] 步骤十二、将得到的 n 步 ESOH 预测值,按照滚动时间窗方式加入原 SOH 得到 SOH', 即在原 SOH 序列中删除从头开始的 n 个元素,并在末尾加入这 n 个 SOH 预测值 ESOH, 得到新序列 SOH' 返回执行步骤七;

[0081] 步骤十三、停止预测,停止预测时的容量所对应的充放电循环次数,即为锂离子电池剩余寿命预测值。

[0082] 本实施方式构造的 SOH' 序列与上一步数据 SOH 序列进行 Pearson 相关系数相似度计算,根据 Pearson 相关系数的大小来判断两个模型相差是否过大。根据相关系数的大小来判断是否需要通过扩充训练集增加模型复杂度来进行重新训练,相似度阈值的取值范围需要根据实际问题进行选取,取值过大可能会造成预测误差较大,取值太小会导致训练频繁,降低效率。

[0083] 具体实施方式二、本实施方式与具体实施方式一所述的具有模型主动更新策略的锂离子电池剩余寿命预测方法的区别在于,步骤一所述的选择锂离子电池电压与容量的训练数据,并将该数据集构建初始 SOH 指数的具体过程为:

[0084] 选取从电池从开始使用到当前充放电循环的锂离子电池容量与放电电压数据的 k

次循环数据序列作为初始数据序列 $X(0)=\{x(0), x(1), \dots, x(k-1)\}$, 其中 $X(0)$ 代表初次构建得到的数据序列。

[0085] 具体实施方式三、本实施方式与具体实施方式二所述的具有模型主动更新策略的锂离子电池剩余寿命预测方法的区别在于, 步骤二所述的对原始数据进行采样熵特征提取, 及高斯过程回归建立 SOH 指数的具体过程为:

[0086] 步骤三一、选取由步骤一得到的当前时刻之前的充放电循环的锂离子放电电压数据序列 X_2 , 构建 $N-m+1$ 维向量 $x_m(i)=[x(i), x(i+1), \dots, x(i+m-1)]$, $i=[1, 2, \dots, N-m+1]$ 。 m 是一个跟电池降级模型相关的一个值, 本例中取 $m=2$, 当前时刻是滚动时间窗预测得到的最新数据对应时刻。

[0087] 步骤三二、按如下公式计算两个不同放电循环之间的距离:

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

[0089] 定义函数

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

[0091] 其中 r 是接受矩阵的容忍度, v^m 是对于所有 $i \neq j$, $d_m[x_m(i), x_m(j)] \leq r$ 的个数。

[0092] 再定义函数

$$A_i^m(r) = \frac{w^{m+1}(i)}{N-m+1}, i=1, \dots, k-m+1 \quad (3)$$

[0094] 其中 w^{m+1} 是对于所有 $i \neq j$, $d_{m+1}[x_{m+1}(i), x_{m+1}(j)] \leq r$ 的个数。

[0095] 然后就可以计算得到所有对应点概率的表达式

$$B^m(r) = \frac{\sum_{i=1}^{k-m} B_i^m(r)}{k-m}, A^m(r) = \frac{\sum_{i=1}^{k-m} A_i^m(r)}{k-m} \quad (4)$$

[0097] 并因此可以得到采样熵度量

$$SampEn(m, r, k) = -\ln \left[\frac{A^m(r)}{B^m(r)} \right] \quad (5)$$

[0099] 步骤三三、将得到的 SampEn 与对应长度的电池健康状态序列 $[X_1(m), \dots, X_1(n)]$, 构成 2 维向量 X , 作为高斯过程回归模型的输入向量。

[0100] 步骤三四、对电池健康状态序列 X_1 计算得到归一化的健康指数序列

$$SOH = X \cdot M_{SOH} \quad (6)$$

[0102] 步骤三五、将电池健康状态序列归一化到 $[0, 1]$ 之间, 即令 $SOH_i = \frac{X_i}{X_n - X_1}$, 作为高斯过程回归模型的输出向量。

[0103] 步骤三六、选取高斯过程的两个关键函数 $m(x)$ 和协方差函数 $k(x, x')$, 其中 $m(x)=E(f(x))$, $k(x, x') = E[(f(x)-m(x)) \cdot (f(x')-m(x'))]$, 由于对于 $0 \sim 1$ 之间的 SOH 进行回归, 高斯过程的后验已可对均值变化很好地建模, 因此令均值函数 $m(x)=0$ 。

[0104] 步骤三七、将 $k(x_i, x_j)$ 分解为函数部分与噪音部分, 即

$$k(x_i, x_j) = k_f(x_i, x_j) + k_n(x_i, x_j) \quad (7)$$

[0106] 其中,根据电池剩余寿命的变化情况的分析先验,先验是指对电池剩余寿命变化曲线的形状的先验知识, k_f 可以建模为一个各向同性的平方指数项与一个周期项之和的核函数,如下所示

$$[0107] k_f = \sigma_f^2 [\exp\left(-\frac{(x-x')^2}{2l^2}\right) + \exp\left(-\frac{2}{l^2} \sin^2\left(\frac{\pi}{2\pi}(x-x')\right)\right)] \quad (8)$$

[0108] 噪声项则视为一个稳定的白噪声,即 k_n 为一个常数, $k_n(x_i, x_j) = v_0$ 。

[0109] 步骤三八、由上述步骤可以得到协方差函数的超参数序列 $\Theta = [\sigma_f, \sigma_n, l_1, l_2, v_0]^T$, 通过设定一定的初值,并利用最大边缘分布方法对高斯似然函数对 Θ 进行推断,得到最佳的参数值,此时高斯过程回归建模完毕。本例中设置超参数初值为 $[\log(1), \log(1), \log(1), \log(1), \log(0.1)]$ 。

[0110] 具体实施方式四、本实施方式与具体实施方式一或具体实施方式三所述的基于模型主动更新策略的锂离子电池剩余寿命预测方法的区别在于,步骤四所述的判断 SOH 预测是否完成的具体过程为:

[0111] 利用高斯过程回归进行多步预测,初始设定 $n=5$,并得到每步预测的方差置信范围 s_i ,根据 s_i 是否大于之前 $i-1$ 步的置信范围的均值的 2 倍,即如下判别公式

$$[0112] s_i \geq \frac{2 \cdot \sum_{n=0}^{i-1} s_n}{i-1} \quad (9)$$

[0113] 来判断是否需要停止多步预测,判断为是,则根据滚动时间窗准则得到最终更新的数据序列 SOH' 。

[0114] 具体实施方式五、本实施方式与具体实施方式一或具体实施方式四所述的模型主动更新策略的锂离子电池剩余寿命预测方法的区别在于,步骤七所用的 Pearson 相关系数计算 2 个模型预测结果相关性的方法为:

[0115] 步骤五一,令 X 序列为上一步得到的 SOH 序列, Y 序列为新得到的 SOH 序列, μ_x, σ_x 分别是 X 序列对应的均值和方差, μ_y, σ_y 是 Y 序列对应的均值和方差,然后为按照

$$[0116] PCC = \frac{\text{cov}(X, Y)}{\sigma_x \sigma_y} = \frac{E[(X - \mu_x)(Y - \mu_y)]}{\sigma_x \sigma_y}$$

[0117] 计算得到 Pearson 相关系数。

[0118] 相关程度阈值需要根据实际情况进行调整,取值过大可能会造成预测精度较大,取值太小会导致训练频繁,降低效率。在下面的实验过程中设为 0.8。

[0119] 为了验证所提出的预测框架是否能够有效地实现锂离子电池的寿命估计,采用美国国家航空航天局(NASA)提供的 Battery Data Set 实验数据进行实验验证。该数据集来源于 NASA PCoE 研究中心搭建的锂离子电池实验数据集,通过自定义构建的电池预测试验台采集的,测试台由商用 1850 型可充电锂电池、可编程直流电子负载、电源、电压表、安培计、热电偶传感器、电化学阻抗谱检测仪以及用于数据采集和实验控制的 PXI 机箱组成,采用在室温(24°C)条件下进行如下测试(充电、放电和阻抗测量)的第三组数据(包括电池 #5、电池 #6、电池 #7、电池 #18)的结果:

[0120] 在恒定电流为 1.5A 的模式下进行充电,直到电池电压达到 4.2V;

[0121] 在恒定电流为 2A 的模式下进行放电,直到电池电压下降到 2.5V;

[0122] 通过 EIS 测量电池阻抗, 频率扫描的范围从 0.1Hz 到 5kHz。

[0123] 由于室温条件更接近于大部分锂离子电池的实际工况条件, 用它对本文提出的预测框架进行验证具有更好的代表性, 它们的容量退化过程如图 2 中的曲线所示。

[0124] 图 2 中横轴为锂离子电池的充放电循环周期, 单位为周期(cycle), 纵轴为电池容量值和采用电池电压数据进行采样熵特征提取后得到的电池容量模型, 单位是安时(Ah)。从图中可知, 电池的容量变化曲线大体上是一个指数函数退化曲线, 但是局部能量再生现象明显, 表现为曲线的周期性尖峰。当电池达到寿命结束(End Of Life, EOL)的标准, 即电池的充电容量到额定容量的 70% 左右, 据此容量阈值 U 设为 1.38Ah, 实验停止。电池 #5、电池 #6、电池 #7 电池样本数据为 168 个, 电池 #18 电池样本数据为 132 个, 电池 #5 电池的寿命 $T_1=123\text{cycle}$, 电池 #6 电池的寿命 $T_3=112\text{cycle}$, 电池 #7 电池的寿命 $T_2=166\text{cycle}$, 电池 #18 电池的寿命 $T_2=100\text{cycle}$, 其中电池 #5 和电池 #6、电池 #18 电池容量的数据时间变化范围均大于设定的失效阈值, 而电池 #7 并没有达到失效阈值。因此选用电池 #5 和电池 #6、电池 #18 电池作为标准来阐述实验过程和分析实验结果, 验证预测算法框架的有效性。

[0125] 试验采用电池放电容量前 60 个循环的数据作为训练样本数据。采用高斯过程回归方法进行训练, 得到的 SOH 预测模型表现形式为输入数据、协方差函数以及与之对应的超参数。采用高斯过程回归进行短期时间序列预测, 作为实际的预测结果输出。将回归预测的数据更新到训练数据序列中, 并与原训练数据进行 Pearson 相关性分析, 判断是否需要加入新更新的数据更新模型或是采用滚动时间窗方法进行模型更新, 并与原始的单步迭代的高斯过程回归精度进行对比分析。各模型预测效果如图 4、5、6 所示, 其中横轴为锂离子电池的充放电循环周期, 单位为实际周期 t, 纵轴为采用电池电压数据进行采样熵特征提取后得到的电池健康状态指数 SOH, 1 代表健康, 0 代表电池已经到了失效阈值。表 1 列出了各种模型预测的结果、相对误差值。

[0126] 表一两种预测模型的预测结果

[0127]

电池编号	预测模型	实际 RUL	预测 RUL	相对误差
#5	单步迭代	128	115	10.1%
	主动更新迭代		120	6.2%
#6	单步迭代	116	99	14.6%
	主动更新迭代		106	8.6%
#18	单步迭代	100	90	10.0%
	主动更新迭代		97	3.0%

[0128] 对实验进行分析可以得出如下结论:

[0129] 1、从图 4、5、6 可以看出, 主动更新采样高斯过程回归和单步迭代高斯过程回归对于小样本电池数据预测趋势与实际趋势一致, 两者的预测相对误差基本一致, 主动更新迭代方法略优。同时这两种方法的预测结果都小于真实寿命, 减少了由于未能提前预警而带来的预测无效的风险, 因此具有较好的实用性。

[0130] 2、采用高斯过程回归预测，其预测趋势更接近真实值，同时还可以输出预测结果的置信度区间，证明了此预测模型的优势。

[0131] 3、主动更新采样高斯过程回归预测较单步迭代预测的曲线更接近于真实值，且曲线的不平稳尖峰也表明此方法能较好的建模电池的能量再生过程，达到更精确地预测效果，从而证明本文选用主动更新采样高斯过程回归的合理性。

[0132] 本发明提供的锂离子电池剩余寿命预测方法，采用高斯过程回归模型，对处理高维数、小样本、非线性等复杂的问题具有很好的适应性；提出基于模型主动更新策略的高斯过程回归模型，通过将短期时间序列预测结果以不同策略更新到训练数据序列中，通过扩充训练集的方式进行重新训练，与原有的迭代更新训练方式有所不同，动态地更新预测模型，从而提高预测精度；由于在线应用时通常无法得到电池容量数据，通过电压测量数据进行采样熵特征提取后进行回归得到电池健康状态 SOH 模型，再根据已有的 SOH 模型进行进一步的剩余寿命预测；进行相似度分析并以此为依据，若与原始模型进行相关系数比较时发现变化较大，则原有模型无法对新加入的数据进行正确建模，此时模型训练数据集个数有所变化，因此是通过扩充训练集的方式进行重新训练，与原有的迭代更新训练方式有所不同，动态地更新预测模型，从而提高预测精度。

[0133] 以上详细描述了本发明的较佳具体实施例。应当理解，本领域的普通技术无需创造性劳动就可以根据本发明的构思做出诸多修改和变化。因此，凡本技术领域中技术人员依本发明的构思在现有技术的基础上通过逻辑分析、推理或者有限的实验可以得到的技术方案，皆应在由权利要求书所确定的保护范围内。

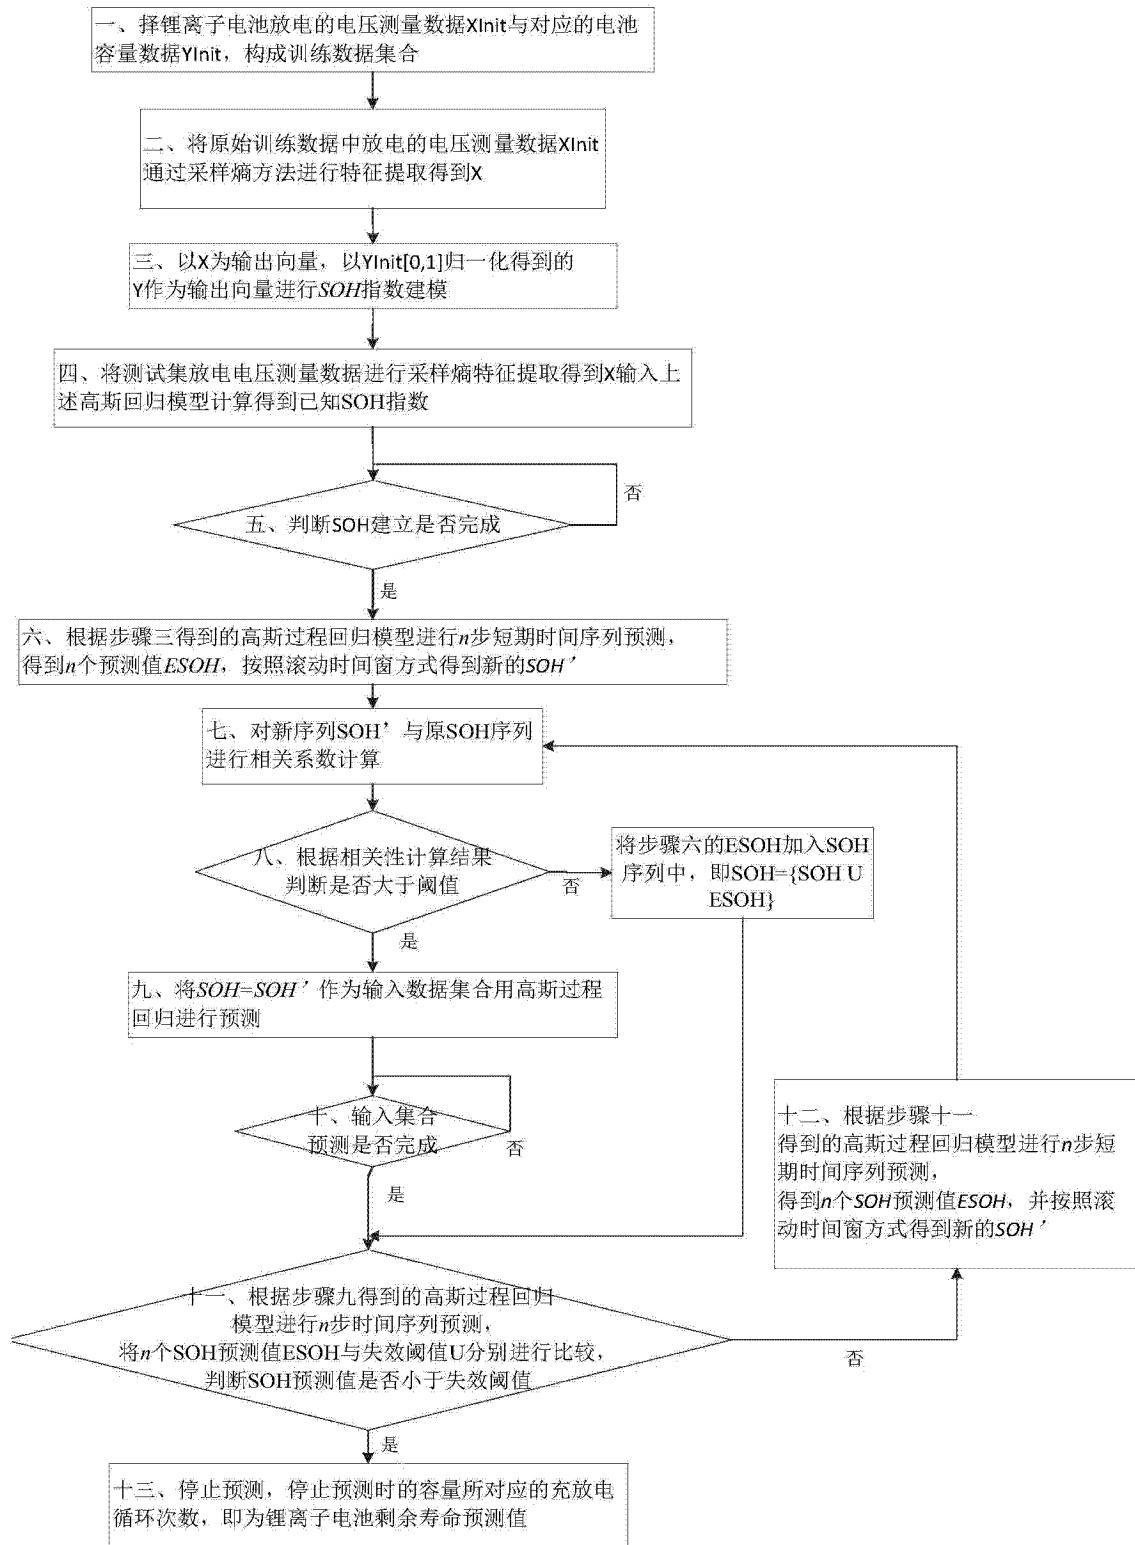


图 1

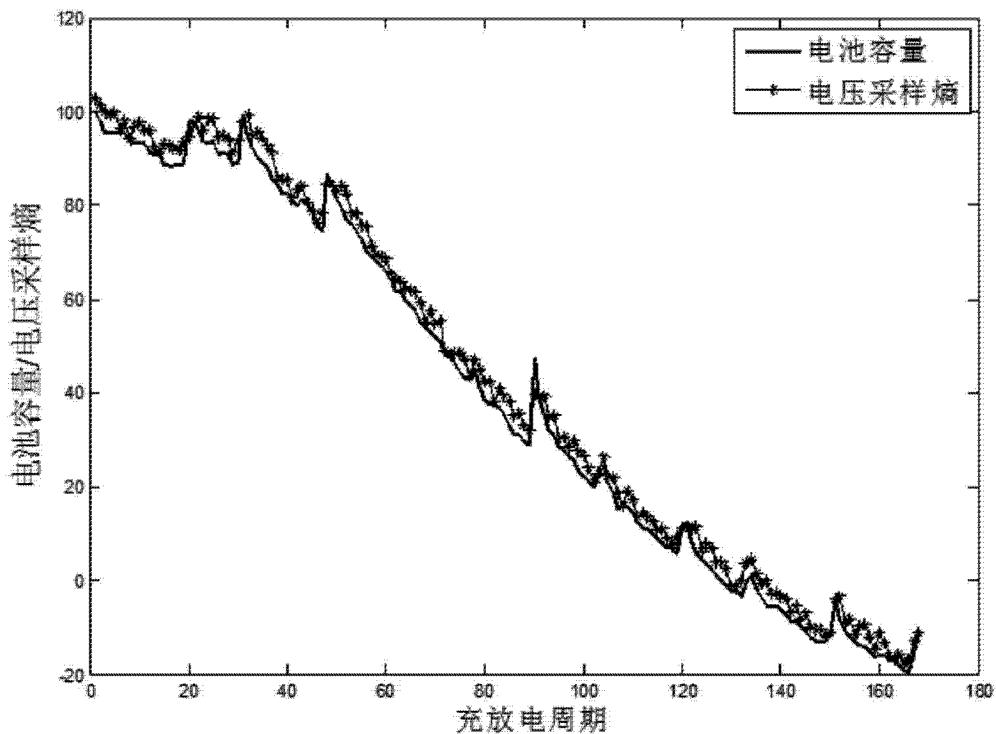


图 2

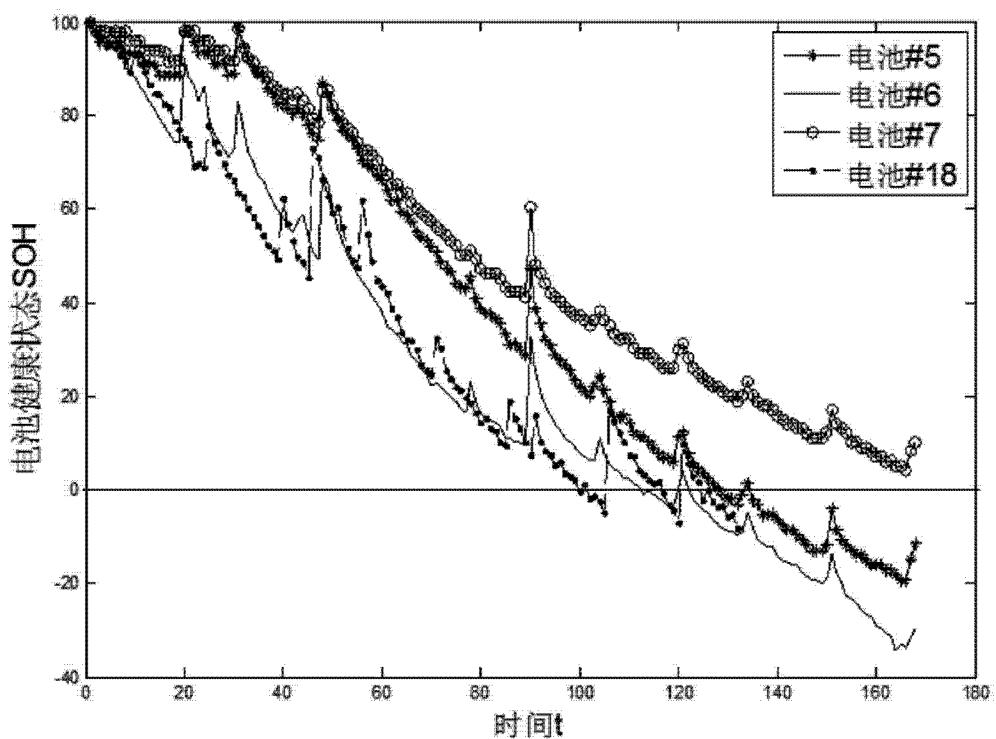


图 3

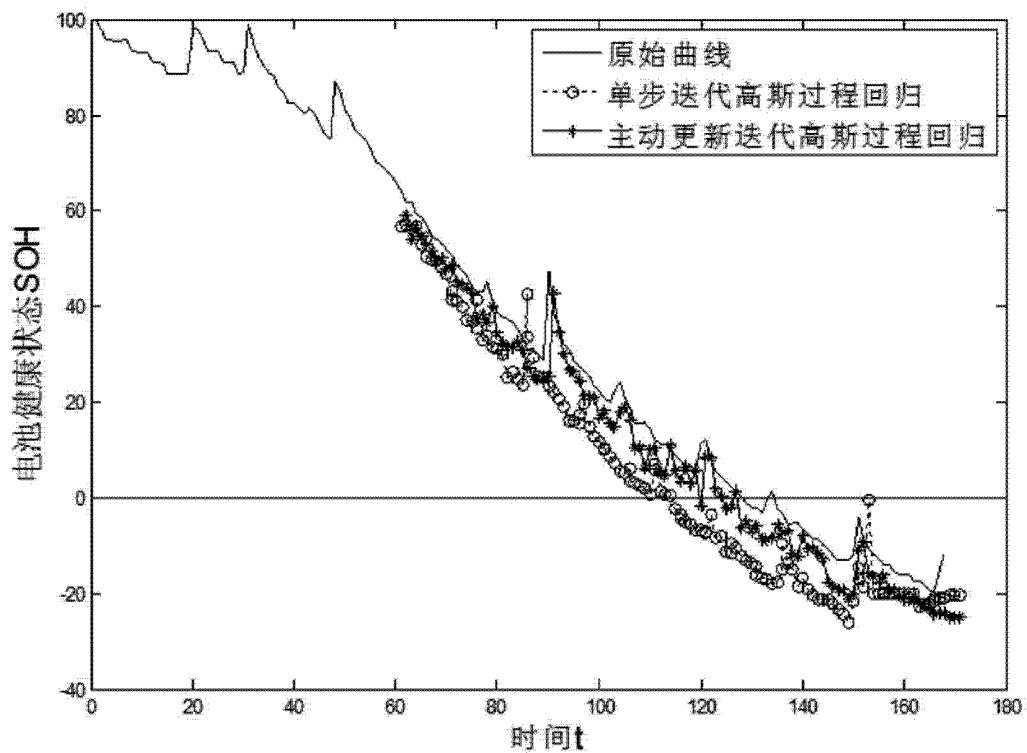


图 4

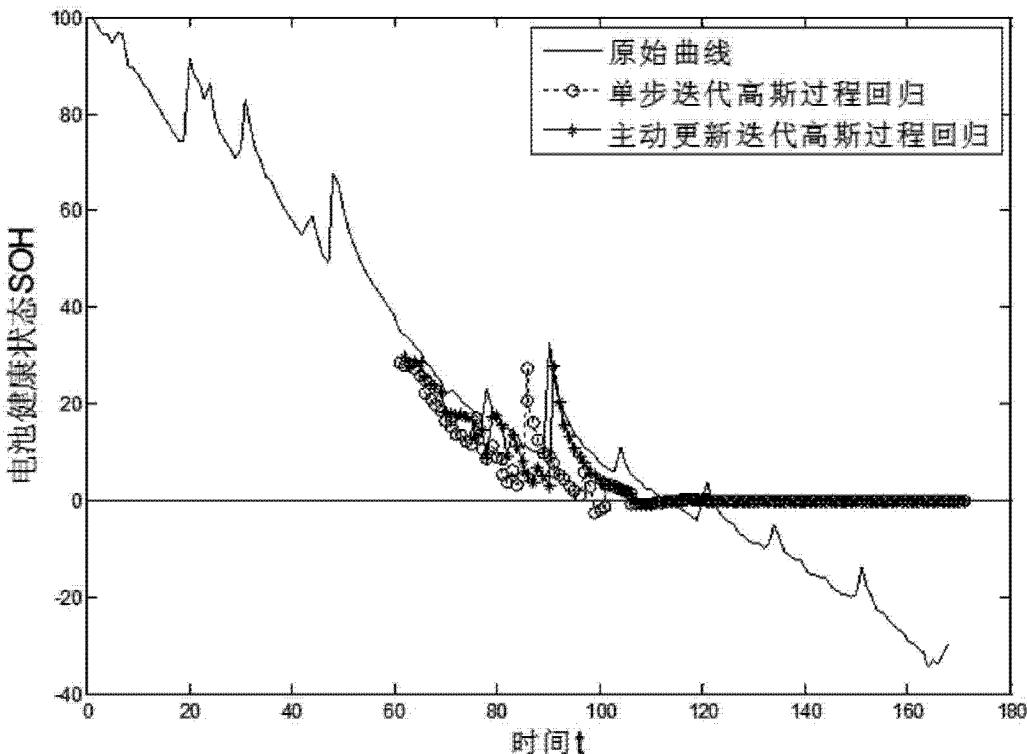


图 5

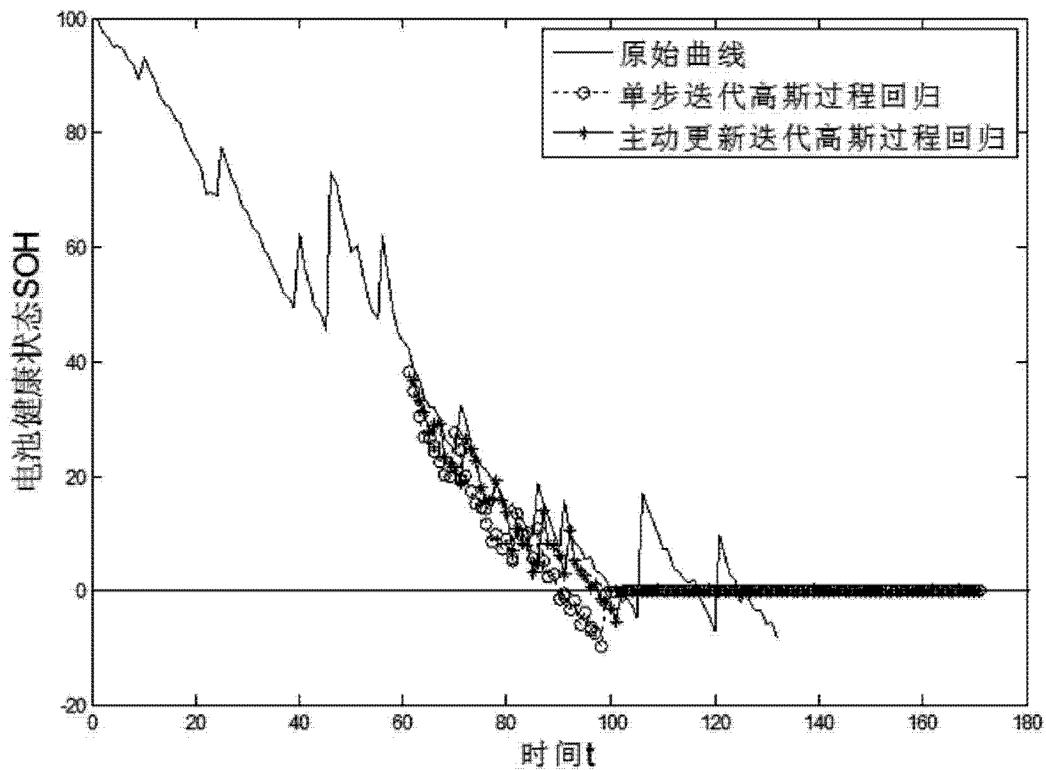


图 6