



(12)发明专利申请

(10)申请公布号 CN 109752656 A
(43)申请公布日 2019.05.14

(21)申请号 201910171802.1

(22)申请日 2019.03.07

(71)申请人 深圳市计量质量检测研究院
地址 518000 广东省深圳市南山区西丽街
道同发路4号
申请人 普天新能源有限责任公司

(72)发明人 杨桂芬 邓迟 周頔 宋元培

(74)专利代理机构 哈尔滨市伟晨专利代理事务
所(普通合伙) 23209
代理人 李思奇

(51) Int. Cl.
G01R 31/36(2019.01)
G01R 31/392(2019.01)

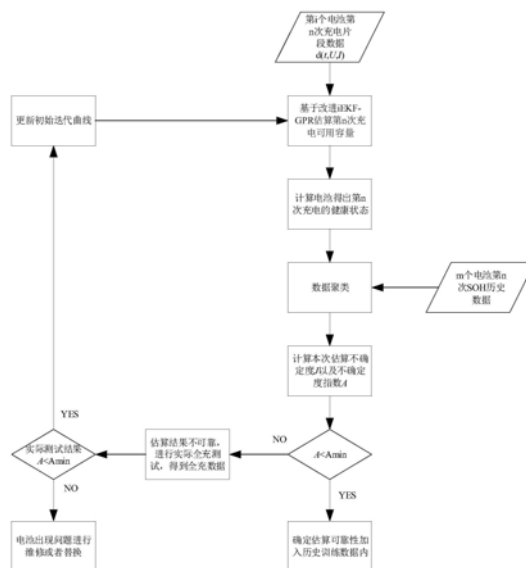
权利要求书3页 说明书11页 附图5页

(54)发明名称

一种在多时间尺度下用电动汽车电池SOH评估方法

(57)摘要

一种在多时间尺度下用电动汽车电池SOH评估方法属于电动汽车电池检测领域;迭代采用片段数据评估电池容量的误差,导致检测结果误差大;包括获取第i个电池第n次充电片段数据d(t, U, I);通过基于改进iEKF-GPR估算第n次充电可用容量;计算电池得出第n次充电的健康状态;获取m个电池第n次SOH历史数据,进行数据聚类;计算本次估算不确定度J以及不确定度指数A;判断是否是A<Amin,若是,确定复算可靠性价加入历史训练数据内;若否,估算结果不可靠,进行实际全充测试,得到全充数据;判断实际测试结果是A<Amin,若是,更新初始迭代曲线,执行步骤b;若否,电池出现为题进行维修或替换;本发明确保电池SOH评估的准确性和实时性。



CN 109752656 A

1. 一种在多时间尺度下用电动汽车电池SOH评估方法,其特征在于,包括以下步骤:

步骤a、获取第*i*个电池第*n*次充电片段数据*d*(*t*,*U*,*I*);

步骤b、通过基于改进iEKF-GPR预算第*n*次充电可用容量;

步骤c、计算电池得出第*n*次充电的健康状态;

步骤d、获取*m*个电池第*n*次SOH历史数据,进行数据聚类;

步骤e、计算本次预算不确定度*J*以及不确定度指数*A*;

步骤f、判断是否是*A*<*A*_{min},若是,确定预算可靠性价加入历史训练数据内;若否,预算结果不可靠,进行实际全充测试,得到全充数据;

步骤g、判断实际测试结果是否是*A*<*A*_{min},若是,更新初始迭代曲线,执行步骤b;若否,电池出现问题进行维修或者替换。

2. 根据权利要求1所述一种在多时间尺度下用电动汽车电池SOH评估方法,其特征在于,所述获取第*i*个电池第*n*次充电片段数据*d*(*t*,*U*,*I*)的方法包括:

确定电池初次循环loop₀的参数,恒流充电电流*I*,恒压充电截止电压*U*,初始恒流充电下的全充数据*d*₀=(*t*₀(*k*),*U*₀(*k*)),*k*=1,2,⋯,*k*₀,*k*₀为在恒流*I*充电下电池达到截止电压*V*时的总采样时间点数,*t*₀(*k*)是等间隔采样的离散相对时间,采样时间间隔*T*_s=*t*₀(*k*+1)-*t*₀(*k*)为常数,*U*₀(*k*)表示第*k*个采样点的电压;基于下列公式,其量测函数为*h*₀:

$$f_i(U) = a_1 * e^{\frac{-(U-U_2-\Delta U_1)^2}{c_1}} + a_2 * e^{\frac{-(U-U_2)^2}{c_2}} + a_3 * e^{\frac{-(U-U_3)^2}{c_3}} + a_4$$

第*n*次日常充电片段数据*d*_n=(*t*_n(*k*),*U*_n(*k*),*I*_n(*k*)),由于片段数据时间的绝对时间从0开始,

$$t_k = 0, T_s, 2T_s, 3T_s \cdots (k-1) T_s。$$

3. 根据权利要求1所述一种在多时间尺度下用电动汽车电池SOH评估方法,其特征在于,所述通过基于改进iEKF-GPR预算第*n*次充电可用容量的方法包括:

对*n*次的片段数据进行改进iEKF-GPR模型预算:

$$\text{状态方程: } U_k^n = GP^f(U_1^n, U_2^n, \dots, U_{k-1}^n) + W_k^n$$

$$\text{量测方程: } t_k^n = h(U_k^n) + GP^v(n)$$

其中*U*_kⁿ为充电时刻;*t*_kⁿ为充电时刻充电电压值;GP^v(*n*)区别于传统假设的量测噪声为高斯白噪声,而是由高斯过程回归得出来均值*V*,方差为*R*_n,而*W*(*k*)则根据充电曲线预测得出均值为0,方差为*Q*的高斯白噪声;

$$\text{状态预测: } U(k|k-1) = GP^f(U(k-1|k-1))$$

$$\text{测量预测: } t(k|k-1) = h(U(k|k-1)) + V$$

$$\text{状态转移矩阵,利用差商近似导数: } \phi(k) = U(k|k-1) - U(k-1|k-1)$$

量测矩阵,利用差商近似导数:

$$\hat{H}(n|n-1) = (h(U(k|k-1)) - h(U(k-1|k-1))) / (U(k|k-1) - U(k-1|k-1))$$

$$\text{协方差预测矩阵: } \hat{P}(k|k-1) = \phi(k) \hat{P}(k-1|k-1) \phi^T(k) + Q$$

$$\text{计算增益: } K(k) = \hat{P}(k|k-1) \hat{H}^T(k) (\hat{H}(k) \hat{P}(k|k-1) \hat{H}^T(k) + R)$$

更新状态: $\hat{x}(k|k) = \hat{x}(k|k-1) + K(k)[t(k) - V - GP^f(U(k|k-1))]$

更新协方差: $\hat{P}(k|k) = [I - K(k)\hat{H}(k)]\hat{P}(k|k-1)$

得到起始电压U所对应绝对时刻,第n次充电的全充所需时间 T_n ,第n次恒流充电可用容量如下:

$$C_c(n) = (T_n - (t-1)T_s) \times I + \sum_0^k I_n(k)$$

其中I为电池恒流充电的电流值。

4. 根据权利要求1所述一种在多时间尺度下用电动汽车电池SOH评估方法,其特征在于,所述计算电池得出第n次充电的健康状态的方法包括:

根据充电容量和放电容量具有的线性相关性,得出线性回归研究充、放电容量二者之间的关系;

$$C_d(n) = \beta_1 C_c(n) + \beta_0$$

其中系数 β_1 和 β_0 由根据下列公式计算得出;

$$\hat{\beta}_1 = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

$$\hat{\beta}_0 = \frac{\sum_{i=1}^n y_i}{n} - \hat{\beta}_1 \cdot \frac{\sum_{i=1}^n x_i}{n} = \bar{y} - \hat{\beta}_1 \bar{x}$$

基于充电数据和放电数据对电池健康状态评估误差和相对趋势影响大的因素是初始容量的确定,第n次充电时电池健康状态SOH为:

$$SOH_n = \frac{C_d(n)}{C_N}$$

其中 $C_d(n)$ 为计算得出的可用放电容量, C_N 为标称放电容量。

5. 根据权利要求1所述一种在多时间尺度下用电动汽车电池SOH评估方法,其特征在于,所述数据聚类的方法包括如下:

步骤d1、确定 SOH_n^m 数据,其中不同电池第n次充电时电池健康状态 SOH_n^m ,m表示各电池的编号,m个按照影响特点划分5个簇C1~C5;

步骤d2:随机分布5个记录成为初始簇中心位置;

步骤d3:为每一个数据找到最近的簇中心,每一个簇中心“拥有”一个数据的子集,从而确定一个数据集的划分;

步骤d4:对于5个簇中的每一个簇,找到簇质心,并将簇质心以新的簇中心位置更新;

步骤d5:重复步骤d3~d5,直至收敛或终止。

6. 根据权利要求1所述一种在多时间尺度下用电动汽车电池SOH评估方法,其特征在于,所述计算本次预算不确定度J的方法包括:

从数据已进行聚类,得到电池第n次充电时电池健康状态的统计值也就是簇中心

$SOH_n^{C_1} \sim SOH_n^{C_s}$, 编号为*i*的电池第*n*次充电预算健康状态值为 SOH_n^i , 将该预算数据聚类到距离最近的一个簇中, 对该簇进行下一步的统计量, 根据下列公式得出簇内合并标准偏差用 $s_n^{C_k}$ 表示;

$$s_p = \sqrt{\frac{\sum_{i=1}^M V_i (y_n^i)^2}{\sum_{i=1}^M V_i}}$$

其预算不确定度为:

$$J_n^i = |SOH_n^i - SOH_n^{C_k}|^2 + |s_n^{C_k}|^2 + |s_p|^2$$

其中, SOH_n^i 为当次预算值; $SOH_n^{C_k}$ 为距离预算值最近的簇中心; $s_n^{C_k}$ 为*k*簇统计得到的标准偏差; s_p 为认为预算分析不确定度因素。

7. 根据权利要求6所述一种在多时间尺度下用电动汽车电池SOH评估方法, 其特征在于, 所述不确定度指数*A*的方法包括: 根据下列公式进一步得到不确定度指数*A*, 优化已经不符合高斯分布的 J_n^i 服从概率密度函数为 $\varphi(J_n^i)$ 的分布, 为直观评价 J_n^i 进行映射计算从而获得较为易于直接比较的数值;

$$A = \int_{\min|y_n^i - y_n^{i'}|}^{\max|y_n^i - y_n^{i'}|} J_n^i (|N(\mu_{n+1}^i, (\sigma_{n+1}^i)^2) - N(y_p^i, (s_p^i)^2)|^2 + |\sigma_n^i|^2 + |s_p|^2) dJ_n^i。$$

一种在多时间尺度下用电动汽车电池SOH评估方法

技术领域

[0001] 本发明属于电动汽车电池检测领域,尤其涉及一种在多时间尺度下用电动汽车电池 SOH评估方法。

背景技术

[0002] 实时评估电动汽车动力锂电池的健康状态(SOH)对电动汽车的维护至关重要。宏观时间尺度的电池SOH评估指的是在电池的全寿命周期使用过程中,随着时间的增加,多个电池逐渐老化、性能逐渐衰退的情况下,对电池的性能进行评估,宏观时间尺度下的数据参数包括SOH(电池容量)-电池充放电次数-电池个数。微观时间尺度的电池状态估计指的是在电池的在全生命周期内单次充放电使用过程中,通过电池曲线特性,对电池荷电状态 SOC及充电容量等参数进行评估,微观时间尺度下的数据参数包括电池充电工作电压-电池充电时间-电池充电次数。

[0003] 目前采用状态与参数联合估计技术的电池容量估计的准确性较差。原因是电池端电压是唯一可测量数据,但是与电池容量正相关的电池单次SOC值由于电池容量的衰减而导致不准确,进而迭代采用片段数据评估电池容量的误差,导致检测结果误差大。

发明内容

[0004] 本发明克服了上述现有技术的不足,提供一种在多时间尺度下用电动汽车电池 SOH 评估方法,将多时间尺度下的数据在宏观时间尺度与微观时间尺度相结合,确保微观模型随着充电次数的增加逐步迭代,同时结合电池实验室数据以及实际测试数据评估,确保电池SOH评估的准确性以及实时性。

[0005] 本发明的技术方案:

[0006] 一种在多时间尺度下用电动汽车电池SOH评估方法,包括以下步骤:

[0007] 步骤a、获取第i个电池第n次充电片段数据 $d(t, U, I)$;

[0008] 步骤b、通过基于改进iEKF-GPR预算第n次充电可用容量;

[0009] 步骤c、计算电池得出第n次充电的健康状态;

[0010] 步骤d、获取m个电池第n次SOH历史数据,进行数据聚类;

[0011] 步骤e、计算本次预算不确定度J以及不确定度指数A;

[0012] 步骤f、判断是否是 $A < A_{min}$,若是,确定预算可靠性价加入历史训练数据内;若否,预算结果不可靠,进行实际全充测试,得到全充数据;

[0013] 步骤g、判断实际测试结果是否是 $A < A_{min}$,若是,更新初始迭代曲线,执行步骤b;若否,电池出现问题进行维修或者替换。

[0014] 进一步地,所述获取第i个电池第n次充电片段数据 $d(t, U, I)$ 的方法包括:

[0015] 确定电池初次循环 $loop_0$ 的参数,恒流充电电流I,恒压充电截止电压U,初始恒流充电下的全充数据 $d_0 = (t_0(k), U_0(k))$, $k = 1, 2, \dots, k_0$, k_0 为在恒流I充电下电池达到截止电压V时的总采样时间点数, $t_0(k)$ 是等间隔采样的离散相对时间,采样时间间隔 $T_s = t_0(k +$

1) $-t_0(k)$ 为常数, $U_0(k)$ 表示第 k 个采样点的电压; 基于下列公式, 其量测函数 为 h_0 :

$$[0016] \quad f_i(U) = a_1 * e^{\frac{-(U-U_2-\Delta U_1)^2}{c_1}} + a_2 * e^{\frac{-(U-U_2)^2}{c_2}} + a_3 * e^{\frac{-(U-U_3)^2}{c_3}} + a_4$$

[0017] 第 n 次日常充电片段数据 $d_n = (t_n(k), U_n(k), I_n(k))$, 由于片段数据时间的绝对时间从 0 开始,

$$[0018] \quad t_k = 0, T_s, 2T_s, 3T_s \dots (k-1) T_s。$$

[0019] 进一步地, 所述通过基于改进 iEKF-GPR 预算第 n 次充电可用容量的方法包括:

[0020] 对 n 次的片段数据进行改进 iEKF-GPR 模型预算:

$$[0021] \quad \text{状态方程: } U_k^n = GP^f(U_1^n, U_2^n, \dots, U_{k-1}^n) + W_k^n$$

$$[0022] \quad \text{量测方程: } t_k^n = h(U_k^n) + GP^V(n)$$

[0023] 其中 U_k^n 为充电时刻; t_k^n 为充电时刻充电电压值; $GP^V(n)$ 区别于传统假设的量测噪声 为高斯白噪声, 而是由高斯过程回归得出来均值 V , 方差为 R_n , 而 $W(k)$ 则根据充电曲线预测得出均值为 0, 方差为 Q 的高斯白噪声;

$$[0024] \quad \text{状态预测: } U(k|k-1) = GP^f(U(k-1|k-1))$$

$$[0025] \quad \text{测量预测: } t(k|k-1) = h(U(k|k-1)) + V$$

$$[0026] \quad \text{状态转移矩阵, 利用差商近似导数: } \phi(k) = U(k|k-1) - U(k-1|k-1))$$

[0027] 量测矩阵, 利用差商近似导数:

$$[0028] \quad \hat{H}(n|n-1) = (h(U(k|k-1)) - h(U(k-1|k-1))) / (U(k|k-1) - U(k-1|k-1))$$

$$[0029] \quad \text{协方差预测矩阵: } \hat{P}(k|k-1) = \phi(k) \hat{P}(k-1|k-1) \phi^T(k) + Q$$

$$[0030] \quad \text{计算增益: } K(k) = \hat{P}(k|k-1) \hat{H}^T(k) (\hat{H}(k) \hat{P}(k|k-1) \hat{H}^T(k) + R)$$

$$[0031] \quad \text{更新状态: } \hat{x}(k|k) = \hat{x}(k|k-1) + K(k) [t(k) - V - GP^f(U(k|k-1))]$$

$$[0032] \quad \text{更新协方差: } \hat{P}(k|k) = [I - K(k) \hat{H}(k)] \hat{P}(k|k-1)$$

[0033] 得到起始电压 U 所对应绝对时刻, 第 n 次充电的全充所需时间 T_n , 第 n 次恒流充电可用容量如下:

$$[0034] \quad C_c(n) = (T_n - (t-1)T_s) \times I + \sum_0^k I_n(k)$$

[0035] 其中 I 为电池恒流充电的电流值。

[0036] 进一步地, 所述计算电池得出第 n 次充电的健康状态的方法包括:

[0037] 根据充电容量和放电容量具有的线性相关性, 得出线性回归研究充、放电容量二者之间的关系;

$$[0038] \quad C_d(n) = \beta_1 C_c(n) + \beta_0$$

[0039] 其中系数 β_1 和 β_0 由根据下列公式计算得出;

$$[0040] \quad \hat{\beta}_1 = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

$$[0041] \quad \hat{\beta}_0 = \frac{\sum_{i=1}^n y_i}{n} - \hat{\beta}_1 \cdot \frac{\sum_{i=1}^n x_i}{n} = \bar{y} - \hat{\beta}_1 \bar{x}$$

[0042] 基于充电数据和放电数据对电池健康状态评估误差和相对趋势影响大的因素是初始容量的确定,第n次充电时电池健康状态SOH为:

$$[0043] \quad SOH_n = \frac{C_d(n)}{C_N}$$

[0044] 其中 $C_d(n)$ 为计算得出的可用放电容量, C_N 为标称放电容量。

[0045] 进一步地,所述数据聚类的方法包括如下:

[0046] 步骤d1、确定 SOH_n^m 数据,其中不同电池第n次充电时电池健康状态 SOH_n^m ,m表示各电池的编号,m个按照影响特点划分5个簇C1~C5;

[0047] 步骤d2:随机分布5个记录成为初始簇中心位置;

[0048] 步骤d3:为每一个数据找到最近的簇中心,每一个簇中心“拥有”一个数据的子集,从而确定一个数据集的划分;

[0049] 步骤d4:对于5个簇中的每一个簇,找到簇质心,并将簇质心以新的簇中心位置更新;

[0050] 步骤d5:重复步骤d3~d5,直至收敛或终止。

[0051] 进一步地,所述计算本次预算不确定度J的方法包括:

[0052] 从数据已进行聚类,得到电池第n次充电时电池健康状态的统计值也就是簇中心 $SOH_n^{C_1} \sim SOH_n^{C_5}$,编号为i的电池第n次充电预算健康状态值为 SOH_n^i ,将该预算数据聚类到距离最近的一个簇中,对该簇进行下一步的统计量,根据下列公式得出簇内合并标准偏差用 $s_n^{C_k}$ 表示:

$$[0053] \quad s_p = \sqrt{\frac{\sum_{i=1}^M V_i (y_n^i)^2}{\sum_{i=1}^M V_i}}$$

[0054] 其预算不确定度为:

$$[0055] \quad J_n^i = |SOH_n^i - SOH_n^{C_k}|^2 + |s_n^{C_k}|^2 + |s_p|^2$$

[0056] 其中, SOH_n^i 为当次预算值; $SOH_n^{C_k}$ 为距离预算值最近的簇中心; $s_n^{C_k}$ 为k簇统计得到的标准偏差; s_p 为认为预算分析不确定度因素。

[0057] 进一步地,所述不确定度指数A的方法包括:根据下列公式进一步得到不确定度指数A,优化已经不符合高斯分布的 J_n^i 服从概率密度函数为 $\varphi(J_n^i)$ 的分布,为直观评价 J_n^i 进行映射计算从而获得较为易于直接比较的数值;

$$[0058] \quad A = \int_{\min|y_n^i - y_n^{i'}|}^{\max|y_n^i - y_n^{i'}|} J_n (|N(\mu_{n+1}^i, (\sigma_{n+1}^i)^2) - N(y_p^i, (s_p^i)^2)|^2 + |\sigma_n^i|^2 + |s_p^i|^2) dJ_n。$$

[0059] 本发明相对于现有技术具有以下有益效果：

[0060] 本发明提供了一种在多时间尺度下用电动汽车电池SOH评估方法，将多时间尺度下的数据在宏观时间尺度与微观时间尺度相结合包括了电池充电工作电压-电池充电时间-电池充电次数-电池个数，4维角度将利用宏观数据模型作为微观数据模型迭代收敛条件，确保微观模型随着充电次数的增加逐步迭代，同时结合电池实验室数据以及实际测试数据评估，确保电池SOH评估的准确性以及实时性。

[0061] 本发明利用相同类型电池组历史充电数据建立根据实际的电池性能进行实时变化的迭代化模型，实时完善估算模型，使模型接近当前电池组工作状态，提高估算精度。

附图说明

[0062] 图1是本发明流程图；

[0063] 图2是本发明电池充电时间变化情况曲线图；

[0064] 图3是本发明电动大巴电池测试现场图；

[0065] 图4是本发明电动汽车容量及SOH在线评估软件界面图；

[0066] 图5是本发明电池估算曲线与初始全充曲线对比图；

[0067] 图6是本发明电池健康状态评估结果图。

具体实施方式

[0068] 以下将结合附图对本发明进行详细说明。

[0069] 具体实施方式一

[0070] 一种在多时间尺度下用电动汽车电池SOH评估方法，如图1所示，包括以下步骤：

[0071] 步骤a、获取第i个电池第n次充电片段数据d(t, U, I)；

[0072] 步骤b、通过基于改进iEKF-GPR估算第n次充电可用容量；

[0073] 步骤c、计算电池得出第n次充电的健康状态；

[0074] 步骤d、获取m个电池第n次SOH历史数据，进行数据聚类；

[0075] 步骤e、计算本次估算不确定度J以及不确定度指数A；

[0076] 步骤f、判断是否是 $A < A_{min}$ ，若是，确定复算可靠性价加入历史训练数据内；若否，估算结果不可靠，进行实际全充测试，得到全充数据；

[0077] 步骤g、判断实际测试结果是否是 $A < A_{min}$ ，若是，更新初始迭代曲线，执行步骤b；若否，电池出现为题进行维修或替换。

[0078] 具体地， A_{min} 为不确定度的最小阈值；

[0079] 具体地，所述获取第i个电池第n次充电片段数据d(t, U, I)的方法包括：

[0080] 确定电池初次循环 $loop_0$ 的相关参数，当前时间t，恒流充电电流I，恒压充电截止电压U，初始恒流充电下的全充数据 $d_0 = (t_0(k), U_0(k))$ ， $k=1, 2, \dots, k_0$ ， k_0 为在恒流I充电下电池达到截止电压V时的总采样时间点数， $t_0(k)$ 是等间隔采样的离散相对时间，采样时间间隔 $T_s = t_0(k+1) - t_0(k)$ 为常数， $U_0(k)$ 表示第k个采样点的电压；基于下列公式，其量测函数为 h_0 ；

$$[0081] \quad f_i(U) = a_1 * e^{\frac{-(U-U_2-\Delta U_1)^2}{c_1}} + a_2 * e^{\frac{-(U-U_2)^2}{c_2}} + a_3 * e^{\frac{-(U-U_3)^2}{c_3}} + a_4$$

[0082] 其中U1、U2、U3分别表征充电曲线的三个拐点电压值,a1、a2、a3、c1、c2、c3分别表征分段函数的模型系数,a4表征电池老化过程中初始电压的逐步提高值

[0083] 第n次日常充电片段数据 $d_n = (t_n(k), U_n(k), I_n(k))$,由于片段数据时间的绝对时间从0开始,

$$[0084] \quad t_k = 0, T_s, 2T_s, 3T_s \cdots (k-1) T_s$$

[0085] 具体地,所述基于改进iEKF-GPR包括如下:

[0086] 利用GPR方法辨识系统模型,包括状态转移模型和量测模型以及相应的噪声协方差阵,以替代或增强原有系统模型,能够解决系统模型未知或系统模型不够准确情况下的状态估计问题。建立参数化模型需要大量专业知识,部分系统只能建立简化模型,这些参数化模型难以全而表征实际系统。GPR模型可以克服参数化模型使用时的不足,通过多维数据的训练,提高模型精度,因为GPR模型可以表征参数化模型无法捕获的系统信息;二是增强了泛化性能。从本质上来看,GPR模型表征的是分离参数模型贡献外的系统残余输出部分。因此在提出的微观时间尺度下iEKF-GPR模型的基础上,在利用宏观时间尺度下将EKF中的量测噪声建立GPR模型,从而改进模型的模型实时性。

[0087] 根据下列公式,

$$[0088] \quad t_k = h(U_k) + V(k)$$

[0089] 其中,h(U_k)是U-t量测方程函数,V(k)是量测噪声;

[0090] iEKF-GPR模型量测方程中的量测噪声V(k),可以根据电池充电的物理意义解释为每一次电池充电曲线的偏差,在iEKF-GPR中通过电池相邻充电曲线不会存在突变性这一特点来进行迭代,但这种假设忽略了电池可用充电容量的短时波动,同时也加大了估算离散的风险,因此将量测噪声V(k)引入宏观时间尺度下电池容量波动的噪声影响量。结合下列公式:

$$[0091] \quad f_i(U) = a_1 * e^{\frac{-(U-U_2-\Delta U_1)^2}{c_1}} + a_2 * e^{\frac{-(U-U_2)^2}{c_2}} + a_3 * e^{\frac{-(U-U_3)^2}{c_3}} + a_4$$

[0092] 得出整个量测方程:

$$[0093] \quad t_k = a_1 * e^{\frac{-(U_k-U_2-\Delta U_1)^2}{c_1}} + a_2 * e^{\frac{-(U_k-U_2)^2}{c_2}} + a_3 * e^{\frac{-(U_k-U_3)^2}{c_3}} + a_4 + V_n$$

[0094] 其中,U2、U3分别表征充电曲线的拐点电压值;ΔU1表示第一个平台电压压差;V_n表示n次充电过程中充电时间的变化。如图2所示,表示宏观时间尺度下电池充电时间的变化情况,

[0095] 在基于GPR的SOH预测拟合模型,选用神经网络核函数以及Maternard核函数加和确定GPR协方差函数。通过式下列公式对SOH的定义:

$$[0096] \quad SOH \approx SOH' = \frac{C'_M}{C'_N}$$

[0097] 其中,C'_M为测量放电电容,C'_N为电池标称放电电容;

[0098] 采用电池容量直接评估电池SOH,也就是说电池SOH与电池容量为正相关关系,那

么 也就是和电池充放电时间有正相关关系,因此采用预测SOH的模型对电池充电时间进行预测拟合。

[0099] 那么改进型高斯-卡尔曼滤波模型的状态方程以及量测方程分别是

$$[0100] \quad x_k = GP^f(x_1, x_2, \dots, x_{k-1}) + W(k)$$

$$[0101] \quad z_k = h(x_k) + GP^V(n)$$

[0102] 式中,参数表达式与式下列公式一致,

$$[0103] \quad U_k = GP^f(U_1, U_2, \dots, U_{k-1}) + W(k)$$

$$[0104] \quad t_k = h(U_k) + V(k)$$

[0105] $GP^V(n)$ 表示电池充电时间波动引起的噪声影响量。需要说明的是, GP^f 与 GP^V 都是基于GPR的非线性预测,但物理意义完全不同, GP^f 是在微观时间尺度下对单次充电曲线中下一个电压值进行预测,而 GP^V 是在宏观时间尺度下对整个充电时间的波动情况进行预测的。

[0106] 提到日常充电数据无法做到锂电池电量的全充全放,因此无法直接得到锂电池真实的可用充电容量。在宏观时间尺度下SOH的变化情况下,改进iEKF-GPR模型,进一步考虑电池容量波动对模型的影响。

[0107] 具体地,所述通过基于改进iEKF-GPR估算第n次充电可用容量的方法包括:

[0108] 对n次的片段数据进行改进iEKF-GPR模型估算:

$$[0109] \quad \text{状态方程: } U_k^n = GP^f(U_1^n, U_2^n, \dots, U_{k-1}^n) + W_k^n$$

$$[0110] \quad \text{量测方程: } t_k^n = h(U_k^n) + GP^V(n)$$

[0111] 其中,k表示离散时间, W_k^n 为状态噪声,h为量测函数, U_k^n 为充电时刻; t_k^n 为充电时刻充电电压值; $GP^V(n)$ 区别于传统假设的量测噪声为高斯白噪声,而是由高斯过程回归得出均值V,方差为Rn,而W(k)则根据充电曲线预测得出均值为0,方差为Q的高斯白噪声。

$$[0112] \quad \text{状态预测: } U(k|k-1) = GP^f(U(k-1|k-1))$$

$$[0113] \quad \text{测量预测: } t(k|k-1) = h(U(k|k-1)) + V$$

$$[0114] \quad \text{状态转移矩阵,利用差商近似导数: } \phi(k) = U(k|k-1) - U(k-1|k-1)$$

[0115] 量测矩阵,利用差商近似导数:

$$[0116] \quad \hat{H}(n|n-1) = (h(U(k|k-1)) - h(U(k-1|k-1))) / (U(k|k-1) - U(k-1|k-1))$$

$$[0117] \quad \text{协方差预测矩阵: } \hat{P}(k|k-1) = \phi(k) \hat{P}(k-1|k-1) \phi^T(k) + Q$$

$$[0118] \quad \text{计算增益: } K(k) = \hat{P}(k|k-1) \hat{H}^T(k) (\hat{H}(k) \hat{P}(k|k-1) \hat{H}^T(k) + R)$$

$$[0119] \quad \text{更新状态: } \hat{x}(k|k) = \hat{x}(k|k-1) + K(k)[t(k) - V - GP^f(U(k|k-1))]$$

$$[0120] \quad \text{更新协方差: } \hat{P}(k|k) = [I - K(k) \hat{H}(k)] \hat{P}(k|k-1)$$

[0121] 上述式中H为量测矩阵,P为协方差预测矩阵,K为增益,R为量测噪声方差, H^T 为H转置;

[0122] 得到起始电压U所对应绝对时刻,第n次充电的全充所需时间 T_n ,第n次恒流充电可用容量如下:

$$[0123] \quad C_c(n) = (T_n - (t-1)T_s) \times I + \sum_0^k I_n(k)$$

[0124] 其中I为电池恒流充电的电流值。

[0125] 具体地,所述计算电池得出第n次充电的健康状态的方法包括:

[0126] 根据充电容量和放电容量具有的线性相关性,得出线性回归研究充、放电容量二者之间的关系;

$$[0127] \quad C_d(n) = \beta_1 C_c(n) + \beta_0$$

[0128] 其中, $C_d(n)$ 为放电可用容量,系数 β_1 和 β_0 由根据下列公式计算得出,

$$[0129] \quad \hat{\beta}_1 = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

$$[0130] \quad \hat{\beta}_0 = \frac{\sum_{i=1}^n y_i}{n} - \beta_1 \cdot \frac{\sum_{i=1}^n x_i}{n} = \bar{y} - \hat{\beta}_1 \bar{x}$$

[0131] 其中, x_i 和 y_i 为随机变量,线性回归模型的参数估计量 $\hat{\beta}$ 是随机变量 y_i 的函数;

[0132] 基于充电数据和放电数据对电池健康状态评估误差和相对趋势影响大的因素是初始容量的确定,第n次充电时电池健康状态SOH为:

$$[0133] \quad SOH_n = \frac{C_d(n)}{C_N}$$

[0134] 其中 $C_d(n)$ 为计算得出的可用放电容量, C_N 为标称放电容量。

[0135] 具体地,引入相同类型电池的SOH大数据信息,对当前电池数据进行聚类分析,采用无监督学习k-means聚类算法,该方法是一种发现数据簇的简单有效的算法,通过建立不同的簇进一步提高系统的鲁棒性,所述方法包括如下:

[0136] 步骤d1、确定 SOH_n^m 数据,其中不同电池第n次充电时电池健康状态 SOH_n^m ,m表示各电池的编号,m个按照影响特点划分5个簇C1~C5;

[0137] 步骤d2:随机分布5个记录成为初始簇中心位置;

[0138] 步骤d3:为每一个数据找到最近的簇中心,每一个簇中心“拥有”一个数据的子集,从而确定一个数据集的划分;

[0139] 步骤d4:对于5个簇中的每一个簇,找到簇质心,并将簇质心以新的簇中心位置更新;

[0140] 步骤d5:重复步骤d3~d5,直至收敛或终止。

[0141] 具体地,所述计算本次估算不确定度J的方法包括:

[0142] 从数据已进行聚类,最终得到电池第n次充电时电池健康状态的统计值也就是簇中心 $SOH_n^{C_1} \sim SOH_n^{C_5}$,编号为i的电池第n次充电估算健康状态值为 SOH_n^i ,将该估算数据聚类到距离最近的一个簇中,对该簇进行下一步的统计量,根据下列公式得出簇内合并标准偏差用 $s_n^{C_k}$ 表示;

$$[0143] \quad s_p = \sqrt{\frac{\sum_{i=1}^M V_i (y_n^i)^2}{\sum_{i=1}^M V_i}}$$

[0144] 其中, s_p 表示合并标准偏差, V_i 表示每一类型的自由度, y_n^i 表示M个相似类型的预测结果或是训练数据;

[0145] 其估算不确定度为:

$$[0146] \quad J_n^i = |SOH_n^i - SOH_n^{C_k}|^2 + |s_n^{C_k}|^2 + |s_p|^2$$

[0147] 其中, SOH_n^i 为本次估算值; $SOH_n^{C_k}$ 为距离估算值最近的簇中心; $s_n^{C_k}$ 为k簇统计得到的标准偏差; s_p 表示合并标准偏差。

[0148] 具体地,所述不确定度指数A的方法包括:根据下列公式进一步得到不确定度指数A, 优化已经不符合高斯分布的 J_n^i 服从概率密度函数为 $\varphi(J_n^i)$ 的分布,为直观评价 J_n^i 进行映射计算从而获得较为易于直接比较的数值;

$$[0149] \quad A = \int_{\min|y_n^i - y_p^i|}^{\max|y_n^i - y_p^i|} J_n (|N(\mu_{n+1}^i, (\sigma_{n+1}^i)^2) - N(y_p^i, (s_p^i)^2)|^2 + |\sigma_n^i|^2 + |s_p|^2) dJ_n。$$

[0150] 其中, y_p 表示预测估计值, J_n 表示不确定度, y_{n+1}^i 表示第i个GPR模型预测得到的第i个过程输出, μ_{n+1}^i 和 σ_{n+1}^i 分别表示第i个预测输出的均值和方差, y_p^i 为k簇统计得到的标准偏差; s_p 表示合并标准偏差, s_p^i 表示k簇统计得到的合并标准偏差, σ_n^i 系统估算方差;

[0151] 具体地,通过A目的判断估算结果的可靠性以及模型优化空间,同时也需要判断电池优劣,总之就是通过不确定度指数来判断是否需要进一步的测试以及估算,确定不确定度指数A判断阈值 $A_n^i \leq A_{\min}$ 。

[0152] 由于目前电池全充全放测试依然是最稳定,最可靠的电池SOH评估方法,因此在不不确定度指数A过高时,需要对电池进行全充测试得到相对精确的电池SOH结果,用以更新迭代初始状态以及训练数据,但如果实际测试数据与估算结果趋于一致的话,进一步说明估算的准确性以及电池本身出现了问题,无法再进行使用需要进一步采取维修、替换工作。

[0153] 具体实施方式二

[0154] 在具体实施方式一得基础上,选取某公交公司同一时间采购的20台K9B相同类型的电动大巴,该大巴车均运营市内线路,因此工况基本相同。对电动大巴车动力电池进行电池健康状态评估,K9B电池包是由63个电池模组组合而成,模组是由8个单体电池串联组成,63个模组又分为3个相对独立的电池模块,3个电池模块并连成一个完成的电池包。动力电池包基本特性如下:

[0155] 表5-1动力电池包基本特性

指标项目	规格
模组数量	63
电池组合方式	21 个模组串联为 1 模块，3 个模块 并联
整车电池总能量	290kWh
容量	540Ah
额定电压	537.6V
电池包总重量	3654kg
工作电压范围	336V~638V
单体充电截止电压	3.80V
单体放电截止电压	2.0V
额定充电电流	100A
最大充电电流	200A
最大持续放电电流	100A
充电温度	-20℃~50℃
放电温度	-20℃~55℃

[0156] 检测数据以及日常充电数据对该电池健康状态算法在线评估模型进行验证，，如图3 所示，为电动大巴车进行电池检测的现场照片。测试设备选用Sinexcel生产的充放电一体机，技术指标为电压精度0.5%，电流精度1.0%。

[0158] 开发的电动汽车在线容量及SOH评估软件对该电动大巴车进行数据分析及挖掘，软件显示界面如图4所示。

[0159] 2013年12月3日在出厂后进行第一次全充容量测试，采用多时间尺度下电池SOH评估模型，基于全充数据以及充电历史数据，将2014年3月10日片段充电数据进行在线电池健康状态评估，充电前电池SOC初始显示值为36%。图5为电池2013年12月3日全充曲线，以及2014年3月10日估算出的电池曲线。最终在线估算2014年3月10日该大巴车电池可用充电容量为：

[0160] $C_k = t_k \times I = 564Ah$

[0161] 从而计算当时电池健康状态为：

[0162] $SOH = \frac{C_k}{C_0} = 97.92\%$

[0163] 该电动大巴车在2013年到2017年之间先后进行了3次电池全充测试,实际测得可用容量见表5-2。

[0164] 表5-2实际测得容量数据

[0165]

全充测试日期	测试结果
2013-12-06	562.3Ah
2016-05-09	522.1Ah
2017-10-29	472.8Ah

[0166] 选取电动大巴充电初始SOC低于40%,并充至100%的充电历史数据对电池进行在线评估,其中选取该辆电动汽车电池全充容量测试间隔不超过5天时间的片段充电数据的充电容量估算数据进行比较。见表5-3。

[0167] 表5-3多时间尺度容量估算结果

[0168]

充电时间	初始 SOC	最终 SOC	估算容量 (Ah)	容量波动
2013-12-08	32%	99%	557.9	-0.78%
2016-05-08	22%	99%	537.4	2.93%
2017-11-3	35%	99%	498.5	5.43%

[0169] 由于电池容量的波动性,所以无法复现电池充电容量的准确性,以电池容量衰减度在电池正常工作的情况下不会发生突变,正常工作的电池容量波动一般不会高于2%,从估算数据与实际数据进行比较,容量波动在6%以下,初步估计容量估算的准确性应优于8%。而通过三次数据SOC进行线性化估算结果,见表5-4,可以看出由于SOC准确性不可控性导致整个线性预测结果的离散性。

[0170] 表5-4 SOC线性估算结果

[0171]

充电时间	初始 SOC	最终 SOC	估算容量 (Ah)	容量波动
2013-12-08	32%	99%	543.5	-3.34%
2016-05-08	22%	99%	492.7	-5.63%
2017-11-3	35%	99%	525.4	11.12%

[0172] 在2013年到2017年之间选取了122组片段充电数据对多时间尺度电池SOH评估算法进行验证,图6为电池健康状态评估结果。

[0173] 本发明首先明确了电池充电过程中微观时间尺度和宏观时间尺度的定义,进而提

出多 时间尺度下电池SOH评估方法,在宏观时间尺度与微观时间尺度相结合包括了电池充电电压-电池充电时间-电池充电次数-电池个数,4维角度将利用宏观数据模型作为微观 数据模型迭代收敛条件,确保微观模型随着充电次数的增加逐步迭代,同时结合电池实验室数据以及实际测试数据评估,确保电池SOH评估的准确性以及实时性。

[0174] 由于锂电池单体与锂电池包的区别,通过分析采用充电设施测量数据优于电池管理系统测量结果,说明基于充电设施大数据对在用电动汽车电池SOH进行评估的可行性。

[0175] 提出多时间尺度下在用电动汽车电池SOH在线评估模型,在提出的微观时间尺度下 iEKF-GPR模型的基础上,在利用宏观时间尺度下将EKF中的量测噪声建立GPR模型,从而改进模型的模型实时性;同时引入相同类型电池的SOH大数据信息,对当前电池数据进行聚类分析,通过建立不同的簇进一步提高系统的鲁棒性;结合上述结果得到不确定度指数,用来优化已经目的判断估算结果的可靠性以及模型优化空间,也需要判断电池优劣,通过不确定度指数来判断是否需要进一步的测试以及估算。

[0176] 在对20辆公交大巴车进行充电数据分析以及实际容量测试结果,分析在线SOH评估 误差能够控制在8%以内。

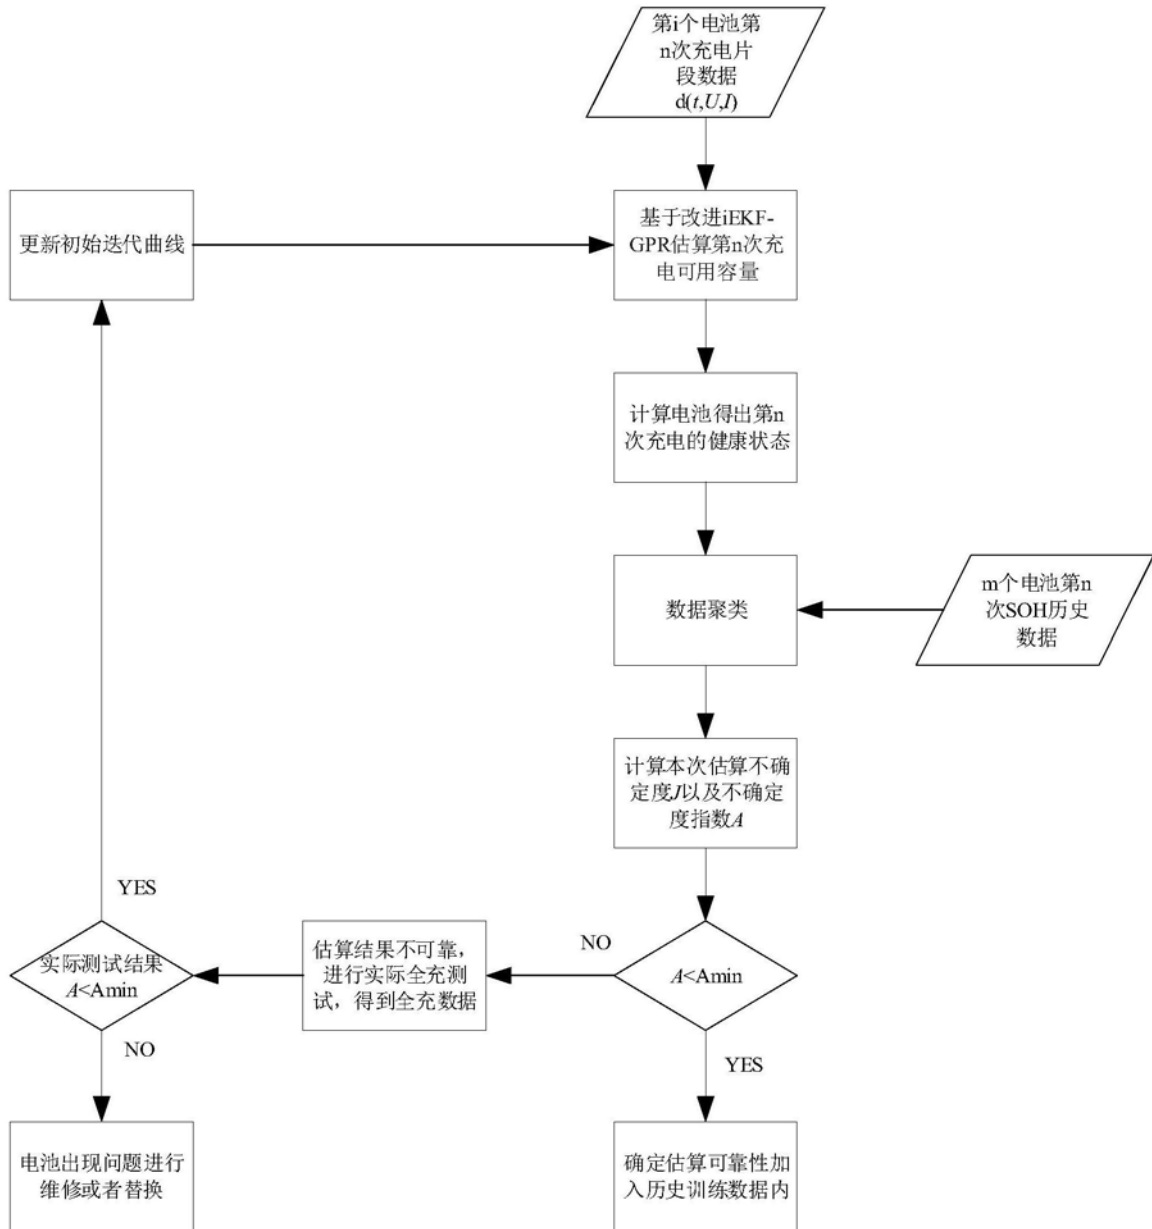


图1




图2



图3




图4




图5




图6