

基于充电电压片段的锂离子电池状态联合估计方法

王萍,张吉昂,程泽,于耀先[†]

(天津大学 电气自动化及信息工程学院,天津 300072)

摘要:锂离子电池的荷电状态(SOC)、健康状态(SOH)和剩余使用使命(RUL)是锂离子电池安全稳定运行的重要状态参数,本文提出一种基于充电电压上升片段的锂离子电池状态联合估计方法,实现对电池预测起点(SP)到寿命终点(EOL)的较长运行周期内 SOC、SOH 和 RUL 的联合估计.该框架在充电阶段进行 SOH 和 RUL 估计,在放电阶段进行 SOC 估计.首先提取电池恒流充电电压曲线片段的上升时间作为健康特征(HF),以 HF 作为输入,循环容量作为输出,建立最小二乘支持向量机(LSSVM)电池老化模型,对当前健康状态进行估计;采用等效电路模型对该电压区段进行非线性拟合,用拟合参数建立状态空间模型,结合无迹卡尔曼滤波算法进行 SOC 估计;用高斯过程回归时间序列模型对电池的健康特征序列进行建模,通过循环次数外推预测健康特征的变化趋势,并结合 LSSVM 老化模型,对 RUL 进行预测并给出置信区间.实验结果表明,所提方法具有较高的估计精度和较好的稳定性.

关键词:荷电状态;健康状态;剩余使用寿命;等效电路模型;数据驱动方法

中图分类号:TM912.1

文献标志码:A

A Coupled State Estimation Method of Lithium Batteries Based on Partial Charging Voltage Segment

WANG Ping, ZHANG Ji'ang, CHENG Ze, YU Yaoxian[†]

(School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: The state of charge (SOC), state of health (SOH) and residual mission (RUL) of lithium-ion battery are important state parameters for the safe and stable operation of lithium-ion battery. In this paper, a coupled estimation method of lithium-ion battery state based on the rising segment of charging voltage is proposed to realize the coupled estimation of SOC, SOH and RUL in a long operation cycle from the starting point of battery prediction (SP) to the end of life (EOL). The framework estimates SOH and RUL in the charging phase and SOC in the discharge phase. Firstly, the rising time of constant current charging voltage curve segment is extracted as the health feature (HF), and the HF as the input and cycle capacity as the output are used to establish the least squares support vector machine (LSSVM) battery aging model for SOH estimation; The equivalent circuit model is used for nonlinear fitting of the voltage segment, and the state space model is established with the fitting parameters, which is combined with the unscented Kalman filter algorithm to estimate SOC; Gaussian process regression time series model is used to model the health feature series, and the change trend of HF is predicted by extrapolation of cycle times, which is combined with LSSVM

* 收稿日期:2021-04-18

基金项目:国家自然科学基金资助项目(61873180), National Natural Science Foundation of China(61873180)

作者简介:王萍(1959—),女,天津人,天津大学教授,博士生导师

[†] 通信联系人, E-mail: yu_yx0901@163.com

model to predict RUL and the corresponding confidence interval. The experimental results show that the proposed method has high estimation accuracy and good stability.

Key words: state of charge; state of health; remaining useful life; equivalent circuit model; data-driven method

锂离子电池具有成本低、能量密度高、循环寿命长的优点,在全球能源和环境危机不断加剧的背景下,正逐渐成为电动汽车、直流变电站和光伏电网的重要储能装置^[1].对锂离子电池配备电池管理系统(battery management system, BMS)可以对电池进行科学评估、风险预警和定期更换,保障电池的健康稳定运行.锂离子电池的荷电状态(state of charge, SOC)、健康状态(state of health, SOH)和剩余使用寿命(remaining useful life, RUL)是BMS运维的重要参数^[2].SOC是电池短时间尺度的状态变化,其实时估计可以预测系统运行时间,制定合理的充放电策略.SOH用来描述电池在不同循环次数下的老化程度,是对长时间尺度下当前状态的描述,其准确估计有利于对电池的健康诊断,及时更换老化电池.此两者是对电池当前状态的描述,而RUL定义为电池从当前时刻衰减至寿命终止(End of Life, EOL)所需的循环次数,是对电池未来状态的描述,其准确估计有利于合理规划电池的投运,提前排除隐患.三者从不同方面保障系统的平稳运行.

不同于电压电流等可测参数,锂离子电池的SOC、SOH和RUL参数无法用传感器直接测量,只能根据一些外部可测量,结合数学算法进行定量估计.电池的状态估计方法主要有间接测量法、模型法和数据驱动法等,下面分别展开介绍.

SOC估计的方法中,测量法主要是直接利用定义推出的基于电流积分的安时积分法和通过测量电池充放电过程中的开路电压进行SOC估计的开路电压法^[3],但是前者容易受到初始SOC误差的影响,且估计误差会随着时间不断积累,无法进行校正和补偿;后者需要耗费较长的时间,不适合在线使用.数据驱动方法^[4]用算法来学习电压、电流、温度等可测量与SOC的映射关系,训练量和计算量较大,不易在线应用.模型法需要建立等效电路模型(equivalent circuit model, ECM),包含电压源、电阻电容等元件,以模拟电池的外部工作状态,并结合滤波算法进行闭环SOC估计^[5].这种方法的稳定性较好,可以校正

初值误差,避免测量误差的时间累积.缺点是模型的阻容参数的适应性较差,随着电池老化,电池的阻容参数会发生较大变化^[6],模型参数的辨识值会产生较大的拟合误差,不适合电池全周期的SOC估计.此外,当前可用容量或健康状态会对SOC的估计结果造成较大的影响,不宜单独进行SOC估计.

SOH估计方法中,测量法主要是通过小电流放电进行核容,精确度高但是费时费力.基于模型的方法主要包括电化学模型和经验退化模型.电化学模型对于电池的内部工作机理的描述更为细致,通过建立一系列的偏微分方程来描述电池的容量衰退理化机制,如基于多孔电极理论搭建的准二维多孔电极模型(pseudo two-dimensional model, P2D model)^[7]及其简化方案^[8],但电化学模型参数辨识困难,方程计算复杂,不适合BMS系统的在线估计.经验退化模型可以对电池全周期的容量衰退趋势进行建模^[9],参数辨识简单,但是难以适应电池的个体差异导致的不同容量衰退趋势,同时难以刻画锂离子电池的容量再生现象,即电池容量的局部波动,常与其他方法结合使用^[10].基于数据驱动的SOH估计方法无须分析电池的内部机理,通过提取和分析与电池容量衰退密切相关的外部健康特征(health factor, HF)^[11],并通过机器学习的算法来建立HF与电池SOH之间的非线性映射关系,避免了物理建模和参数辨识问题,灵活性较强,应用广泛.这类方法主要依赖于所选健康特征的合理性和训练算法的泛化能力^[12].

RUL预测方法中的模型方法包括随机过程模型和经验退化模型,随机过程模型将锂离子电池的衰退过程看作一个随机的时间序列,对其进行建模,常见的随机过程模型包括Wiener模型^[13],马尔可夫(Markov)模型^[14],布朗运动模型^[15]等,这类模型中包含随机项,每次计算结果的波动性较大;经验模型利用数学公式对电池的历史数据进行拟合建立退化模型,外推迭代模型实现对锂离子电池RUL的预测.常见的经验模型包括指数模型^[16]、多项式模型^[17]和组合模型^[18]等,模型方法通常只能提供点预测结果,模

型跟踪能力差,在 RUL 长期预测中表现不佳.基于数据驱动的 RUL 预测方法包括神经网络(neural network, NN)^[19]、相关向量机(Relevance vector machine, RVM)^[20]、高斯过程回归(Gauss process regression, GPR)^[21]等.数据驱动方法有较好的非线性建模能力,在 RUL 长期预测中表现良好^[22],并提供区间预测结果.

锂离子电池的状态估计研究中,对于 SOC、SOH 和 RUL 参数的单独估计最为常见^[3-5,9-12,16-22],其次是对两个参数进行联合估计,如 SOC-SOH 联合估计^[23-24]、SOH-RUL 联合估计^[25-26].文献[23]提出一种基于粒子滤波的 SOC-SOH 多时间尺度估计方案;文献[24]采用动态神经网络对 SOC-SOH 进行闭环观测;文献[25]用布朗运动模拟电池 SOH 衰退时间序列,对短期 SOH 和长期 RUL 进行联合估计;文献[26]采用长短时记忆神经网络分别对 SOH 和 RUL 进行多对一和一对一映射.但是由于 SOC、SOH 和 RUL 都是电池运行的重要参数,且三者之间也存在复杂的相互影响,伴随电池全周期运行的始终,只考虑其中的一个或部分会导致较大的估计误差.比如电池不断老化中,电池等效模型的阻容参数会明显变化,造成 SOC 估计的不准确;电池的当前健康状态也影响着对电池寿命未来变化趋势的研判,影响 RUL 值^[25].所以在电池较长生命周期内对 SOC、SOH 和 RUL 进行联合估计具有现实的必要性.

估计算法方面,纯模型法或者纯数据驱动法不能完全令人满意,前者的鲁棒性较好,但是无法适应电池的不断老化而自动调整;后者泛化能力较强,但比较依赖训练样本的数量和代表性.由于电池长时间运行的数据量比较大,采用纯数据法会造成较大的计算负担,无法在线应用.所以有必要探索两种方法的有机融合,提高联合状态估计算法的准确度和稳定性.

锂离子电池的充电电压与电池状态具有较好的联系,且容易获取,因此本文以充电电压片段为切入点,将等效电路模型(equivalent circuit model, ECM)与数据驱动(data driven method, DDM)有机融合,在锂离子电池较长生命周期内,实现 SOC-SOH-RUL 联合估计.

本文的创新性贡献如下:

1)利用电压片段进行电池建模和状态估计,能够适应完全充电和局部充电情形,适应直流放电和随机放电工况,计算量小,可操作性强.

2)提出了等效电路模型和数据驱动方法相融合的联合估计方案,该方案结合了模型法的稳定性和数据法的学习能力,能够在同一个框架下联合估计电池的 SOC、SOH 和 RUL 三个状态参数,估计精度高.

3)考虑了电池使用过程中状态参数的关联影响,能够实现各状态参数的长期稳定预测.

在 Oxford 数据集和 NASA 电池数据集上进行实验验证,结果表明了所提方法的可行性.

1 健康特征和等效电路模型

1.1 锂离子电池 SOC、SOH 和 RUL 定义

SOC 定义为电池剩余电量占当前容量的比值,第 N 次放电循环的 t 时刻的 SOC 值为:

$$\text{SOC}(t) = \text{SOC}(t_0) - \int_{t_0}^t i(t) d\tau / Q(N) \quad (1)$$

式中: $i(t)$ 为 t 时刻的放电电流; $Q(N)$ 为第 N 次充放电循环的当前可用容量; t_0 为计量初始时刻,对于满充电池, $\text{SOC}(t_0) = 1$.

SOH 定义为电池的当前可用容量占额定容量(出厂容量)的比值,第 N 次充放电循环的 SOH 为:

$$\text{SOH}(N) = Q(N) / Q_N \quad (2)$$

式中: Q_N 为额定容量.对于新电池 $\text{SOH}(0) = 1$,随着充放电次数的增多,SOH 呈现逐渐降低的趋势,当 SOH 下降到 EOL 时,认为电池寿命终止,EOL 一般取 0.7~0.8.

RUL 定义为充放电循环了 N 次的电池在其 SOH 下降到 EOL 之前还能继续充放电循环的次数,第 N 次充放电循环时的 RUL 值为:

$$\text{RUL}(N) = \inf\{n: \text{SOH}(N) \geq \text{EOL}\} - N \quad (3)$$

式中 $\inf\{n: \text{SOH}(N) \geq \text{EOL}\}$ 表示电池从 $\text{SOH} = 1$ 下降到 $\text{SOH} = \text{EOL}$ 所经历的次数.

1.2 数据来源

牛津大学电池老化数据集^[20](Oxford Battery Degradation Dataset)包含 8 块 Kokam 的钴酸锂离子袋装电池,型号为 SLPB533459H4,标记为 Cell1~Cell8.该电池的额定容量为 740mAh.该电池的阴极材料为锂钴氧化物和锂镍钴氧化物,阳极材料为石墨.老化测试在 40℃室温下进行,对 8 个电池进行 2C 即 1.48A 恒流充电,采用能够模拟汽车实际行驶状态的 ARTEMIS 市区行驶工况对电池进行动态放电.每 100 个老化周期后,对电池进行 1C 恒流充电,直到电池终止寿命,老化测试结束.整个过程中

利用 Bio-Logic MPG-205 电池测试仪, 每一秒记录一次电池的电流、电压和表面温度。


NASA 数据集^[25]来源于 NASA 艾姆斯卓越预测研究中心(Prognostics Center of Excellence, PCoE), 包含四个阴极为 $\text{LiNiCo}_{0.15}\text{Al}_{0.05}\text{O}_2$ 、阳极为石墨的 LG Chem 18650 锂电池老化数据, 标称容量为 2 Ah, 编号分别为 B0005、B0006、B0007 和 B0018. 在老化实验中, 这三个电池在 1.5 A 及 4.2 V 的恒流恒压模式下重复充电, 截止电流为 20 mA, 然后施加 2 A 恒流电流分别放电至 2.7 V, 2.5 V 和 2.5 V. 整个测试在室温 24 °C 下进行, 利用 Arbin 测试仪测量电池的电流、电压和表面温度. 此外, NASA 数据集还包含动态工况下的 RW4 和 RW9 两个电池, 其正极和负极材料分别为 $\text{LiNi}_{0.8}\text{Co}_{0.15}\text{Al}_{0.05}\text{O}_2$ 和 MAG-10 石墨, 标称容量为 2 Ah. 为了加速电池老化, 进行了循环随机电流放电实验, 即从 $[-5\text{A}, 5\text{A}]$ 组中随机选择放电电流, 电流为 0.05 A 的整数倍. 当终端电压低于 3.2 V, 或高于 4.2 V, 或电流持续时间达到 5 min 时, 将随机产生下一工作电流. 每 50 个随机放电循环后, 采取局部充电, 各充电循环的初始 SOC 处于 $[20\%, 50\%]$. 充满后并以 1 A 的恒定电流放电, 以检查当前的可用容量.


两个数据集提供了电池较长生命周期的容量衰退数据和充放电电压电流, 适合进行状态估计实验.

1.3 健康特征提取

随着电池充放电次数的增加, 电池老化程度加深, 当前 SOH 呈现下降的趋势, 电池不同 SOH 下的恒流充电(CC)阶段的电压曲线如图 1(a)(c)(e)所示, 曲线颜色由亮到暗, 表示电池老化程度加深, CC 阶段达到充电截止电压的时间不断缩短, 充电电压曲线与容量衰退呈现出较好的一致性, 故可以用充电电压曲线来表征电池的健康状态. 考虑到完整的充电电压曲线往往难以获取, 故可以选取电压区段来表征电池的当前健康状态. 在实际应用中, 电池的充电时刻不好统计, 而充电电压容易测量, 故选取充电电压从 U_1 上升到 U_2 的时间差 $\Delta T = T_2 - T_1$ 作为健康特征(HF), 等压升时间记为 DV_DT.

下面采用遍历法寻找最优电压区段. 图 1(b)(d)(f)展示了各电池不同的 $[U_1, U_2]$ 取值所获得的 ΔT 与 SOH 的 Pearson 关联度, 见式(4), 由图可知, 不同的电压升区段的选取对容量相关度的影响较大, 牛津数据集电池的最优电压区段选取 $[3.8, 4.15]$; NASA 数据集 B0005~B0018 选取 $[3.8, 4]$.





(f)RW9 不同电压区段与 SOH 的关联度

图 1 电池老化过程中充电电压曲线和电压区段关联度分析
Fig.1 Charging voltage curve and capacity increment curve during battery degradation

$$P = \frac{\sum_i (D_i - \bar{D})(S_i - \bar{S})}{\sqrt{\sum_i (D_i - \bar{D})^2} \sqrt{\sum_i (S_i - \bar{S})^2}} \quad (4)$$

$$P = \frac{1}{n} \sum_{i=1}^n \frac{\min |S_i - D_i| + \rho \max |S_i - D_i|}{|S_i - D_i| + \rho \max |S_i - D_i|} \quad (5)$$

式(4)(5)中: D_i 表示第*i*次循环的等压升时间; S_i 为第*i*次循环的健康状态值; n 为总的循环次数; ρ 为分辨系数,一般取 0.5. Pearson 系数从线性相关性的角度衡量两个变量序列之间的关联程度,其值位于[-1,1]之间,绝对值越大,相关性越高. 灰色关联度(grey relation coefficient, GRC)从两个变量序列的几何曲线相似程度的角度来衡量其相关程度,其值位于[0,1]之间,越接近 1,相关性越高,分别计算两个数据集的 DV_DT 与 SOH 之间的 Pearson 系数和灰色关联度,得到表 1.

表 1 各电池 SOH 与 DV_DT 的相关度

Tab.1 The relevance between SOH and DV_DT of batteries

数据集	电池	Pearson 系数	GRC
Oxford	Cell1	0.999 5	0.933 4
	Cell2	0.996 4	0.879 1
	Cell3	0.999 3	0.934 4
	Cell4	0.997 5	0.939 0
	Cell5	0.998 1	0.886 2
	Cell6	0.994 4	0.928 0
	Cell7	0.998 9	0.942 1
	Cell8	0.998 8	0.930 2
NASA	B0005	0.991 8	0.863 2
	B0006	0.988 7	0.871 2
	B0007	0.992 3	0.853 8
	B0018	0.987 6	0.832 8
	RW4	0.980 3	0.831 8
RW9	0.996 3	0.859 6	

由表 1 可知,完全充电的 Cell1~Cell8 电池和 B0005~B0018 电池的 Pearson 系数都在 0.98 以上, GRC 在 0.8 以上. 局部充电的 RW4 和 RW9 电池的相关性稍低,但 Pearson 系数和 GRC 分别也分别大于 0.96 和 0.75,表明所选的健康特征 DV_DT 能够表达全充和局部充电条件下的电池老化特征,同时易于提取,适合用于 SOH 的在线估计.

1.4 等效电路模型

如引言中所述,电池的等效电路模型在电池状态估计中具有重要作用,常用的有一阶等效电路模型,结构如图 2 所示:




图 2 一阶等效电路模型

Fig.2 The first-order equivalent circuit model

其数学表达式如式(6)所示:

$$\begin{cases} U = U_{OCV} + IR_0 + U_p \\ \frac{dU_p}{dt} = -\frac{1}{C_p R_p} U_p + \frac{1}{C_p} I \end{cases} \quad (6)$$

式中: I 表示输入电流; U_p 为端电压; R_0 表示欧姆内阻; R_p 和 C_p 分别表示极化电阻和极化电容,随着电池老化逐渐增大; U_{OCV} 为通常被认为是 SOC 的函数,即 $U_{OCV}=f(\text{SOC})$,常用多项式进行拟合.其中, SOC 表示荷电状态,获取方法一般采用小电流充放电,时间耗费较长,由于 f 受健康状态的影响较小^[27],故这里选用新电池的 OCV-SOC 曲线. 电池的充电工况一般选取先恒流再恒压充电,下面考察不同循环次数下恒流充电的电池端电压 U_p 的变化. 恒流充电下的 SOC 的表达式为:

$$\text{SOC}(t) = I \times t / Q(n) \quad (7)$$

式中: $Q(n)$ 表示第 n 次充放电循环下的可用容量,此时的健康状态计算公式如式(8)所示:

$$\text{SOH}(n) = Q(n) / Q_N \quad (8)$$

式中: Q_N 为电池的出厂容量.

求解方程组(6),可得:

$$U^{(n)}(t) = U_{OCV}^{(n)}(It/Q(n)) + U_p^{(n)}(t) + IR_0^{(n)} = U_{OCV}^{(n)}(It/Q(n)) + (U_{p0} - IR_p^{(n)}) \exp(-t/R_p^{(n)}C_p^{(n)}) + IR_p^{(n)} + IR_0^{(n)} \quad (9)$$

各变量上标(n)表示第 n 次充电.

采用最小二乘算法对电压片段进行拟合,即式

(9)中 $t \in [T_1, T_2]$, 以辨识阻容参数 $R_0^{(n)}$ 、 $R_p^{(n)}$ 、 $C_p^{(n)}$, 拟合结果如图 3 所示. 可知 ECM 在电池的全周期都能较好地刻画电池的充电外特性. 由第 n 次循环的恒流充电阶段辨识到的 RC 参数将用于该次循环放电阶段的 SOC 估计, 这将在下一节中介绍.




图 3 充电电压真实值和一阶模型输出值
Fig.3 Real value and fitting value of charging voltage

2 相关数学方法

2.1 UKF

本文方法的模型部分主要是一阶 ECM 结合无

迹卡尔曼滤波算法(unscented Kalman filter, UKF)^[28]. 根据引言中所述, 锂离子电池的 SOC 估计方法常采用闭环滤波算法, 其最大的优势是可以克服 SOC 初值的不确定性, 进行误差校正, 同时能够减少误差在时间上的累积. 本文建立一阶 ECM, 结合 UKF 进行 SOC 估计, 选取 SOC 和极化电压向量 $[SOC, U_p]^T$ 作为状态变量建立电池的状态空间方程, 如式(10).

$$\begin{bmatrix} SOC(k+1) \\ U_p(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & e^{-\frac{\Delta t}{R_p C_p}} \end{bmatrix} \begin{bmatrix} SOC(k) \\ U_p(k) \end{bmatrix} + \begin{bmatrix} -\frac{\Delta t}{Q(n)} \\ R_p(1 - e^{-\frac{\Delta t}{R_p C_p}}) \end{bmatrix} \times I(k)$$

$$U_i(k) = U_{ocv}(SOC(k)) - U_p(k) - R_0 I(k) \tag{10}$$

式中: Δt 为采样时间.

写成如下的紧凑形式:

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) + w_k \\ y(k) = Cx(k) + Du(k) + v_k \end{cases} \tag{11}$$

式中: 状态量 $x = [SOC, U_p]^T$, 控制量 $u = I$. w_k 为过程噪声, 其协方差矩阵为 Q . v_k 为测量噪声, 其协方差矩阵为 R . 各矩阵含义如下:

$$\begin{cases} A = \begin{bmatrix} 1 & 0 \\ 0 & e^{-\frac{\Delta t}{R_p C_p}} \end{bmatrix}, B = \begin{bmatrix} -\frac{\Delta t}{Q(n)} \\ R_p(1 - e^{-\frac{\Delta t}{R_p C_p}}) \end{bmatrix} \\ C = \begin{bmatrix} U_{ocv}(SOC(k)) \\ (SOC(k)) \end{bmatrix}^T, D = -R_0 \end{cases} \tag{12}$$

建立好状态方程和观测方程后, 就可以采用 UKF 算法进行递推运算, 进行 SOC 估计.

UKF 算法基于 UT 变换技术, 即利用采样点 (sigma 点) 的分布来近似非线性函数的概率分布. 与其他基于卡尔曼滤波的 SOC 估计方法相比, UKF 算法避免了求导运算, 对状态方程的要求低, 同时对方差的估计更为准确.

UKF 算法估计 SOC 主要包括系统初始化、预测阶段和更新阶段.

2.1.1 系统初始化

状态量的初始值和初始误差协方差矩阵分别为:

$$\hat{x}_0 = E(x_0), P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T] \tag{13}$$

用对称采样法生成初始 Sigma 点:

$$\begin{cases} \chi_0 = \hat{x}_0 \\ \chi_i = \hat{x}_0 + [\sqrt{(n+\lambda)P_0}]_i, i=1, 2, \dots, n \\ \chi_i = \hat{x}_0 - [\sqrt{(n+\lambda)P_0}]_{i-n}, i=n+1, n+2, \dots, 2n \end{cases} \tag{14}$$

给每一个 Sigma 点设置权重值用于后续的计算中:

$$\begin{cases} \omega_0^m = \lambda / (n + \lambda) \\ \omega_0^c = \frac{\lambda}{(n + \lambda) + (1 - \alpha^2 + \beta)} \\ \omega_i^m = \omega_i^c = \frac{1}{2(n + \lambda)}, i = 1 : 2n \end{cases} \quad (15)$$

式中: $\lambda = \alpha^2 (n + \kappa) - n$, α 描述了 Sigma 点偏离状态值的程度, 满足 $10^{-4} \leq \alpha \leq 1$; λ 是 Sigma 点的尺度参数, κ 是副尺度参数, 为了保证方差阵为半正定, 满足 $\kappa \geq 0$, 一般在状态估计时取 0, 在参数估计时取 $3 - n$; β 是一个与 Sigma 点分布相关的量, 当 Sigma 点成高斯分布时, 通常 $\beta = 2$ 时最优。

2.1.2 预测阶段

第 k 个采样时刻, Sigma 点构建的矩阵为:

$$\chi_{k-1} = [\hat{x}_{k-1} \quad \hat{x}_{k-1} + \sqrt{(n+\lambda)P} \quad \hat{x}_{k-1} - \sqrt{(n+\lambda)P}] \quad (16)$$

对式 (13) 生成的 Sigma 点进行状态方程的处理, 并对时刻系统状态量和误差方差矩阵作出预测:

$$\begin{cases} \chi_{i,k-1}^* = A_{k-1} \chi_{i,k-1} + B_{k-1} u_{k-1} \\ \hat{x}_k = \sum_{i=0}^{2n} \omega_i^m \chi_{i,k-1}^* \\ P_{x,k} = \sum_{i=0}^{2n} \omega_i^c [\chi_{i,k-1}^* - \hat{x}_k][\chi_{i,k-1}^* - \hat{x}_k]^T + Q_k \end{cases} \quad (17)$$

2.1.3 更新阶段

将各个 Sigma 点在 k 时刻的估计值 $\chi_{i,k-1}^*$ 代入系统观测方程得到 k 时刻观测量的估测值:

$$\begin{cases} y_{i,k-1}^* = C_{k-1} \chi_{i,k-1}^* + D_{k-1} u_{k-1} \\ \hat{y}_k = \sum_{i=0}^{2n} \omega_i^m y_{i,k-1}^* \end{cases} \quad (18)$$

计算 k 时刻观测量的方差矩阵:

$$P_{yy} = \sum_{i=0}^{2n} \omega_i^c [y_{i,k-1}^* - \hat{y}_k][y_{i,k-1}^* - \hat{y}_k]^T + R_k \quad (19)$$

计算 k 时刻状态量与观测量的协方差:

$$P_{xy} = \sum_{i=0}^{2n} \omega_i^c [\chi_{i,k-1}^* - \hat{x}_k][y_{i,k-1}^* - \hat{y}_k]^T \quad (20)$$

计算卡尔曼滤波增益:

$$K_k = P_{xy} / P_{yy} \quad (21)$$

更新状态量与误差方差矩阵:

$$\begin{cases} x_k = \hat{x}_k + K_k (y_k - \hat{y}_k) \\ P_{x,k} = P_{x,k}^- - K P_y K^T \end{cases} \quad (22)$$

已知初值 x_0 和 P_0 , 通过不断递推, 就能得到状态量和误差矩阵的实时估计。

2.2 LSSVM 和 GPR 算法

本文采用的数据驱动方法主要是最小二乘支持向量机 (LSSVM) 和高斯过程回归 (GPR). LSSVM 适合小样本数据的非线性建模, 可用于短周期的 SOH 点估计. 高斯过程回归时间序列模型适合强非线性的数据建模问题, 并可以给出预测的不确定性表达, 可用于 RUL 的长期预测^[25]. 算法的详细数学推导分别参见文献[12]和[29].

3 SOC-SOH-RUL 联合估计框架

由于锂电池的 SOC、SOH 和 RUL 参数缺一不可, 且在电池运行中相互影响, 所以本文提出一种 SOC-SOH-RUL 联合估计框架, 包括老化建模和状态估计两大块, 状态估计又分为 SOC 估计、SOH 估计和 RUL 预测三个部分. 锂电池的周期运行行为反复的充电-放电, 对于一次充放电循环, 因为充电模式相对固定, 一般采取恒流-恒压 (CC-CV) 模式, 故 SOH 和 RUL 估计在充电阶段进行. 由于负载的不确定性, 放电工况较复杂, 不易进行电池建模, 但放电过程也是 SOC 估计的重要应用场合. 整体流程图如图 4 所示.

1) 老化建模: 采集电池预测起点 SP 之前的充放电循环电压电流数据, 对充电电压数据进行相关性分析, 提取最优电压区段 $[U_1, U_2]$ 的上升时间 DV_DT 为 HF. 将 HF 序列作为输入, SOH 序列作为输出, 建立 LSSVM 电池老化模型.

2) SOH 估计: 采集第 n 次循环 ($n > SP$) 的充电电压最优区段, 提取 HF 并代入建好的 LSSVM 老化模型中进行 SOH 估计. 框图中的 OCV-SOC 曲线如果每次充放电循环都重新测量, 则繁琐且不实用. 一般情况下, OCV-SOC 曲线随 SOH 变化较小^[27], 故测量新电池的 OCV-SOC 曲线, 用于拟合 SP 之后各循环的最优充电电压片段, 以进行 SOC 估计. 对于动态工况下的电池, OCV-SOC 曲线随 SOH 的变化较明显^[30], 故测量第 SP 循环的 OCV-SOC 曲线供 SP 之后各循环使用. 实验条件允许的情况下, 也可以每隔一定的循环周期数对 OCV-SOC 曲线进行测量更新一次, 这有助于改善 SOC 的估计效果.

3) SOC 估计: 对第 n 次循环的放电阶段进行 SOC 估计. 由 2.1 可知, UKF 算法的状态空间方程包含的阻容参数 R_0, R_p, C_p 通过拟合该次循环的充电电压片段获取, 容量 $Q(n)$ 可以由本次循环的 SOH 估计值与额定容量的乘积 $\hat{Q}(n)$ 来表示. 值得注意的是,

端电压的表达式(9)中包含当前容量 $Q(n)$, 而第 n 次充电中 $Q(n)$ 是未知的, 故这里的 $Q(n)$ 采用上一次循环的 SOH 估计值与额定容量的乘积 $\hat{Q}(n-1)$ 来替代, 图 4 中的 Z^{-1} 表示取上一次循环的 SOH 估计值, 由于在同一次充电和放电过程中, 电池的老化程度近似相同, 所以辨识出的阻容参数能够较好地适应电池的不断老化, 从而为 SOC 估计提供一个比较准确的等效电路模型。

4) RUL 估计: GPR 时间序列模型的输入为循环次数集 $\{1, \dots, n\}$, 输出为健康特征集 $\{DV_DT\}_{i=1,2,\dots,n}$, n 大于预测起点 SP, 采用共轭梯度法训练

GPR 模型. GPR 模型建立后, 依次将循环数 $n+r(r>0)$ 输入模型中, 输出 HF 在第 $n+r$ 次循环的预测值 D 和置信上下限 $[D_1, D_2]$, 将 D, D_1 和 D_2 分别代入 LSSVM 老化模型中, 分别输出值 S, S_1, S_2, S 为 SOH 退化预测轨迹在第 $n+r$ 次循环上的点, S_1 和 S_2 分别为置信上下限. 当 S 大于寿命阈值 EOL 时, 表明电池还未报废, 置 $r=r+1$, 重复上述步骤, 直到 S 在 EOL 以下, 表明在第 $n+r$ 次循环时, SOH 低于寿命阈值, 则第 n 次循环的 RUL 预测值为 r . 退化轨迹的上下限 S_1 和 S_2 分别在 $n+r_1$ 和 $n+r_2$ 次计算时低于 EOL, 则 $[r_1, r_2]$ 即为 RUL 的置信区间。

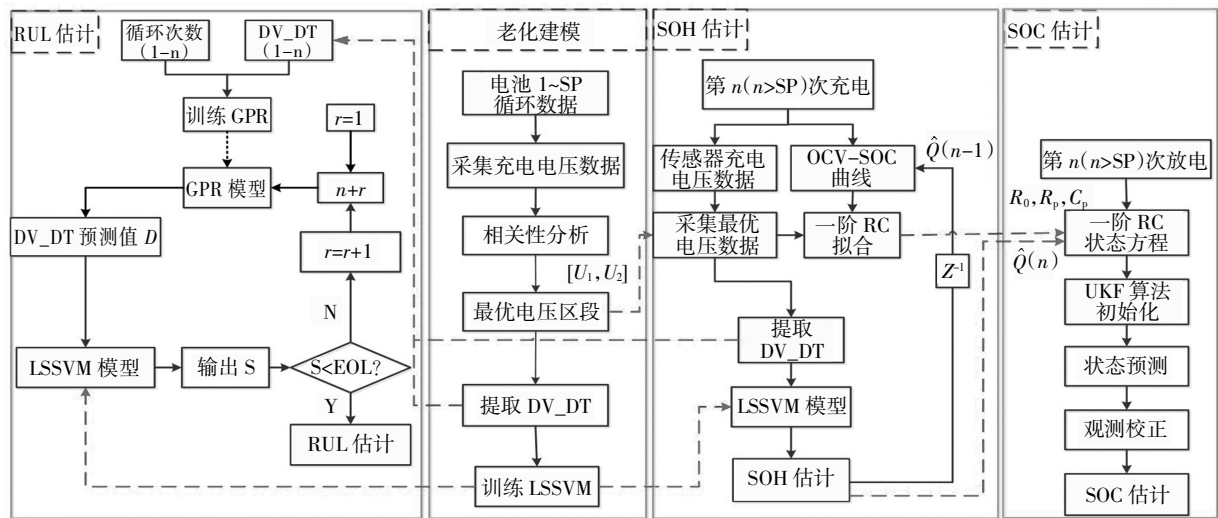


图 4 锂离子电池 SOC-SOH-RUL 联合估计框图

Fig.4 The coupled estimation framework of SOC-SOH-RUL for lithium-ion battery

4 实验结果与分析

本文采用相对误差百分比 (relative percentage error, RPE)、平均绝对误差 (mean absolute error, MAE) 和最大误差 (maximum error, ME) 来对估计结果进行定量评价, x_i 和 \hat{x}_i 分别为真实值和估计值。

$$RPE = \frac{x_i - \hat{x}_i}{x_i} \times 100\% \tag{23}$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - \hat{x}_i| \tag{24}$$

$$ME = \max_{i \in \{1, \dots, N\}} |x_i - \hat{x}_i| \tag{25}$$

牛津数据集 Cell1、Cell2、Cell3、Cell7 和 Cell8 的标准化周期数约为 80, 预测起点 SP 设为 30; Cell4~Cell6 的标准化周期数约为 50, 预测起点 SP 设为 20, EOL 设为 0.8. NASA 数据集 B0005~B0007 有 168 个周期, SP 设为 80; B0018 有 132 个周期, SP 设

为 60, EOL 设为 0.75. RW4 和 RW9 提供的标准化周期较少, SP 设置为总循环次数的 50%, EOL 分别设为 0.8 和 0.7. EOL 以后循环不在本文考虑的范围。

4.1 牛津数据集

4.1.1 SOH 和 RUL 估计结果

SOH 和 RUL 估计在充电阶段进行. 图 5 详细展示了 Cell1 和 Cell4 的 SOH 和 RUL 估计结果, 更多电池结果见表 2. 图中绿色和蓝色虚线分别表示电池预测起点 SP 和寿命终点 EOL, 由图可知, SOH 估计的相对误差百分比在 1% 以内, 由表 2 可知, MAE 计算结果在 0.5% 以内, ME 小于 0.01, 表明所选的健康特征—等压升时间能够很好地反映电池的老化, 并能适应电池不一致性带来的容量衰退趋势差异. 同时表明 LSSVM 算法具有较强的非线性映射能力, 在数据量较小的样本中 (Cell4~Cell6) 中也能实现 SOH 的准确估计。

RUL 预测通过 GPR 时间序列模型输出健康特征在未来循环次数的变化趋势, 将该趋势输入到建

好的 LSSVM 模型中, 输出健康状态的退化预测轨迹, 该轨迹到达 EOL 所经历的总循环次数即为当前循环下的 RUL 预测值. HF 和 SOH 的预测趋势及相应的 95%置信区间(以不同循环数为预测起点)如图 5(a)和(b)所示, 轨迹显示为不同颜色的曲线簇, 颜色越深, 表示作为 RUL 预测起点的循环数越大. 从图 5 可以看出, 在不同的预测起点下, HF 和 SOH 的预测趋势均与以青色表示的实际趋势较好地吻合, 鲁棒性较好.

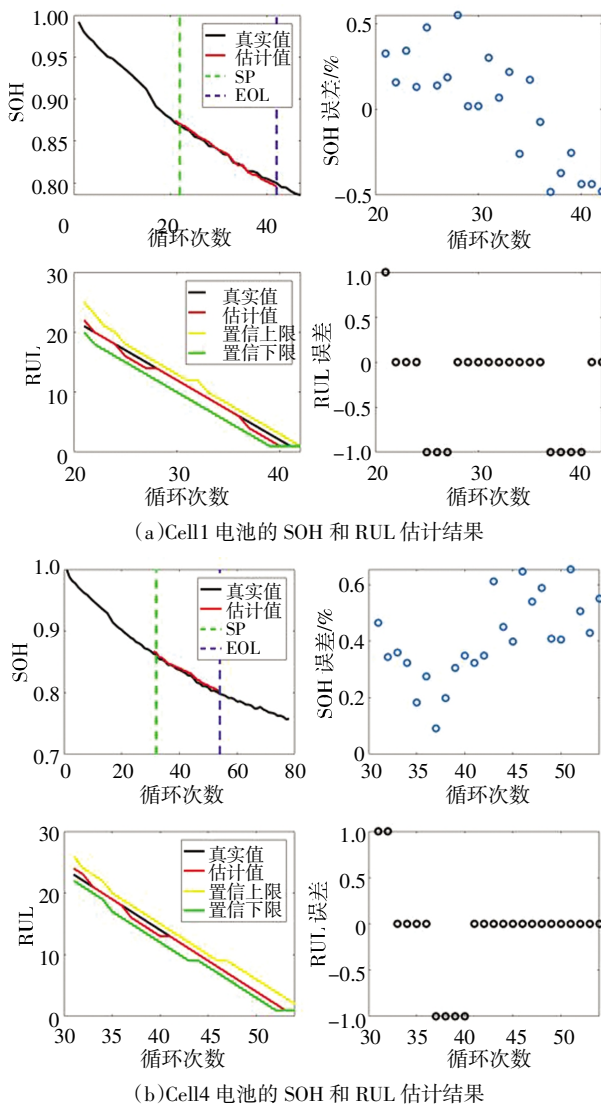


图 5 牛津数据集 SOH 和 RUL 估计结果和误差
Fig.5 The estimation results and error of SOH and RUL for Oxford dataset

由图 6 可知, Cell1 和 Cell4 电池从 SP 到 EOL 各循环周期的 RUL 估计值(红线)与真实值(黑线)非常接近, 最大误差为 1, 且持续周期数较少. 绿线和黄线分别表示 RUL 置信区间的上下限, 估计值和真实值都落在置信区间里, 且置信区间的宽度较窄, 表

明估计结果具有较高的可靠性. 表 2 中展示了 RUL 估计的 MAE 和 RMSE 结果, 各电池 MAE 均小于 1, ME 为 1 或 2, 定量表明该方法具有较高的精度和稳定性.

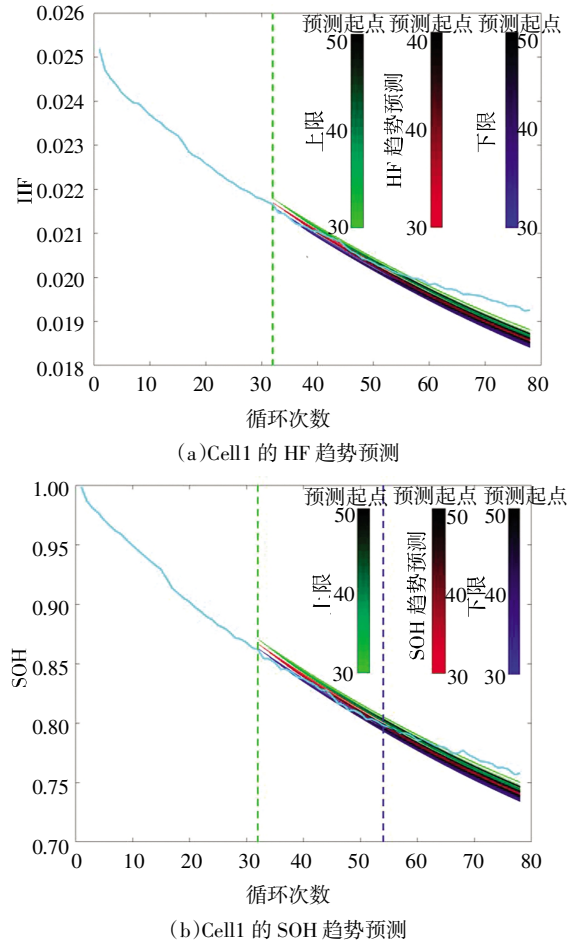



图 6 Cell1 电池不同起点下 HF 和 SOH 的衰退趋势预测
Fig.6 The degradation trend of HF and SOH under different starting points for Cell1

表 2 牛津电池 SOH 和 RUL 估计结果
Tab.2 The estimation results of SOH and RUL for Oxford batteries


电池	SOH		RUL	
	MAE	ME	MAE	ME
Cell1	0.003 4	0.005 3	0.250 0	1
Cell2	0.001 6	0.002 6	0.400 0	1
Cell3	0.005 2	0.008 7	0.724 1	2
Cell4	0.002 2	0.004 8	0.363 6	1
Cell5	0.001 4	0.003 7	0.214 3	1
Cell6	0.003 8	0.006 4	0.087 0	1
Cell7	0.003 7	0.008 3	0.725 0	2
Cell8	0.001 3	0.003 8	0.291 7	2

4.1.2 SOC 估计结果

SOC 估计在放电阶段进行. 图 7 展示了 Cell1 和 Cell4 电池从预测起点到 EOL 各放电周期的 SOC 估计结果,更多电池结果见表 3. 放电工况为恒流放电. 由于实际中 SOC 的初值一般是不确定的,为了验证算法的鲁棒性,设置 SOC 的初始误差为 0.5,定义跟随时间为 SOC 估计值与真实值的误差小于 0.1 的时间和放电总时间的比值,计算跟随时刻之后的 MAE 和 RMSE,绘制各指标随循环次数的变化趋势. 从 SP 到 EOL 的总循环次数中等间隔取四次循环,四次循环的放电阶段 SOC 估计效果如图 7 左边四个子图的红线所示.



(a)Cell1 电池的 SOC 估计结果



(b)Cell4 电池的 SOC 估计结果

图 7 牛津数据集 SOC 估计结果和误差

Fig.7 The estimation results and error of SOC for Oxford dataset

由图 7 可知, 电池在不同循环次数下的平均跟随时间在 0.07 左右, 精度较高且相对误差随循环次数的波动比较平稳,反映了较好的鲁棒性. 表 3 中电池各循环周期的平均 MAE 在 2%以内, 平均 RMSE 在 3%以内. 图 7 左子图的蓝色曲线展示了 SOC 单独估计的效果,即 UKF 的状态方程和观测方程的阻

容参数设为初始辨识值, Q_n 设为额定容量 740 mAh,此时 SOC 出现了明显的偏离,且随着电池老化更加严重. 而采用本方法,阻容参数和当前容量可以随电池老化的进行而自适应调整,因而提升了 ECM 的精度和适应性,降低了跟随时间,在电池较长生命周期都能取得较高的 SOC 估计精度.

表 3 牛津电池 SOC 估计结果

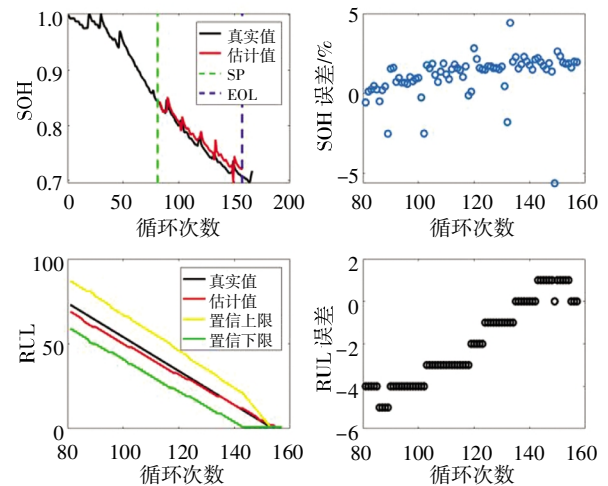
Tab.3 The estimation results of SOC for Oxford batteries

电池	平均跟随时间	平均 MAE	平均 RMSE
Cell1	0.069 7	0.014 3	0.021 9
Cell2	0.067 3	0.013 0	0.021 8
Cell3	0.069 5	0.015 1	0.022 1
Cell4	0.070 9	0.014 0	0.022 4
Cell5	0.064 9	0.015 4	0.022 2
Cell6	0.068 9	0.013 9	0.022 1
Cell7	0.069 4	0.014 0	0.021 6
Cell8	0.071 0	0.014 2	0.022 3

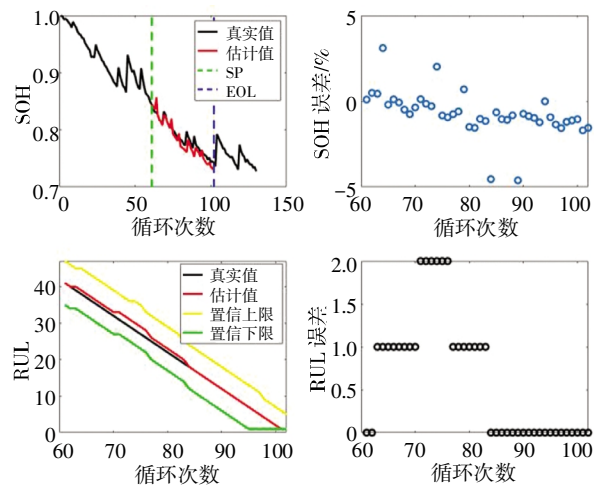
4.2 NASA 数据集

4.2.1 SOH 和 RUL 估计结果


图 8(a)(b)展示了 B0005 和 B0018 的 SOH 估计结果和相对误差. SOH 估计大部分点的误差在 2%, 少数异常波动的点的误差也不超过 5%, 符合 BMS 系统对误差的要求. 局部充电条件下的 RW4 和 RW9 的 SOH 估计结果如图 8 (c)(d) 所示. 可以看出,SOH 估计的相对误差百分比小于 2%, 说明所提方法具有一定的迁移能力. 表 4 为各电池误差的计算结果,各电池的 MAE 在 1.2%以内,ME 小于 0.05, 精度较高.




(a)B0005 电池的 SOH 和 RUL 估计结果




(b)B0018 电池的 SOH 和 RUL 估计结果




— SOH 真实衰退轨迹 — 预测轨迹 — 上界 — 下界 — SP — EOL



(c)RW4 电池的 SOH 和 RUL 估计结果



— SOH 真实衰退轨迹 — 预测轨迹 — 上界 — 下界 — SP — EOL



(d)RW9 电池的 SOH 和 RUL 估计结果

图 8 NASA 数据集 SOH 和 RUL 估计结果和误差


Fig.8 The estimation results and error of SOH and RUL for NASA dataset

表 4 NASA 电池 SOH 和 RUL 估计结果


Tab.4 The estimation results of SOH and RUL for NASA batteries

电池	SOH		RUL	
	MAE	ME	MAE	ME
B0005	0.011 4	0.041 4	2.692 3	5
B0006	0.010 3	0.047 8	0.750 0	2
B0007	0.003 7	0.038 2	1.809 5	4
B0018	0.008 3	0.037 4	0.627 9	2
RW4	0.011 0	0.017 4	0.500 0	1
RW9	0.005 9	0.014 0	0.500 0	1

B0005 的 HF 和 SOH 的预测趋势及 95%置信区间如图 9(a)(b)所示. NASA 电池虽然存在明显的容量再生现象,但以不同循环次数为 RUL 预测起点的 HF 和 SOH 衰退预测趋势均与实际的青色轨迹一致,保障了 RUL 估计的准确性. B0005 和 B0007 的 RUL 初始估计误差较大,ME 为 5 和 4,原因是其预测步长在 80 次左右,RUL 长期预测的难度较大.随着循环次数的增加,估计误差逐渐减小到 0,对于较新的电池(预测起点附近),由于还有较长的使用空间,所以对 RUL 的精确度要求不高,而使用次数较多的电池的 RUL 估计显得更为重要. B0018 的预测步长较短,其 MAE 不超过 1,ME 为 2,精度较高.此外电池的真实 RUL 都位于预测的上下限内,表明了预测的可靠性较强.表明本方法对于电池容量衰退的复杂波动也能较好地适应,并能进行准确可靠的估计,估计误差也在理想的范围内. RW4 和 RW9 的



(a)B0005 的 HF 趋势预测



(b)B0005 的 SOH 趋势预测

图 9 不同起点下 HF 和 SOH 的衰退趋势预测


Fig.9 The degradation trend of HF and SOH under different starting points

RUL 估计结果如图 8(c)(d)所示. 可以看出,在不同的预测起点下,SOH 退化的预测趋势与实际趋势很好地吻合,从而实现了准确的 RUL 估计,MAE 为 0.5,ME 为 1. 这也体现了 GPR 算法较强的小样本建模能力和非线性映射能力.


4.2.2 SOC 估计结果

图 10 和表 5 展示了 NASA 各电池的 SOC 估计结果. 图 10(a)(b)详细展示了 B0005 和 B0018 各循环周期的 SOC 估计结果、误差和跟随时间,绝大部分点的 MAE 和 RMSE 计算值较小. 个别点的误差较大,即出现误差的短暂波动,但不超过 0.1. 不同于 Oxford 电池衰退趋势较平缓,NASA 电池 B0005~B0018 电池出现较明显的容量再生现象,这涉及到电池内部的物化反应^[31],通过外部健康特征不能完全映射这种非线性波动,故增加了状态估计的复杂性,造成了图 8(a)(b)中个别周期的 SOH 估计误差较大,进而造成个别周期的 SOC 估计误差稍大,但跟随时间和整体误差都远好于单独估计的效果(蓝色曲线).

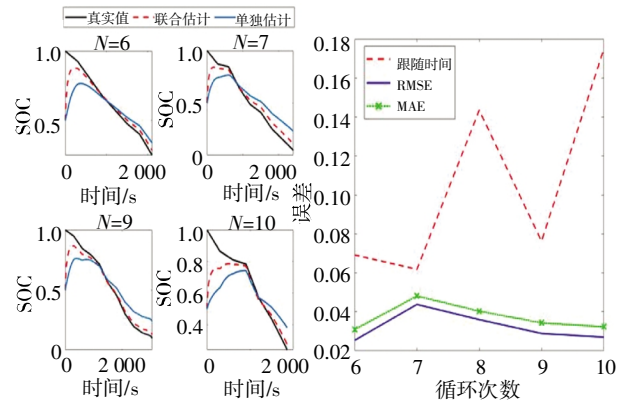
RW4 和 RW9 的 SOC 估计结果如图 9(c)(d)所示. 结果表明,本文提出的联合估计方法比单独估计方法具有更好的性能,估计误差小,跟踪性能好,验证了该方法在随机放电模式下的有效性. 由图 9 和表 5 可知,变电流放电条件下,各循环次数下 SOC 估计的平均 MAE 或 RMSE 均小于 0.04,跟随时间在 0.03 以内,效果较好.



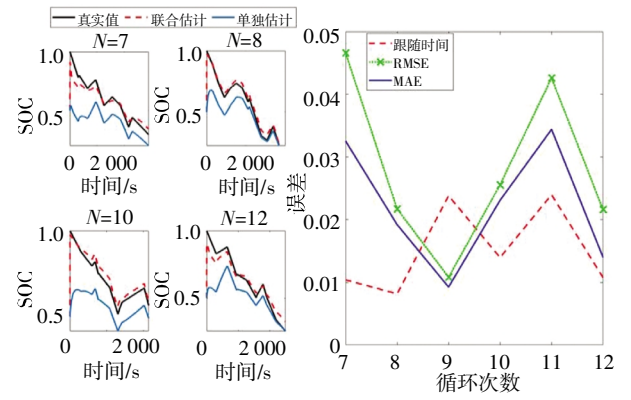
(a)B0005 电池的 SOC 估计结果



(b)B0018 电池的 SOC 估计结果



(c)RW4 电池的 SOC 估计结果



(d)RW9 电池的 SOC 估计结果

图 10 NASA 数据集 SOC 估计结果和误差

Fig.10 The estimation results and error of SOC for NASA dataset

表 5 NASA 电池 SOC 估计结果

电池	平均跟随时间	平均 MAE	平均 RMSE
B0005	0.012 9	0.031 7	0.041 6
B0006	0.044 5	0.031 2	0.039 4
B0007	0.025 3	0.024 4	0.035 3
B0018	0.010 6	0.037 5	0.042 8
RW4	0.022 1	0.027 9	0.033 7
RW9	0.015 2	0.022 1	0.028 1

5 结 论

本文以锂离子电池充电电压片段为切入点,进行等效电路模型建模和健康特征(HF)提取,在预测起点(SP)之前建立反映电池老化的 LSSVM 老化模型. SP 之后循环工作时采集该压升片段,将 HF 代入 LSSVM 模型中实现 SOH 估计;用每次循环所建立的等效电路模型,构建 SOC 估计的状态空间模型,对放电的 SOC 进行估计;用高斯过程回归时间序列模型对健康特征序列循环次数的变化进行建模,通过循环次数外推对 DV_DT 的变化趋势进行预测,将变化趋势输入 LSSVM 老化模型中,输出 SOH 的退化轨迹,该轨迹与寿命阈值的交点即为 RUL 预测值,并给出区间预测结果. 采用 Oxford 和 NASA 数据集进行算法验证,结果表明所提方法能够在电池预测起点之后的较长运行周期内实现 SOC、SOH 和 RUL 的准确估计.

本文提出的状态联合估计方案不需要锂电池内部的电化学反应机理,借助电压、电流等常规物理量,通过等效电路模型和数据驱动方法的有机融合,实现了 SOC、SOH 和 RUL 的联合估计,计算量小,实用性强.

参考文献

- [1] SARMAH S B, KALITA P, GARG A, *et al.* A review of state of health estimation of energy storage systems: challenges and possible solutions for futuristic applications of Li-ion battery packs in electric vehicles [J]. *Journal of Electrochemical Energy Conversion and Storage*, 2019, 16(4):. DOI:10.1115/1.4042987.
- [2] RAHIMI-EICHI H, OJHA U, BARONTI F, *et al.* Battery management system: an overview of its application in the smart grid and electric vehicles [J]. *IEEE Industrial Electronics Magazine*, 2013, 7(2):4—16.
- [3] NG K S, MOO C S, CHEN Y P, *et al.* State-of-charge estimation for lead-acid batteries based on dynamic open-circuit voltage[C]//2008 IEEE 2nd International Power and Energy Conference. Johor Bahru, Malaysia: IEEE, 2008:972—976.
- [4] DENG Z W, HU X S, LIN X K, *et al.* Data-driven state of charge estimation for lithium-ion battery packs based on Gaussian process regression [J]. *Energy*, 2020, 205:118000.
- [5] XIA B Z, SUN Z, ZHANG R F, *et al.* A comparative study of three improved algorithms based on particle filter algorithms in SOC estimation of lithium ion batteries [J]. *Energies*, 2017, 10(8):1149.
- [6] WAAG W, KAEBITZ S, SAUER D U. Experimental investigation of the lithium-ion battery impedance characteristic at various conditions and aging states and its influence on the application [J]. *Applied Energy*, 2013, 102:885—897.
- [7] DOYLE M, FULLER T F, NEWMAN J. Modeling of galvanostatic charge and discharge of the lithium/polymer/insertion cell [J]. *Journal of the Electrochemical Society*, 1993, 140(6):1526—1533.
- [8] PANG H, MOU L J, GUO L, *et al.* Parameter identification and systematic validation of an enhanced single-particle model with aging degradation physics for Li-ion batteries [J]. *Electrochimica Acta*, 2019, 307:474—487.
- [9] JIANG Y Y, ZHANG J, XIA L, *et al.* State of health estimation for lithium-ion battery using empirical degradation and error compensation models [J]. *IEEE Access*, 2020, 8:123858—123868.
- [10] 王萍, 张吉昂, 程泽. 基于最小二乘支持向量机误差补偿模型的锂离子电池健康状态估计方法 [J]. *电网技术*. <https://doi.org/10.13335/j.1000-3673.pst.2021.0045>.
- [11] GUO P Y, CHENG Z, YANG L. A data-driven remaining capacity estimation approach for lithium-ion batteries based on charging health feature extraction [J]. *Journal of Power Sources*, 2019, 412:442—450.
- [12] YUN Z H, QIN W H, SHI W P, *et al.* State-of-health prediction for lithium-ion batteries based on a novel hybrid approach [J]. *Energies*, 2020, 13(18):4858.
- [13] JIN G, MATTHEWS D E, ZHOU Z B. A Bayesian framework for on-line degradation assessment and residual life prediction of secondary batteries inspacecraft [J]. *Reliability Engineering & System Safety*, 2013, 113:7—20.
- [14] PATTIPATI B, SANKAVARAM C, PATTIPATI K. System identification and estimation framework for pivotal automotive battery management system characteristics [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2011, 41(6):869—884.
- [15] LONG B, XIAN W M, JIANG L, *et al.* An improved autoregressive model by particle swarm optimization for prognostics of lithium-ion batteries [J]. *Microelectronics Reliability*, 2013, 53(6):821—831.

- [16] WANG D, MIAO Q, PECHT M. Prognostics of lithium-ion batteries based on relevance vectors and a conditional three-parameter capacity degradation model [J]. *Journal of Power Sources*, 2013, 239: 253—264.
- [17] XING Y J, MA E W M, TSUI K L, *et al.* An ensemble model for predicting the remaining useful performance of lithium-ion batteries [J]. *Microelectronics Reliability*, 2013, 53(6): 811—820.
- [18] CHEN L, LIN W L, LI J Z, *et al.* Prediction of lithium-ion battery capacity with metabolic grey model [J]. *Energy*, 2016, 106: 662—672.
- [19] REZVANI M, ABUALI PHD M, LEE S, *et al.* A comparative analysis of techniques for electric vehicle battery prognostics and health management (PHM)[C]//SAE Technical Paper Series. Warrendale, PA, United States; SAE International, 2011.
- [20] LIU D T, ZHOU J B, LIAO H T, *et al.* A health indicator extraction and optimization framework for lithium-ion battery degradation modeling and prognostics [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2015, 45(6): 915—928.
- [21] PATTIPATI B, SANKAVARAM C, PATTIPATI K. System identification and estimation framework for pivotal automotive battery management system characteristics [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2011, 41(6): 869—884.
- [22] LIU J, SAXENA A, GOEBEL K, *et al.* An adaptive recurrent neural network for remaining useful life prediction of lithium-ion batteries [C]. *Proceedings of Annual Conference of the Prognostics and Health Management Society*, Portland, 2010.
- [23] 印学浩, 宋宇晨, 刘旺, 等. 基于多时间尺度的锂离子电池状态联合估计[J]. *仪器仪表学报*, 2018, 39(8): 118—126.
- YIN X H, SONG Y C, LIU W, *et al.* Multi-scale state joint estimation for lithium-ion battery [J]. *Chinese Journal of Scientific Instrument*, 2018, 39(8): 118—126. (In Chinese)
- [24] CHE Y B, LIU Y S, CHENG Z, *et al.* SOC and SOH identification method of Li-ion battery based on SWPSO-DRNN [J]. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 2021, 9(4): 4050—4061.
- [25] DONG G Z, CHEN Z H, WEI J W, *et al.* Battery health prognosis using Brownian motion modeling and particle filtering [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(11): 8646—8655.
- [26] LI P H, ZHANG Z J, XIONG Q Y, *et al.* State-of-health estimation and remaining useful life prediction for the lithium-ion battery based on a variant long short term memory neural network [J]. *Journal of Power Sources*, 2020, 459: 228069.
- [27] ABU-SHARKH S, DOERFFEL D. Rapid test and non-linear model characterisation of solid-state lithium-ion batteries [J]. *Journal of Power Sources*, 2004, 130(1/2): 266—274.
- [28] TIAN Y, XIA B Z, SUN W, *et al.* A modified model based state of charge estimation of power lithium-ion batteries using unscented Kalman filter [J]. *Journal of Power Sources*, 2014, 270: 619—626. 1225—1236.
- [29] LIU K L, HU X S, WEI Z B, *et al.* Modified Gaussian process regression models for cyclic capacity prediction of lithium-ion batteries [J]. *IEEE Transactions on Transportation Electrification*, 2019, 5(4): 1225—1236.
- [30] CHEN X K, LEI H, XIONG R, *et al.* A novel approach to reconstruct open circuit voltage for state of charge estimation of lithium ion batteries in electric vehicles [J]. *Applied Energy*, 2019, 255: 113758.
- [31] YO KOBAYASHI, HAJIME MIYASHIRO, ATSUKO YAMAZAKI, *et al.* Unexpected fade and recovery mechanism of LiFePO₄/graphite cells for grid operation [J]. *Journal of Power Sources*, 2020, 449: 227502—227510.