

DOI:10.19651/j.cnki.emt.2416769

锂电池剩余电量估算方法及应用研究综述^{*}

崔相东¹ 黄彦琪¹ 邬小玫^{1,2,3,4}

(1. 复旦大学信息科学与工程学院生物医学工程系 上海 200438; 2. 复旦大学工程与应用技术研究院 上海 200433;

3. 上海市医学图像处理与计算机辅助手术重点实验室(复旦)上海 200032; 4. 复旦大学义乌研究院 金华 322000)

摘要:为了全面展示锂电池剩余电量估算方法的研究进展,本文查阅了Web of science、知网、国家知识产权局等数据库中2013年以来的相关论文和专利,综述了锂电池剩余电量的主流估算方法。针对常用的直接估算的方法(安时积分法、开路电压法和阻抗表征)、基于等效电路模型的方法、基于电化学模型的方法和基于人工智能神经网络等的锂电池剩余电量估算方法,本文汇总了各方法的估计误差,结果为安时积分法的最大估计误差可达15%;开路电压法最大估计误差为12.4%;电化学阻抗谱法平均估计误差小于3.8%;卡尔曼滤波法的估计误差小于1%;粒子群滤波法的平均误差可小于1%;基于电化学模型的方法平均误差小于2%;基于神经网络的方法平均误差小于2%;多方法混合和多参数联合估计的方法最大误差小于5%,平均误差小于2.5%。结果表明,卡尔曼滤波法相较于直接估算的方法和其他基于模型的方法,精确度更高且更容易实现;基于神经网络的方法无需对电池模型进行分析即可获得较为准确的结果;多种方法混合使用和利用多种参量修正估算值的方法进一步提高了估算精度。本文还针对电动汽车以及植入式医疗电子设备对于剩余电量估算方法的需求,对比分析了各方法的估算精度、优点、难点及适用电池类型,阐明估算方法的具体应用方案,并展望估算方法在这两个领域的发展方向。本文可为相关领域的研究和从业人员提供全面、详实的锂电池剩余电量估算方法的研究现状及发展方向信息。

关键词:锂电池;SOC;电动汽车;植入式医疗电子设备

中图分类号: TN702 文献标识码: A 国家标准学科分类代码: 510

Overview of state-of-charge estimation methods and application for Lithium-ion batteries

Cui Xiangdong¹ Huang Yanqi¹ Wu Xiaomei^{1,2,3,4}

(1. Department of Biomedical Engineering, School of Information Science and Technology, Fudan University, Shanghai 200438, China; 2. Academy for Engineering and Technology, Fudan University, Shanghai 200433, China;

3. Key Laboratory of Medical Imaging Computing and Computer Assisted Intervention(MICCAI) of Shanghai, Fudan University, Shanghai 200032, China; 4. Yiwu Research Institute of Fudan University, Jinhua 322000, China)

Abstract: In order to comprehensively show the research progress of the residual power of Lithium-ion batteries, this paper reviewed the relevant papers and patents in the databases of Web of science, cnki, the patent library of the China National Intellectual Property Administration et al since 2013, and summarized the mainstream estimation methods of the residual power of Lithium-ion batteries. This article summarizes the estimation errors of commonly used direct estimation methods (ampere hour integration method, open circuit voltage method, and impedance characterization), methods based on equivalent circuit models, methods based on electrochemical models, and methods based on artificial intelligence neural networks for estimating the remaining battery capacity of Lithium-ion batteries. The results show that the maximum estimation error of ampere hour integration method can reach 15%; the maximum estimation error of the open circuit voltage method is 12.4%; the average estimation error of electrochemical impedance spectroscopy is less than 3.8%; the estimation error of kalman filtering method is less than 1%; the average error of particle swarm filtering method can be less than 1%; the average error of the method based on electrochemical model is less than 2%; the average error of neural network-based methods is less than 2%; the maximum error of the multi method mixing and multi parameter joint estimation method is less than 5%, and the average error is less than 2.5%. The results indicate that the kalman filter method has higher accuracy and is easier to implement compared to direct estimation methods and other model-based methods; the method based on neural networks can obtain more accurate results without analyzing the battery model; the mixed use of multiple methods and the use of multiple parameters to correct the estimated values have further improved the estimation accuracy. This article also compares and analyzes the estimation accuracy, advantages, difficulties, and applicable battery types of various methods for estimating remaining power in electric vehicles and implantable medical electronic devices. It clarifies the specific application plans of estimation methods and looks forward to the development direction of estimation methods in these two fields. This article can provide comprehensive and detailed information on the research status and development direction of Lithium-ion battery remaining capacity estimation methods for researchers and practitioners in related fields.

Keywords: Lithium-ion batteries; SOC; electric vehicles; implantable electronic medical devices

0 引言

锂电池凭借其高存储能量密度、长使用寿命、高安全性

和绿色环保等诸多优势,在电子设备中得到了非常广泛的应用。电子设备的电池管理系统(battery management system, BMS)对电池剩余电量的准确估算,关系着设备能

否安全可靠地工作。比如:电动汽车在低电量时将调节为低输出功率模式,防止车辆中途抛锚,对电量误判可能导致动力不足或中途抛锚等问题,充电时对电量误判可能因过充对电池造成损伤;心脏起搏器需要准确的剩余电量估计,以便在电量耗尽前提醒医生/患者更换设备,否则会影响患者的生命安全。因此,锂电池的剩余电量估算一直是电子设备电池管理系统的重要研究课题之一。

电池剩余电量可由荷电状态(state of charge, SOC)表示;SOC 指在一定放电倍率下,电池剩余的电量与电池总容量的比值,取值为 0~1。

近几年,电动汽车(electric vehicles, EVs)制造等行业的兴起促进了电池 SOC 估算相关领域的研究,锂电池 SOC 的估算方法向多元化发展^[1-2],也出现了许多综述 SOC 估算方法的文章。文献[3]归纳描述各类 SOC 估算方法,分析了各方法优劣;文献[4]详细说明了一些 SOC 估算方法的数学原理;文献[5]介绍了 SOC 领域的新研究成果。但这些文献仅对一些方法做出粗略表述,对于如何将这些方

法用于估算、精度具体如何、可应用场景等问题很少涉猎。本文在查阅 Web of science、中国知网、国家知识产权局等数据库的 80 余篇相关论文(79% 的文献来源于 2019 年之后的研究)和专利的基础上,对目前锂电池剩余电量的各估算方法做出更细致、全面的分类,详细介绍了锂电池剩余电量估算的主流方法以及各方法的估算精度,分析比较了各类方法的优劣,总结出各类方法的应用场景和应用方案。最后,以电动汽车和植入式医疗电子设备为例介绍了锂电池剩余电量估计的应用并给出建议,并展望该领域的发展方向。

1 SOC 估算方法

图 1 为锂电池 SOC 估算方法分类。SOC 估算方法分为五大类:直接的方法(包括安时积分法、开路电压法和阻抗表征法)、基于等效电路模型的方法、基于电化学模型的方法、基于人工智能的方法和多参量联合估算的方法。这些方法都需要先测量电池的电压电流数据再进行估算。

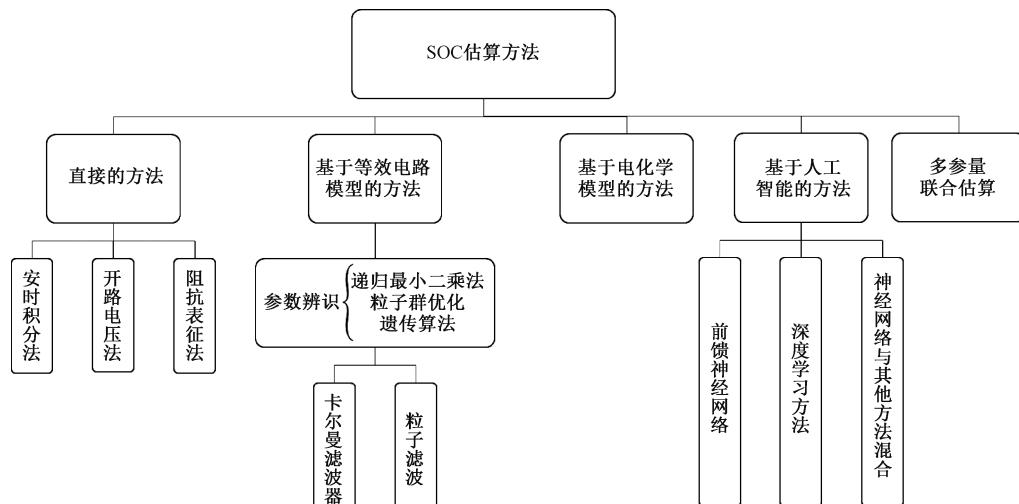


图 1 SOC 估算方法分类

Fig. 1 Classification of SOC estimation methods

表 1 所列为评价 SOC 估算精度的常用指标,有最大误差(maximum absolute errors, MAEs)、平均误差(mean absolute error, MAE) 和 均方根误差(root mean square errors, RMSEs)。

表 1 评价估算精度的主要指标

Table 1 Indicators for estimating accuracy

误差表示方法	数学表达式
最大误差	$\text{Max} Error $
平均误差	$\frac{1}{M} \sum_{k=1}^M Error $
均方根误差	$\sqrt{\frac{1}{M} \sum_{k=1}^M (Error)^2}$

其中,误差 $Error = (\text{测量值} - \text{估算值}) / \text{测量值} \times 100\%$, M 为估算总次数, k 为某次估算次序。

直接估算的方法为第一类方法,包括安时积分法、开路电压法和阻抗表征法,该类方法使用测量的电流、电压和阻抗值直接表征 SOC 值。安时积分法是直接按照 SOC 的定义来估算的方法。开路电压法和阻抗表征法则需建立电池的开路电压、阻抗与电池 SOC 的关系,以此来直接表征电池剩余电量。这种直接表征的方法受噪声影响大,精度低,对于要求电池剩余电量估算精度较高的电子设备来说难以满足需求。

之后的基于等效电路模型的方法聚焦于滤除这些直接估算方法中的噪声,以期更精确地估算 SOC;如采用卡尔曼滤波器(Kalman filters, KF)和粒子滤波(particle filter, PF)等方法滤除噪声。在较长的一段时间内,相关

研究在这些方法的基础上进行改进,特别是在 KF 的方法中,解决了滤波过程中系统非线性和协方差矩阵负定等问题^[6]。

电化学模型从离子的浓度分布和转移出发,根据电池内部的电化学和动力学行为估算 SOC;比等效电路模型更精确,但更复杂,需要大量计算,对算力有较高要求。

人工智能领域的发展,也为电池 SOC 估算带来新的方案。神经网络通过离线学习测得的电池参数(如电压、电阻和温度等)与 SOC 的映射关系建立模型,估算时输入电池参数即可实时获取 SOC 值。其精度和鲁棒性都有很好的表现。近几年的研究还将神经网络与基于等效电路模型的方法或基于电化学模型的方法相结合,进一步提高了电池 SOC 的估算精度。

随着电池的老化和环境温度的变化,电池的容量、内阻和极化电容等参数会随之变化。根据 SOC 的定义,电池总容量的变化会影响 SOC 值;电池内阻和极化电容等电池参数的变化将影响电池模型的精度,若忽略这些因素则会造成计算误差。因此,很多研究考虑温度变化和电池老化情况,在不同温度条件下进行 SOC 估算,估计电池老化带来的容量变化,并对 SOC 进行修正。联合估计温度和容量变化以修正 SOC 估算结果的多参量联合估算的方法,也是提高 SOC 估算精度的有效途径之一。

2 直接估算方法

2.1 安时积分法

锂电池当前的 SOC_t 为电池的初始 SOC_0 值加上电池一段时间内增减的 SOC 值,如式(1)所示。

$$SOC_t = SOC_0 + \int_0^t \frac{i(t)}{C} dt \quad (1)$$

式中: $i(t)$ 为电池充/放电电流, C 为电池的总容量。 $i(t)$ 在时间段 t 内的积分表示电池的充/放电电量,即在该时间段内增减的 SOC 值;充电为正值,放电为负值。

安时积分法^[7]是按照定义进行 SOC 估算的方法。安时积分法需定时测量电池的充放电电流,将每次测量的电流作为这一小段时间内的恒定电流,乘以间隔时间得到这一小段时间内的充放电电量,累加获得一段时间内的总充放电电量,除以电池总容量得到电池 SOC 的总变化值,加上初始 SOC 值即可获得电池 SOC 的估算值^[8-9]。

安时积分法的误差来源于 $i(t)$ 和 C 的估测。式(1)中的 $i(t)$ 通常为电池充/放电电流的采样值,将该采样值作为采样间隔时间内的恒定电流计算会产生误差,误差大小与采样间隔时间和电流变化速度正相关。同时, $i(t)$ 的测量还会受到噪声的干扰而产生误差。另外,锂电池的总容量 C 会随电池的使用慢慢下降。而安时积分法通常默认 C 不变,随着电池的消耗,所带来的误差会不断增加。

Mohammadi 等^[7]提出了增强的安时积分法。该方法增加两个误差因子对测量电流进行修正,如式(2)所示。

$$I(t) = i(t) + \epsilon_M(t) + \epsilon_I(t) \quad (2)$$

其中, $I(t)$ 为测量电流, $i(t)$ 为电池的实际充放电电流, $\epsilon_M(t)$ 和 $\epsilon_I(t)$ 分别为测量误差因子和计算误差因子。误差因子由电池容量估算获得。

对于安时积分法受噪声和 C 影响的问题,可以分别使用滤波器以及实时估算 C 值的方法解决。此类方法将在第 3 和 6 节中介绍。

2.2 开路电压法

锂电池的 SOC 与电池的开路电压(open circuit voltage, OCV)一一对应且基本保持单调。若已知 OCV-SOC 的对应关系,测量 OCV 值即可查表获得 SOC。图 2 展示了使用充放电实验获取的数据建立的锂电池 OCV-SOC 的关系^[10]。

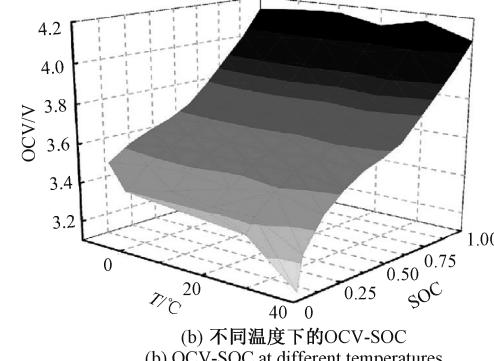
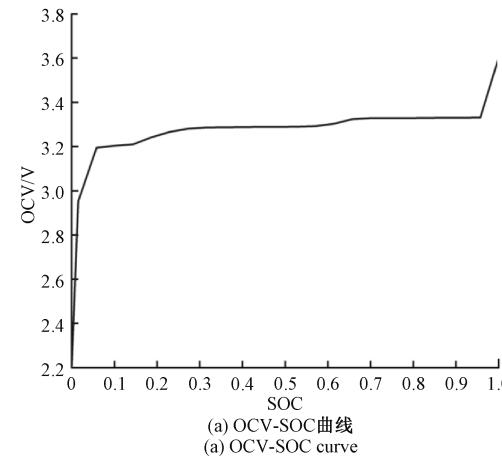


图 2 OCV-SOC 对应关系^[10]

Fig. 2 The relationship between OCV and SOC

从图 2(a) 中可知,在 SOC 值为 0.1~0.9 之间时, OCV 上升比较缓慢,这意味着获取的 OCV 值稍有误差,就会导致 SOC 估计出现很大偏差,而 OCV 的测量误差又是很难避免的。因此,只根据电池 OCV 来估计 SOC 值的误差较大。同时,锂电池的 OCV 获取需要静置较长时间(多则两小时),在实际工况下可能无法为了估算 SOC 而较长时间静置电池。

2.3 阻抗表征和电化学阻抗谱法

电池的阻抗同样可以用于表征 SOC 值。图 3 为锂电

池欧姆内阻和极化内阻与 SOC 的关系。通过电池脉冲充放电实验^[11]获得的数据可估算出电池的欧姆内阻 R_o , 从图 3 可见 R_o 在 SOC 范围内较稳定, 而极化内阻有比较明显的变化; 其中 R_o 与 SOC 的关系在一定的温度范围内具有单调性, 可以用于表征 SOC。

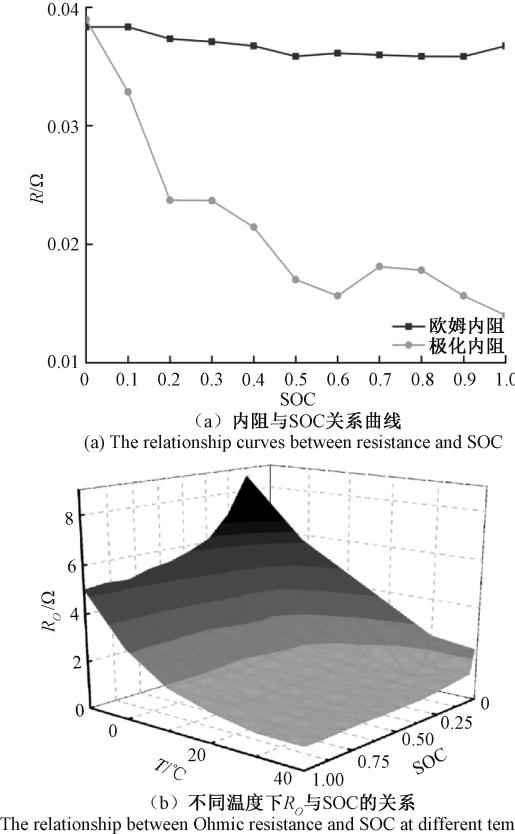
图 3 内阻与 SOC 的关系^[10]

Fig. 3 The relationship between resistance and SOC

电化学阻抗谱法^[12] (electrochemical impedance spectroscopy, EIS) 常用于估算电池内阻。对于一个电路系统, 输入一个正弦信号 S , 将产生响应信号 P , 由二者的关系可以得到电路的阻抗或导纳 $G(\omega)$, 如式(3)所示。

$$P = G(\omega) \cdot S \quad (3)$$

当输入信号为电流信号, 输出信号为电压信号时, 得到的 $G(\omega)$ 为电路阻抗, 反之则为导纳。在电池充放电时, 输入正弦电流信号 $i(t)$, 得到电压响应信号 $v(t)$, 则电池阻抗 $Z_{in}(f)$ 为:

$$Z_{in}(f) = \frac{v(t)}{i(t)} = \frac{V_{\max}}{I_{\max}} e^{j\varphi} \quad (4)$$

其中, f 为输入信号频率, V_{\max} 和 I_{\max} 为信号幅值, φ 为信号经过电池后相角的偏移量。 $Z_{in}(f)$ 在低频时表示为电池活性材料内部的扩散过程, 中频表示双层电容效应, 高频部分可获得电池的欧姆内阻。获得欧姆内阻后, 若已知欧姆内阻与 SOC 的对应关系表, 查表即可获得 SOC 值。

EIS 方法估算 SOC 受温度变化影响较大, 低温和高温

时(低于 0 ℃ 和高于 20 ℃)平均误差 MAE 低于 4.9%, 温度在 0 ℃ ~ 20 ℃ 时总体平均误差低于 7%, 最大误差 MAEs 达到 17.5%^[13]。对于 SOC 估算, 需考虑电池 SOC 与内阻是否具备较好的对应关系, 否则 EIS 方法的误差较大, 精度要求较高的情况下无法使用该方法。

锂电池的内阻与电池容量具有更好的对应关系, 电池容量变化由电池剩余寿命(state of health, SOH)表示, EIS 方法估算 SOH 更为准确^[14]。目前 EIS 方法常用作估算 SOH, 再由 SOH 修正 SOC 的估计值, 进一步提高 SOC 估算精度。

3 基于等效电路模型的方法

由直接的方法可知, 测量电池的充放电电压、电流和电阻, 可以获得电池 SOC 的估算值, 但此估算值误差较大, 难以直接使用。想要降低估算误差、提高估算精度, 可以使用滤波器对估算值进行降噪。滤波器的实现需要电池的状态方程, 获取状态方程则需要建立电池模型。

等效电路模型^[15] (equivalent circuit model, ECM) 作为经典的电路模型, 常用于模拟锂电池的电学表现。基于等效电路模型的 SOC 估算方法流程如图 4 所示。在测量电池的电压和电流值后, 由直接的方法可以得到估计的 SOC 值, 随后通过递归最小二乘法(recursive least square, RLS)、粒子群优化(particle swarm optimization, PSO)、遗传算法(genetic algorithm, GA) 等方法获得锂电池的欧姆内阻、极化电阻和极化电容等参数(参数辨识过程), 建立电池的等效电路模型; 之后, 便可使用 KF、PF 等方法降低 SOC 的估计误差。

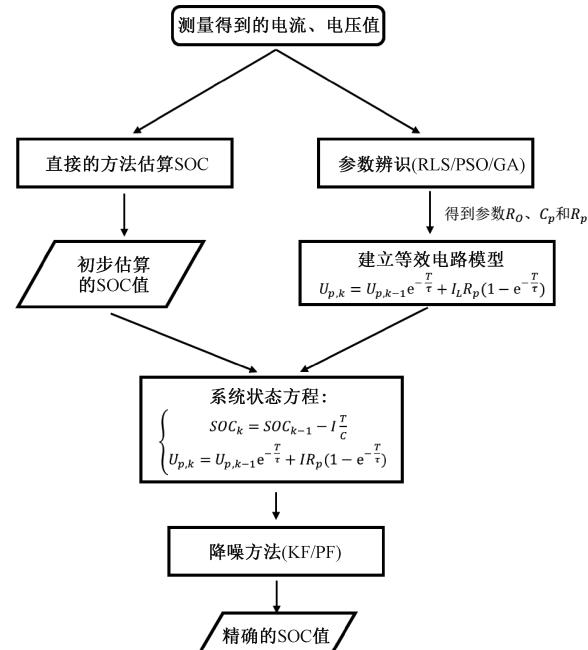


图 4 基于等效电路模型的估算方法

Fig. 4 Estimation method based on equivalent circuit model

锂电池状态分析中常用的等效电路模型有 Thevenin 等效电路模型^[16]和二阶 RC 等效电路模型^[17-18]。经典的 Thevenin 模型如图 5(a)所示,将电池模型简化为一个理想电压源 U_{oc} 、一个欧姆内阻 R_o 和一个 RC 电路(R_p 为极化内阻, C_p 为极化电容)的组合,电池充放电电流为 I 。Thevenin 模型可以有效地反映电池极化现象和欧姆极化现象,精度不高但参数获取简便,因此被广泛应用于锂电池的状态估计中。

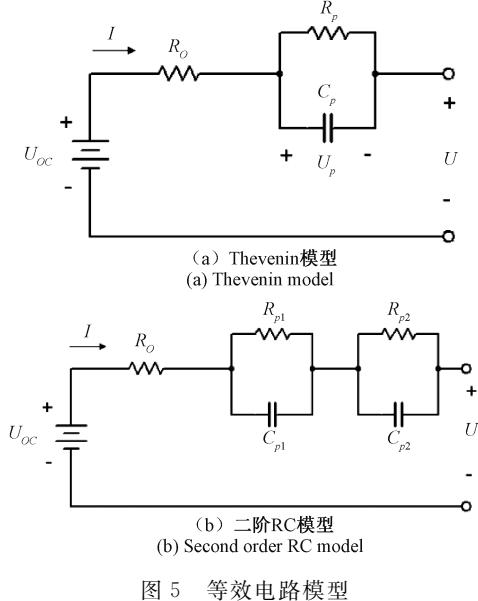


图 5 等效电路模型

Fig. 5 Equivalent circuit models

在 Thevenin 等效电路中,根据等效电路和 RC 电路充放电特性,RC 电路两端的极化电压 U_p 和端电压 U 可由式(5)和(6)表示:

$$\frac{dU_p}{dt} = -\frac{U_p}{C_p R_p} + \frac{I}{C_p} \quad (5)$$

$$U = U_{oc} - U_p - IR_o \quad (6)$$

解微分方程式(5),得极化电压表达式(7),其中 K 为待定常数。

$$U_p = Ke^{-\frac{t}{C_p R_p}} + IR_p \quad (7)$$

令 $t=0$ 时 $U_p=U_{p,k-1}$, $t=T$ 时 $U_p=U_{p,k}$, k 为任意采样时刻, T 为两次采样间隔, 则极化电压经过时间间隔 T 的递推方程如式(8)(其中 $\tau=C_p R_p$):

$$U_{p,k} = U_{p,k-1} e^{-\frac{T}{\tau}} + IR_p (1 - e^{-\frac{T}{\tau}}) \quad (8)$$

式(6)和(8)结合为 Thevenin 等效电路模型:

$$\begin{cases} U_{p,k} = U_{p,k-1} e^{-\frac{T}{\tau}} + IR_p (1 - e^{-\frac{T}{\tau}}) \\ U = U_{oc} - U_p - IR_o \end{cases} \quad (9)$$

其中, R_o 、 R_p 、 C_p 和 τ 由电池放电现象分析或参数辨识获得。

如图 5(b)所示,二阶 RC 等效电路模型比起 Thevenin

模型多了一组 RC 电路以表征电池的电化学极化和浓差极化现象。其对电池充放电过程的描述更加准确,精度更高,但计算量也随之增加。在二阶 RC 模型中 C_{p2} 与 C_{p1} 往往相差较大,因此 $\tau = R_p C_p$ 大小相差较大^[19],导致二阶 RC 对于 SOC 估算精度的提升不多,而更高阶的模型对于精度的提升更加不明显,只是徒增计算量。因此,上述的 Thevenin 模型和二阶 RC 模型是较为常用的等效电路模型。

3.1 参数辨识方法

在基于等效电路模型的 SOC 估算方法中,以 Thevenin 模型为例,需要计算电池的欧姆内阻 R_o 、极化内阻 R_p 和极化电容 C_p 等参数来建立式(9)所示模型。参数辨识就是使用某些方法从测量的电路电流电压等数据中估计出模型参数的过程^[20-24]。

欧姆内阻 R_o 可由电池放电时的瞬间压降获得,极化内阻 R_p 和极化电容 C_p 可由电池充放电开始和结束时的电压变化过程(极化现象)获得^[25]。电池实际放电过程以持续放电为主,放电中途一般不发生极化现象,而这些参数需要实时获得以估算 SOC,因此需在充放电过程中从电池系统中辨识这些参数。这里以 Thevenin 等效电路为例介绍如何对电池参数进行辨识。Thevenin 等效电路在 s 域的传递函数 $G(s)$ 为:

$$G(s) = \frac{R_p}{1 + sR_p C_p} + R_o \quad (10)$$

离散化,得 k 时刻的电路开路电压 $U(k)$ 如式(11):

$$U(k) = -cU(k-1) + aI(k) + bI(k-1) + U_{oc}(k) \quad (11)$$

其中,

$$\begin{cases} R_o = a \\ R_p = \frac{b-ac}{1+c} \\ C_p = \frac{T}{b-ac} \end{cases} \quad (12)$$

根据式(11),测量 3 个不同时刻的电池端电压 U_{oc} 、开路电压和电流,即可计算出 a,b,c ,进而根据式(12)辨识出参数 R_o 、 R_p 和 C_p 。

这些参数在不同电池中是不同的,即使是同一型号的不同电池个体的参数仍有所不同,在估算中使用固定参数会导致较大误差。同时,受电池老化和温度等因素影响,电池参数在充放电过程中也会发生变化,需要不断更新^[20]。并且,在实时估算过程中需要的开路电压数据也需要由测量数据辨识得到。因此要求参数估计方法能够实现动态计算,下面介绍几种常用的参数估计方法,这些方法在基于电化学模型或神经网络的方法中同样可以使用。

1) 递归最小二乘法 RLS

在已知一组观测数据的情况下,RLS^[26]实现损失函数平方最小,是动态估计参数最好的方法之一,常用来估计

电池动态模型参数。基本的最小二乘法 (least squares method, LS) 其估计方法如式(13)~(18) 所示。

由式(11)可知, Thevenin 模型中需要辨识的参数 $\hat{\theta} = [a \ b \ c \ 1]$, 令 $Y = U(k)$, $X = [I(k) \ I(k-1) \ -U(k-1) \ U_{oc}(k)]^T$, 则式(11)可表示为矩阵形式:

$$Y = \hat{\theta}X \quad (13)$$

由最小二乘法估计:

$$\hat{\theta} = (X^T X)^{-1} \cdot X^T Y = R^{-1} \cdot Q \quad (14)$$

其中, $R = X^T X$, $Q = X^T Y$ 。

如果参数是动态变化的, 即不断产生新的数据, 需要根据式(14)不断进行矩阵求逆。由于逆矩阵的计算量巨大, 且矩阵尺寸随新数据加入不断增大, 该方法的计算复杂度将大大增加。

RLS 针对观测数据不断增加的情况进行改进^[27], 根据分块矩阵的计算方法, 新的矩阵可表示为:

$$R' = \lambda R + x_{n+1} x_{n+1}^T \quad (15)$$

其中 λ 为加入的遗忘因子, 以减少旧数据的权重, x_{n+1} 和 y_{n+1} 为新加入的数据, 通常可令:

$$\lambda = 1 - \frac{1}{N} \quad (16)$$

$$k = \frac{R^{-1} x_{n+1}}{\lambda + x_{n+1}^T R^{-1} x_{n+1}} \quad (17)$$

推导可得:

$$\hat{\theta}' = \hat{\theta} - k(x_{n+1}^T \hat{\theta} - y_{n+1}) \quad (18)$$

在 RLS 中设置的遗忘因子 λ 值越小, 遗忘旧数据的速度越快, 当系统的新旧数据变化很小时, 协方差矩阵可能无法收敛而不能计算。Rozaqi 等^[28] 使用多个遗忘因子解决这一问题, 并用 GA 来决定遗忘因子的大小, 解决数学问题的同时提高了估算精度。

动态估计 SOC 时, 使用 RLS 估计出电池模型参数后, 通常进一步使用 KF 等方法更新电池 SOC 并降低噪声。

2) 遗传算法 GA

GA^[29-32] 同样可以用于参数估计问题, 缺点是时间成本较高, 容易陷入局部最优解。GA 模拟自然选择和生物进化过程, 利用遗传算子对群体进行选择、交叉和变异, 不断进行迭代更新, 直到更新结果收敛于设置的终止条件。

选择: 通过适应度优胜劣汰、适者生存, 将最优的个体选择出来, 用于下一次的遗传交叉变异;

交叉: 将个体交叉融合, 诞生出更优子代个体, 促使子代向最优解进化;

变异: 通过变异概率判断个体是否变异, 对需要进行变异的个体进行基因改动, 恢复个体曾拥有的遗传信息或增加新的基因, 可使得算法具有局部随机搜索能力, 并且尽可能防止算法提前收敛。

通过设置收敛条件, 可以得到合适的估计结果。

例如, 利用 GA 对 Thevenin 模型中需要的参数 U_{oc} 、

R_o 、 R_p 和 C_p 进行辨识时^[29], 可先初始化多组不同的参数值满足电路模型式(9), 设定适应度函数(可根据情况灵活选用)评估参数适应度:

$$F_f = \frac{\alpha_{GA}}{(U_{oc}^* - \hat{U}_{oc})^2} + \frac{(1 - \alpha_{GA})}{(R_o^* - \hat{R}_o)^2} \quad (19)$$

其中, α_{GA} 为 0~1 的系数, \hat{U}_{oc} 和 \hat{R}_o 为安时积分法得到的 SOC 值查表获得的开路电压值和欧姆内阻值, U_{oc}^* 和 R_o^* 为初始化的一组参数值, 适应度越高, 该组参数表现越好。

随后进行交叉变异^[30], 设定交叉系数 $\alpha_{crossover}$, 需要交叉的个体之间可两两进行交叉产生子代, 比如两组参数中的欧姆内阻 R_o^a 和 R_o^j :

$$R_o^{a*} = \alpha_{crossover} R_o^a + (1 - \alpha_{crossover}) R_o^j \quad (20)$$

$$R_o^{j*} = \alpha_{crossover} R_o^j + (1 - \alpha_{crossover}) R_o^a \quad (21)$$

变异过程可设定服从高斯分布的变异系数 $\alpha_{mutation}$, 根据变异概率选定需要变异的个体进行变异, 比如某组参数中的欧姆内阻值变异:

$$R_o^* = R_o + \alpha_{mutation} \quad (22)$$

然后利用适应度函数评估子代适应性, 选择出优质个体再次进行交叉变异, 不断重复此过程直至收敛, 得到最优参数估计。

GA 适应性强, 不仅可以辨识等效电路模型参数, 还可以用于其他问题的参数估计, 其在基于电化学模型、基于神经网络和其他估算方法中仍可发挥作用。

3) 粒子群优化 PSO

PSO^[33] 算法同 GA 一样都是全局优化算法, 可以解决参数估计问题, 实现较容易, 对于同一问题比 GA 的计算量小六倍以上。PSO 算法是对鸟群飞行的现象进行研究得到的。PSO 算法通过初始化各种随机粒子(各种解), 赋予粒子位置与速度, 获得最优解的过程就是找到最优粒子的过程。PSO 算法同样引入适应度, 将每个粒子与最好的粒子相比较, 如果该粒子更好则更新最优粒子, 同时更新每个粒子的位置和速度, 使每个粒子都向最优粒子的位置行进^[34]。

速度和位置更新方程为:

$$v^{k+1} = v^k + c\alpha_{ps} (x_{best}^k - x^k) \quad (23)$$

$$x^{k+1} = x^k + v^{k+1} \quad (24)$$

其中, c 为加速系数, α_{ps} 是值为 0~1 的系数。每个粒子通过式(23)、(24)不断行进, 最后收敛于最优解。

PSO 算法用于等效电路模型辨识过程时, 粒子 x^k 可以是待估参数 U_{oc} 、 R_o 、 R_p 和 C_p , 适应度函数可使用 GA 所使用的式(19), 整体计算量较少, 容易实现。

PSO 算法适于解决连续优化问题, 计算简便, 可用于计算并更新 SOC 估计过程中的参数或某些待定系数, 是一个用于参数估计的便捷手段。

3.2 滤波器

通过参数辨识获取锂电池等效电路模型中的相关参

数之后,可以使用滤波器的方法对直接方法初步估算得到的电池 SOC 值进行降噪。

1) 卡尔曼滤波器 KF

KF 是该领域最常用、也是最便利的方法之一。KF 擅长处理线性系统中的高斯噪声,是一种常用的状态观测器。从 2009~2018 年,SOC 估算相关研究中 KF 方法占 40%,除 KF 以外的观测器方法占 7%,其他的方法包括 PF 和神经网络等方法总共占 53%^[3]。2019 年之后,锂电池 SOC 估算研究中的 54% 使用了 KF(统计数据来源于 IEEE)。

KF 仅使用 5 个计算公式,便可以对系统状态进行优化,其计算效率高,便于软件实现,且不需要存储过去的计算数据,非常适合 SOC 估算。

离散系统状态方程和观测方程可由式(25)表示,其中 \mathbf{X}_k 为系统输入值, Z_k 为系统输出值, \mathbf{A}, \mathbf{B} 为参数辨识获得的系统参数矩阵, \mathbf{H} 为传递矩阵, $\mathbf{W}_k, \mathbf{V}_k$ 为系统过程噪声和观测噪声。

$$\begin{cases} \mathbf{X}_k = \mathbf{AX}_{k-1} + \mathbf{B} + \mathbf{W}_k \\ Z_k = \mathbf{HX}_k + \mathbf{V}_k \end{cases} \quad (25)$$

KF 进行最优化估计遵循式(26)~(30), \mathbf{Q} 和 \mathbf{R} 分别为系统噪声和观测噪声协方差:

先利用上一状态预测下一状态:

$$\hat{\mathbf{X}}_k^- = \mathbf{A}\hat{\mathbf{X}}_{k-1} + \mathbf{B} \quad (26)$$

计算协方差:

$$\mathbf{P}_k^- = \mathbf{AP}_{k-1}\mathbf{A}^T + \mathbf{Q} \quad (27)$$

计算卡尔曼增益:

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{HP}_k^- \mathbf{H}^T + \mathbf{R})^{-1} \quad (28)$$

得到下一状态的最优结果:

$$\hat{\mathbf{X}}_k = \hat{\mathbf{X}}_k^- + \mathbf{K}_k (Z_k - \mathbf{H}\hat{\mathbf{X}}_k^-) \quad (29)$$

更新下一状态的协方差:

$$\mathbf{P}_k = (\mathbf{E} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^- \quad (30)$$

其中, \mathbf{E} 为单位矩阵, 式(28)计算得出的卡尔曼增益反映了由系统方程递推结果与观测结果的可信度; 式(29)为 KF 的优化过程, Z_k 为观测值, $\mathbf{H}\hat{\mathbf{X}}_k$ 是由系统状态方程对 Z_k 的估计值, 二者相减得到观测前后的信息差, 乘以卡尔曼增益得到修正值, 修正值加上由系统状态方程递推估计的输出值, 即可得到最优化输出值。

在估算电池 SOC 的 KF 中^[35], 系统状态方程由等效电路模型式(8)和 SOC 计算式(1)组合而成, 其矩阵表示为:

$$\begin{bmatrix} U_{p,k} \\ SOC_k \end{bmatrix} = \begin{bmatrix} e^{-\frac{T}{\tau}} & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} U_{p,k-1} \\ SOC_{k-1} \end{bmatrix} + \begin{bmatrix} (1 - e^{-\frac{T}{\tau}}) R_p \\ -\frac{T}{C} \end{bmatrix} I \quad (31)$$

其中, T 为时间间隔, τ 为 RC 环节时间参数, R_o, R_p

和 C_p 由参数辨识得到。

观测方程使用测量得到的端电压值, 如式(32):

$$U = \begin{bmatrix} -1 & \frac{dU_{oc}}{dZ} \end{bmatrix} \begin{bmatrix} U_{p,k} \\ Z_k \end{bmatrix} - IR_o \quad (32)$$

其中, $\frac{dU_{oc}}{dZ}$ 可由图 2(a)所示的 OCV-SOC 的关系曲线得到。

式(31)由电路方程和安时积分法递推出下一时刻端电压和 SOC 值的估计值, 带入式(32)中得到端电压的估计值, 观测得到的端电压值与估计的端电压相减得到观测信息差, 乘以卡尔曼增益得到对输出值的修正值, KF 的作用因此得以实现。KF 对直接方法初步估算的 SOC 结果进行降噪, 因此 KF 的精度将高于安时积分法。仅使用 KF 进行 SOC 估算最大误差 MAEs 大约为 3%。KF 相关的研究着力于解决滤波过程中遇到的数学问题和提高估算精度^[3]。如线性卡尔曼滤波(linear Kalman filter, LKF)使用时域线性动态方程作为系统输入方程, 解决了电池系统非线性的问题, 能够限制最小均方误差; 扩展卡尔曼滤波(extended Kalman filter, EKF)是 LKF 的非线性版本, 使用泰勒级数展开系统方程从而使系统方程线性化, 有效地减少了由于初始 SOC 值不准确而带来的误差; EKF 因其假设测量值和过程噪声的协方差为一固定值, 降低了估算的精度, 自适应扩展卡尔曼滤波(adaptive extended Kalman filter, AEKF)^[36]通过更新迭代协方差矩阵解决了这一问题, 提高估计稳定性; 无迹卡尔曼滤波(unscattered Kalman filter, UKF)使用无迹变换的方法, 避免了 EKF 时使用非线性方程的线性化 Jacobi 矩阵, 其在初始 SOC 未知时具有高精度、鲁棒性和收敛性。

近年来基于 KF 的 SOC 估计方法仍有新改进方法提出, 改进后的 KF 方法的估算最大误差可低于 1%。Jiang 等^[10]使用自适应的矩阵根分解方法, 保证了 KF 计算时协方差矩阵的非负定; He 等^[37]建立分数阶等效模型, 使用中心差分 KF 估计 SOC, 其对噪声具有很好的鲁棒性; Shrivastava 等^[38]提出基于双遗忘因子的 AEKF 用以更新电路模型状态参数, 在错误的初始条件下也能估算出真实 SOC 值; 华菁等^[39]采用带时变遗忘因子的递推最小二乘法进行参数辨识, 并使用自适应容积卡尔曼滤波器(adaptive cubature kalman filter, ACKF)进行 SOC 估算, 其估算最大误差在不同工况下小于 1.5%; 邢丽坤等^[40]采用最小二乘法辨识二阶 RC 模型参数, 结合 UKF 估计 SOC 值, 估算平均误差控制在 1.08% 左右。

改进的 KF 方法已逐步完善, 新的相关研究趋向于将 KF 与其他方法结合, 或加入其他参量联合估计, 以提高估算精度, 这些方法会在后文介绍。

2) 粒子滤波器 PF

KF 能够很好地滤除线性系统中的高斯噪声, 但对于其他类型的噪声效果欠佳。PF 的方法不受噪声类型的限

制,且可以直接用于非线性系统的分析。PF 算法使用的系统状态方程和观测方程与 KF 同为式(31)和(32),系统方程都由安时积分和电路模型方程组成,因此也是对安时积分的结果进行降噪。PF 使用粒子的概率分布来估计结果,计算出系统的先验概率密度,通过贝叶斯理论可得到后验概率密度,根据蒙特卡洛原理简化并计算出粒子的权值,并更新系统状态^[41]。PF 计算过程中会遇到粒子退化问题,可以使用重采样的方法消除权重小的粒子,保留权重大的粒子,并将权重大的粒子均匀分布以解决粒子退化问题。基本的 PF 估算 SOC 的过程如下:

$$\text{令 } k \text{ 时刻系统状态值为 } x_k = \begin{bmatrix} U_{p,k} \\ SOC_k \end{bmatrix}, y_k \text{ 为由}$$

式(31)、(32)计算得到的 x_k 的观测值。因为状态真值在观测值附近,为状态值加上高斯噪声形成粒子群 $\{x_k^i | i = 1, 2, \dots, N\}$, 随之得到观测值粒子群 $\{y_k^i | i = 1, 2, \dots, N\}$, 其中, N 为生成的粒子数。

粒子的权值计算可由式(33)决定(类似于式(19),用于评估粒子适应度,可自行设计),其中 σ 为观测噪声标准差:

$$q_k^i = \left(\frac{1}{\sqrt{2\pi}\sigma} \right) e^{-\frac{(y_k^i - x_k^i)^2}{2\sigma^2}} \quad (33)$$

归一化后得到:

$$q_k^i = \frac{q_k^i}{\sum_{i=1}^N q_k^i} \quad (34)$$

输出预测值:

$$\hat{x}_k = \sum_{i=1}^N x_k^i q_k^i \quad (35)$$

式(33)既评价了粒子的适应度,也给出了该粒子在输出值中所占比例,每个粒子的值乘此权值再求和,取长补短,得到 PF 的最优估计值。

PF 估算 SOC 的计算复杂度较高,需要其他方法协助解决粒子退化和粒子多样性匮乏等问题。如郑超逸等^[29]引入 GA 思想解决粒子退化问题,使用蚁群算法理论增加粒子多样性,估算 SOC 的最大误差 MAEs 降至 0.89%;Xu 等^[42]使用 PSO 算法替代粒子重采样,估算 SOC 的最大误差 MAEs 降低到 1% 左右。

4 基于电化学模型的方法

4.1 P2D 模型

等效电路模型能够从电池的电学表现宏观地描述电池的电学特性,但尚不能准确反映电池内部的极化等现象;使用更高阶的电路模型增加了计算量,但对模型的修正帮助很少。电化学模型(electrochemical model, EM)^[43]从电池内部离子转移和分布出发,详细描述了电池的各项特性,为 SOC 估计提供了更详细的依据。为了对锂电池整体结构和功能进行模拟,Doyle 和 Newman 设计出了锂电

池的准二维电化学模型(pseudo-two-dimensions, P2D),如图 6 所示。P2D 模型遵循如表 2 中所示的固相和液相的电荷及质量守恒方程,以及电极电化学反应动力学方程^[44],可准确描述锂离子电池电化学行为,能够很好反映电池内部应力、浓度分布、荷电状态以及电极极化等特性,计算精度高。其中, x 为电极厚度方向, r 为电极粒径方向, c_s 为电极锂离子浓度, c_e 为液相锂离子浓度, D_{eff} 为液相有效扩散系数, φ_s 为固相电势, σ^{eff} 为固相有效导电率, κ^{eff} 为液相浓度函数, ϵ_e 为液相体积分数, F 为法拉第常数, j^{Li} 为锂离子摩尔通量, t_+^0 为锂离子迁移数, R_f 为隔膜阻抗。

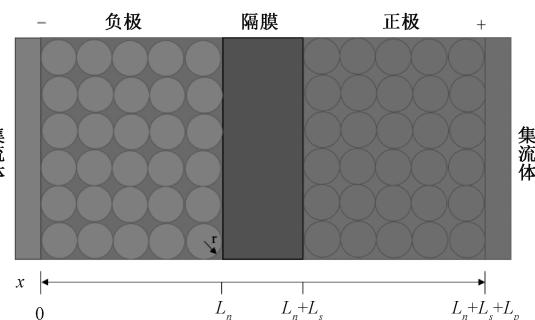


图 6 锂电池 P2D 模型

Fig. 6 Lithium-ion batteries P2D model

如表 2 所示,P2D 模型需要求解大量微分方程,计算量大,在动态工况中难以使用。后续相关研究提出大量简化 P2D 模型计算,同时保持其模拟精度不下降的方法;代表性的简化模型有单粒子(single particle, SP)模型、增强单粒子(enhanced single particle, ESP)模型及多物理耦合(multiphysical-coupling, MC)模型。这些简化模型显著提高了 P2D 模型参数的求解速度。根据实际需要,还能够对这些简化模型作进一步简化,如:庞辉^[45]基于扩展的物理电化学模型相关假设提出的简化 P2D 模型(simplified pseudo-two-dimensions, SP2D),减少了一半微分方程的求解,模型计算时间为 7.2 s,相比于传统的 P2D 模型减少了 91.5%,且计算精度损失很少;刘征宇等^[46]基于单粒子模型对液相锂离子浓度进行化简,大幅减少计算量,相比于传统 P2D 模型计算时间减少 99.73%。

4.2 电化学模型估算 SOC

在动态工况中,电池的数据实时变化,需从实时采集到的电池数据中辨识电化学模型参数(如固相锂离子浓度、交换电流密度、锂离子摩尔数和电解质活度系数等 20 个参数左右)。但是如果每有数据加入,就需重新计算模型,计算量太大;因此可使用 2.1 节介绍的参数辨识等算法更新模型参数。

通过分析电化学模型辨识出需要的参数后,根据固相锂离子浓度计算 SOC。在电化学模型中,正极和负极的 SOC 分别如式(36)、(37)所示。

表 2 P2D 模型控制方程
Table 2 Control equations of P2D model

控制方程	表达式
固相质量守恒方程	$\frac{\partial c_s}{\partial t} = \frac{D_s}{r^2} \frac{\partial}{\partial r} (r^2 \frac{\partial c_s}{\partial r})$
液相质量守恒方程	$\frac{\partial (\epsilon_e c_e)}{\partial t} = \frac{\partial}{\partial x} \left(D_{eff} \frac{\partial c_e}{\partial x} \right) + \frac{1 - t_+^0}{F} j^{Li}$
固相电荷守恒方程	$\frac{\partial}{\partial x} \left(\sigma^{eff} \frac{\partial \varphi_s}{\partial x} \right) = j^{Li}$
液相电荷守恒方程	$\frac{\partial}{\partial x} \left(\kappa^{eff} \frac{\partial \varphi_e}{\partial x} \right) + \frac{\partial}{\partial x} \left(\kappa_D^{eff} \frac{\partial}{\partial x} \ln c_e \right) = -j^{Li}$
BV 动力学方程	$j^{Li} = a_s i_0 \left\{ \exp \left[\frac{\alpha_a F}{RT} \eta \right] - \exp \left[-\frac{\alpha_c F}{RT} \eta \right] \right\}$
交换电流密度	$i_0 = k_i c_e^{a_a} (c_{surf,max} - c_{surf,e})^{a_a} (c_{surf,e})^{a_c}$
过电势	$\eta = \varphi_s - \varphi_e - U$
电池端电压	$V(T) = \varphi_s(L,t) - \varphi_s(0,t) - \frac{R_f}{A} I$

$$SOC_p = \frac{\bar{c}_{s,p} - c_{s,p0}}{c_{s,pmax} - c_{s,p0}} \quad (36)$$

$$SOC_n = \frac{\bar{c}_{s,n} - c_{s,n0}}{c_{s,nmax} - c_{s,n0}} \quad (37)$$

其中, $\bar{c}_{s,p}$ 和 $\bar{c}_{s,n}$ 为正负极全局固相锂离子浓度, $c_{s,p0}$ 和 $c_{s,n0}$ 为正负极扩散前初始的锂离子浓度, $c_{s,pmax}, c_{s,nmax}$ 为完全扩散后的锂离子浓度。正负极 SOC 的平均值为电池的 SOC:

$$SOC = \frac{SOC_p + SOC_n}{2} \quad (38)$$

经过大量研究,P2D 模型及其简化模型的计算时间已大大降低,可应用于实际工况中的锂电池 SOC 估计。近年来使用电化学模型估算 SOC 的研究仍在跟进,Wu 等^[47]基于固相简化的 P2D 模型,使用帕德近似和体积平均法拟合模型参数,设计比例积分微分 (proportional-integral-differential, PID) 观测器估算 SOC,最大误差 MAEs 低于 1%;Wang 等^[48]基于单粒子电化学模型,使用 PSO 算法计算并更新模型动态参数,参数用于 PF 估算电池 SOC,最大误差 MAEs 低于 1%。

基于电化学模型的 SOC 估计方法同样倾向于多参量联合估计以提高精度,相关研究方法将在后文介绍。

5 基于人工智能的方法

人工智能领域近几年来飞速发展,诞生出了传统机器学习、深度学习等神经网络,在估算和预测系统输出方面有很好表现。神经网络的方法同样可以应用于锂电池 SOC 估算。神经网络的方法估算 SOC,甚至无需构建模拟

电池内部电化学行为的复杂的电池模型,无需构建系统方程,无需建立参数之间的关联方程,即可建立 SOC 与输入的电压、电流、温度或内阻值的关系^[49]。同时,随着神经网络方法的不断发展、GPU 的兴起和广泛应用,其学习速度越来越快,具有更好的鲁棒性,且可以与其他估算方法联合使用,进一步降低 SOC 估算误差。人工智能的应用为电池 SOC 估算方法带来了新的生机,2019 年之后的锂电池 SOC 估算研究中,29% 的研究使用了神经网络相关方法。

5.1 前馈神经网络

前馈神经网络 (feed-forward neural networks, FNN) 是人工智能领域第一个简易的人工神经网络 (artificial neural networks, ANN)^[50]。FNN 的结构如图 7 所示,一般包括输入层、输出层和多个隐藏层,输入信号通过隐藏层正向传播,通过权重在节点和相邻层之间连接和传播,最后输出预测值。

FNN 的预测过程是一个传递信息并进行分类的过程。其结构简单,容易实现,适用于锂电池 SOC 估算。Ismail 等^[51]使用 FNN 建立电压电流与 SOC 值的关系,在进行 2 000 次训练后,RMSE 低至 1.6148×10^{-6} 。

反向传播神经网络 (back propagation neural networks, BPNN) 是一种简易的 FNN,其中的 S 曲线模型与 OCV-SOC 关系曲线相似,可据此预测 SOC 值。Dang 等^[52]使用等效电路模型构建锂电池的受控自回归滑动平均 (controlled auto-regressive and moving average, CARMA) 模型系统方程,使用 RLS 决定系统参数,以获取开路电压 OCV 的估计值,加入前馈补偿减少估计 OCV 的误差,使用 BPNN 离线训练,建立 OCV-SOC 关系模型,在

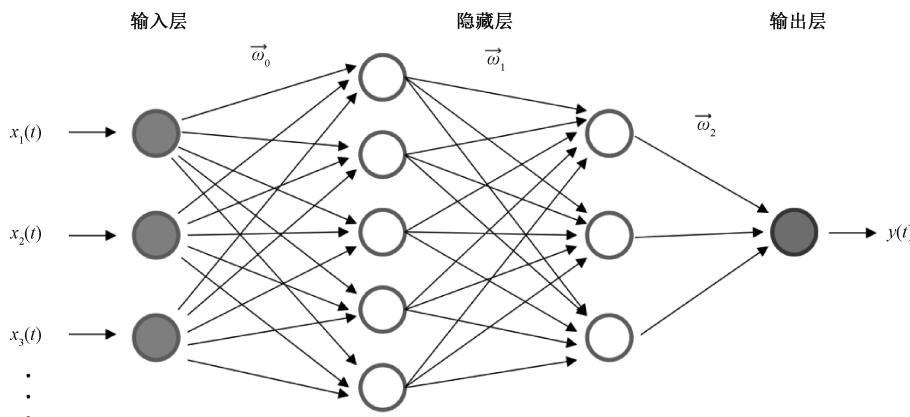


图 7 前馈神经网络结构

Fig. 7 Structure of feed-forward neural networks

线估计 SOC 值,平均误差 MAE 为 0.332 5%,最大误差为 1.237 8%。

FNN 结构简单,但对于具有时序关系的数据处理能力较弱,且需要大量数据进行训练,收敛速度较慢,容易陷入局部最优值。刘齐等^[53]针对 FNN 精度不高和容易陷入局部最优的问题,使用改进的麻雀搜索算法(类似于 2.1 节介绍的 PSO 算法)对神经网络的初始权值和宽度参数进行寻优,估算平均误差为 3.15%,与 BPNN 的精度相比提升了一倍。

5.2 深度学习方法

深度学习的方法在上述传统的全连接神经网络基础上演变而来,比起传统的全连接神经网络结构多了一些隐层,能够自主提取数据信息中的特征,在识别语音和图像

方面取得了卓越的效果。在锂电池 SOC 估算中,深度学习方法同样能够获取用于估算 SOC 值的特征^[51],具有精度高、鲁棒性好的优点,加入的门控机制又进一步提高其对于长序列数据处理的精确性和稳定性。

1) 循环神经网络

循环神经网络(recurrent neural networks, RNN)作为一种深度学习方法,解决了传统的全连接神经网络不能建立数据时序关系的问题。SOC 估算的输入输出数据是时间相关序列,因此与其他网络结构相比,结构如图 8 所示所示的 RNN 在此方面具有一定优势。RNN 具有记忆单元,能够储存历史状态信息,并实时更新,进行参数共享,实现对时间序列的特征信息提取。

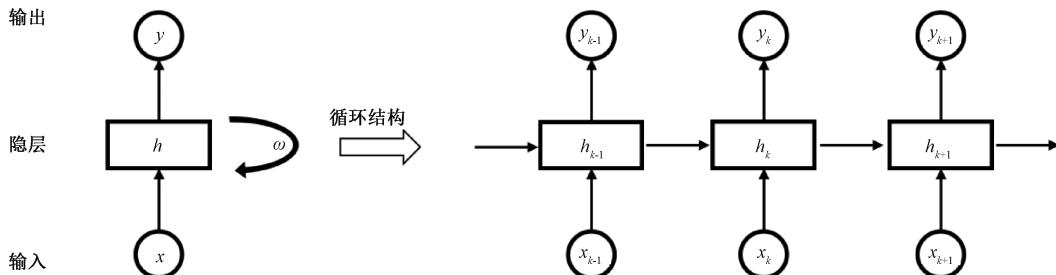


图 8 循环神经网络结构

Fig. 8 Structure of recurrent neural networks

RNN 的权值是共享的,每一时刻的权值由所有时刻共同决定,当序列过长时,RNN 无法获取长距离的依赖关系,不能进行长序列学习。引入的门控算法,如长短时记忆网络(long short-term memory, LSTM)和门控循环单元(gated recurrent unit, GRU),解决了长时记忆学习的问题。LSTM 单元替代了传统 RNN 中的神经单元^[54],通过遗忘门、输入门和输出门,控制历史信息的保留或遗忘,决定信息的传递和输出。GRU 是另一种解决长时记忆的方法,结构比 LSTM 简易,包括重置门和更新门两部分,控制历史状态信息的数量和新状态中包含的历史信息^[55]。

引入门控机制的 RNN 更加擅长处理类似于 SOC 估算输入的时序序列。Yang 等^[56]使用 RNN-GRU 神经网络,在不同温度下估算锂电池 SOC,训练一次的时间大约为 0.6 s,经过 6 000 次训练,平均误差 MAE 低于 1%,并与 KF/PF 等方法对比实验,表明其方法精度更高。Wei 等^[57]使用 RNN 的一种特殊的神经网络 NARX(nonlinear auto-regressive models with exogenous input neural network)网络,引入 LSTM 解决长时记忆问题,通过输入的电流、电压和温度数据,估算锂电池 SOC。其估算平均误差 MAE 约为 0.7%,优于 BPNN-PSO、单 LSTM 等方法。

2) 卷积神经网络

卷积神经网络(convolutional neural network, CNN)也是

深度学习中的一个经典结构,常用于进行图像识别。CNN 同样可以处理时序数据^[58]。用于 SOC 估算的 CNN,通过卷积的方法获取数据特征,其卷积核是 1 维的,使用向后传播算法和梯度下降更新权值。用于估算 SOC 的 CNN 结构如图 9 所示,包括 3 个部分:卷积层、池化层和全连接层。卷积层使用

卷积核窗口在数据上滑动,并与数据进行卷积操作,获得数据特征。不同的卷积核获取不同的数据特征,叠加多个卷积层使得网络能够获取更多的特征。池化操作保留需要的特征值,去除冗余信息。全连接层与传统的全连接网络结构一样,学习获取到的特征,输出识别的结果。

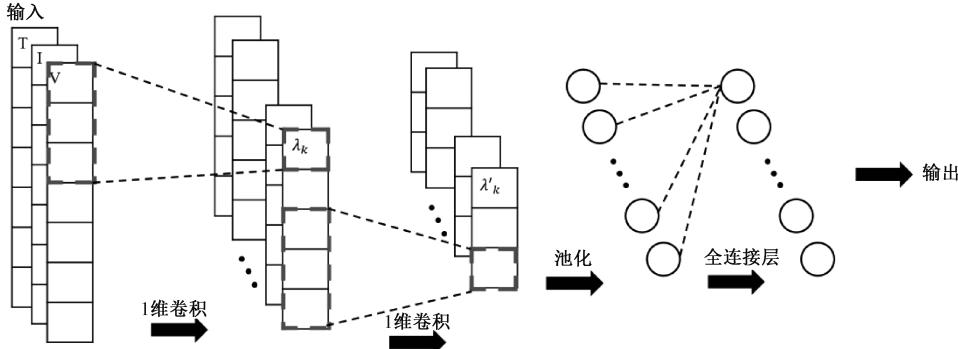


图 9 一维卷积 CNN 结构

Fig. 9 1-Dimension convolutional CNN structure

直接使用 CNN 估算锂电池 SOC 的表现同 RNN 一样好。在 Bhattacharjee 的研究中^[58],CNN 架构使用三层滤波器和卷积层,获取数据在长期和短期内的关联性并提取特征,估算结果的 MAE 低于 1%。

RNN 使用门控算法解决长期记忆问题,在 CNN 中同样可以引入门控算法,获取数据在时序上的相关性^[56-58]。引入门控算法的 CNN 结构如图 10 所示,1 维卷积层对提取数据空间特征,门控单元建立 SOC 与输入数据在时序上的关系,全连接层输出预测结果。Song 等^[59]构建 CNN-LSTM 混合神经网络,加入 80 节点的 LSTM 获取时间特征,估算结果最大误差 MAEs 低于 1%;Huang 等^[60]使用两层 GRU 结构获取数据时间依赖关系,得到的 CNN-GRU 网络适应性强,可适用于其他领域,最大误差低于 2%;Cui 等^[61]在 CNN 获取数据特征的基础上,加入双向加权的门控单(bidirectional weighted gated recurrent unit, BWGRU)提高了网络在低温环境下预测的表现,模型精度高,鲁棒性好,平均误差 MAE 在低温下仍低于 1%。

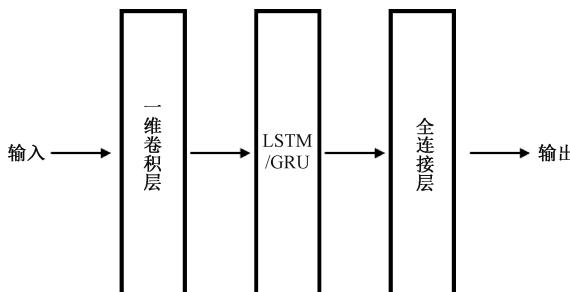


图 10 加入门控单元的 CNN 混合神经网络

Fig. 10 CNN hybrid neural network with gate control unit

5.3 其他方法与神经网络的结合

对于非线性系统的输出预测,神经网络的方法比电化

学模型的方法和 KF 的方法具有更好的鲁棒性。但 KF 在输出值滤波以及联合多参量估算方面仍有用武之地。在使用神经网络的方法建立 SOC 与输入数据之间的关系后,可以使用 KF 等方法对估算值进行去噪,进一步提高估算的准确性^[62-64]。

Tian 等^[62]使用 LSTM 神经网络建立 SOC 和输入电流、电压以及温度之间的关系,再使用 ACKF 对输出的 SOC 值进行平滑、去噪,估算最大误差低于 4%,RMSE 低于 2.2%。Cui 等^[63]改进双向加权的门控神经网络(improved bidirectional gated recurrent unit, IBGRU),建立模型预测 SOC 值,并用 UKF 滤除因计算和系统误差带来的噪声,提升了估算的准确性和稳定性,在温度为 $-10^{\circ}\text{C} \sim 25^{\circ}\text{C}$ 下,其估算误差 MAE 均低于 2%,最大误差约为 5%。Feng 等^[64]搭建简易的电化学模型,使用神经网络估算端电压值,再利用端电压值通过 UKF 联合估算 SOC 和电池温度状态,在 $-10^{\circ}\text{C} \sim 40^{\circ}\text{C}$ 下,误差 RMSE 低于 1%。

目前基于神经网络方法的 SOC 估算研究,趋向于使用多种方法混合,试图减少估算误差,并进一步简化神经网络的使用。考虑到电池的老化带来的误差,基于神经网络的方法也需要对电池的 SOH 进行估算,无论是借助其他方法还是使用神经网络,这将进一步提升 SOC 估算的准确性。

6 多参量联合估算

6.1 容量变化修正

根据 SOC 的定义或式(1)可知,SOC 的值为当前电荷量除以电池总容量。随着锂电池的充放电,电池的容量会缓慢减少,电池的剩余寿命 SOH 值降低。SOH 的定义如式(39)所示。

$$SOH = \frac{Q_{current}}{Q_0} \times 100\% \quad (39)$$

式中: $Q_{current}$ 表示当前可用容量, Q_0 表示电池初始额定容量。

在 SOC 计算过程中, 默认电池的总容量为固定值, 这将导致 SOC 的估算不准确, 在电池使用过程中可能会因容量变化而误判电池的剩余电量。并且, 若电池老化严重, SOH 降到一定值时, 电池将失去充放电能力, 应按报废处理。因此估测电池 SOH 的变化, 对于提高 SOC 估算精度以及监控电池行为变化, 具有重要意义。

近几年, 已有不少研究将 SOH 估算结果用于修正 SOC 估算结果^[21, 27, 65-70], 在基于电路模型的方法和基于神经网络方法的研究中都有体现。

在基于电路模型的方法中, SOC 的估算结果可用于估算 SOH, SOH 的估算结果反过来修正 SOC, 形成二者的联合估算方法^[21]。王辉等^[65] 基于二阶等效电路模型, 使用 EKF 估算 SOC, 并使用时间序列加权法在线估计 SOH, 以更新 SOC 计算结果, 不同老化程度的电池 SOC 估计的最大误差均低于 2.7%, SOH 估计最大误差低于 1.51%。Xu 等^[42] 使用双 PF 的方法分别估算 SOC 和 SOH, 在不同 SOC 初始值情况下估算, 平均误差 MAE 低于 1.3%。Gao 等^[66] 基于电化学模型 P2D, 进行 SOC 和 SOH 的联合估计, 最大误差低于 2.28%, RMSE 低于 0.7%。

基于人工智能的方法同样可以估算 SOH 以修正 SOC 估算结果。Li 等^[67] 基于等效电路模型, 使用 RLS 方法辨识参数、AEKF 估算 SOC, 使用艾尔曼神经网络 (elman neural network, ENN) 实时估算电池容量, 利用容量修正 SOC, 在室温下估算误差低于 2%, 在不同温度下最大误差低于 6%。Eleftheriadis 等^[68] 基于 RNN 双门控单元估算 SOC 和 SOH, 分别实验了双 LSTM 和双 GRU 层的估算

结果, 二者结果相差不大, 估算 SOH 平均 MAE 为 0.3%, SOC 估算平均 MAE 为 1.42%。Cui 等^[63] 使用支持向量机 (support vector machine, SVM) 估算 SOH 相关参数, UKF 用于实时估算 SOC, SOH 估计结果用于 SOC 估算更新, 在修正后估算误差 MAE 低于 0.5%, RMSE 低于 0.63%。

由于电池阻抗与电池容量变化具有良好关系, 电化学阻抗谱法成为一个估测 SOH 的快捷方法^[12, 14]。SOH 估算精度的提升, 也将提高 SOC 估算表现。

6.2 温度影响

由上文提到的 Cui 等的研究^[63-64] 可知, 在不同温度条件下, SOC 的估算结果出现变化, 尤其在低温条件下, SOC 估算误差明显增加。这是因为电池温度状态 (state of temperature, SOT) 变化影响电池参数随之变化, 包括阻抗、电容、容量和电压等^[71]。当温度从 10 ℃ 变化到 40 ℃ 时, 电池容量将变化约 5.2%。如果不考虑温度变化带来的影响, 在实际工况中估算 SOC 的误差将增加更多。

估算电池 SOT 修正 SOC 估算结果, 或在不同温度条件下实验修正的方法已有研究使用。Feng 等^[64] 用神经网络的方法联合估算 SOT-SOC。Xie 等^[72] 构建电池的三维温度模型, 更全面分析温度对电池参数产生的影响, 使用双 AKF 联合估算三维 SOT 模型和 SOC, SOT 估算最大误差为 8%, SOC 估算 MAE 低于 1.5%。

温度作为一个影响因素, 在很多 SOC 估算方法研究中都有提及。在之后的研究中, 联合估算 SOT、SOH 和 SOC, 或考虑到其他因素的影响, 将进一步提高 SOC 估算精度。

7 SOC 估算方法的应用

上述提到的 SOC 估算方法各有千秋, 各方法优缺点、精度总结如表 3 所示。

表 3 估算方法总结表
Table 3 Summary table of estimation methods

估算方法	优势	缺点	参考文献	电池类型(未标注 电压默认 3.6 V)	估算结果
开路电压法	快速	误差大	[7]	磷酸铁锂电池	最大误差 12.4%
安时积分法	精确	需要积分电路 保持工作	[7-9]	磷酸铁锂电池	误差随时间增加, 最大误差可达 15%
EIS	阻抗表征	若与阻抗关系不好, 误差大	[13]	镍钴锰酸锂电池, 型号为松下的 18650PF	平均误差小于 3.8%
KF	计算量小, 容易实现	受非线性系统和噪声影响	[10] [37] [38]	亚科源的镍钴锰三元锂电池 镍钴锰三元锂电池 镍钴锰酸锂、锰酸锂钴酸锂 和磷酸铁锂三种电池比较	使用带平方根的 AEKF, 平均误差小于 1% 使用 ACDKF, 最大误差小于 1% 使用双遗忘因子的 AEKF, 最大误差均小于 1%

表 3 估算方法总结表(续)
Table 3 Summary table of estimation methods (Continued)

估算方法	优势	缺点	参考文献	电池类型(未标注 电压默认 3.6 V)	估算结果
PF	精确度较高	需解决粒子退化等问题	[29]	镍钴锰三元锂电池, 型号为 18650	平均误差小于 1%, 最大误差为 3%
基于 EM	精确度较高	模型复杂, 计算量较大	[47] [48]	锰酸锂钴酸锂电池 镍钴锰三元锂电池, 型号为 18650	平均误差小于 2% 平均误差为 0.76%
BPNN	容易实现	收敛慢, 需要大量数据	[51] [52]	商用 3.6 V 电池 24 V 磷酸铁锂电池	均方误差 RMSE 为 3.853×10^{-9} 平均误差为 1.23%
RNN-门控	可获取时间特征, 鲁棒性好	需要门控单元和离线训练	[56] [57]	镍钴锰三元锂电池 镍钴锰三元锂电池, 型号为 18650	平均误差小于 1% 平均误差小于 0.72%
CNN	可获取更多特征	需要离线训练	[58] [59]	镍钴锰三元锂电池 镍钴锰三元锂电池, 型号为 18650	准确率高但未给出误差数值 平均误差小于 1%
CNN-门控	可获取时间特征, 适应性强	需要离线训练	[60] [61]	镍钴锰三元锂电池, 型号为 18650 镍钴锰三元锂电池, 型号为 18650	平均误差小于 2% 平均误差小于 1.27%
混合方法	估算结果进一步滤波, 降低误差		[62] [63]	A123 磷酸铁锂电池 镍钴锰三元锂电池, 型号为 18650 和三星的 21700	使用 LSSTM-ACKF, 最大误差小于 4% 使用 IBGRU-UKF, 最大误差小于 5%
			[64]	A123 磷酸铁锂电池	使用 EM-NN-UKF, 平均误差为 1.32%, 最大误差小于 5%
			[65]	磷酸铁锂电池	使用双 KF, 平均误差小于 1.4%
			[66]	LR2170LA 电池	使用双 PF, 平均误差小于 1%
			[67]	镍钴锰三元锂电池, 型号为 18650	基于 EM, 平均误差小于 1.45%
SOH-SOC	容量修正		[68]	镍钴锰三元锂电池	使用 AEKF, 不同温度下最大误差小于 6%
			[69]	镍钴锰三元锂电池, 型号为 LG18650	使用 LSTM, 平均误差为 1.42%
			[70]	NASA 的 B0005 锂电池数据集	使用 SVM-UKF, 平均误差小于 2%
SOT-SOC	温度补偿		[72]	镍钴锰三元锂电池	使用双 AKF, 平均误差小于 2.5%

这些方法基本都是针对电车电池管理系统提出的, 并且都适用于电车这种功率高、能耗较大的系统。而植入式医疗电子设备尺寸小, 电池储能不高, 要求电池管理系统的功耗必须保持在最低水平, 并且还需保持一定的估算精

度。比如在心脏起搏器中, 其起搏功能能耗极低, 电池 SOC 估算系统不可能占用太多能耗, 否则其使用寿命将大大减少。

因此, SOC 估算方法能否应用于一个电池管理系统

中,还需分析其设备的具体情况:

1)在设备 CPU 不可连续使用的情况下,需要建立模型、进行大量计算的方法无法使用。此时可以考虑采用如安时积分法、电压/电阻表征等直接方法。其中安时积分法的准确性更高;电压/电阻表征方法(查表法)易受不同电池参数、测量的电压/电流/电阻值不准确和温度变化等因素影响,准确度较低,但使用更简单。

2)在设备 CPU 可用的情况下,与基于电化学的方法和神经网络的方法相比,基于等效电路模型的方法需要的计算量很少,且可达到相当的估算精度,可应用于设备的片上嵌入式系统中。基于神经网络的方法,则需要大量的矩阵运算,拥有配套的神经网络计算模块可加速其计算^[73]。

若设备中不具备计算能力,或者设计者不希望在设备内部进行计算,基于物联网的云计算方案^[74-75]提供了解决思路。设备可将电池的数据传输到如程控仪等外部系统中,在外部进行估算并显示剩余电量;需要时可再将估算结果反馈给设备,这样的方案在诸多场合中将是适用的。

7.1 估算方法在电动汽车中的应用

电动汽车采用可充电池,充放电循环过程中电池寿命不断减少,需要考虑 SOH 变化;且实际工况下环境温度变化大,还需考虑温度变化对各项参数的影响。因此,电动汽车内部的电池管理系统具备多种功能:电池的状态估算(包括 SOC、SOH 和 SOT 等状态估算)、电池单元平衡、充放电控制、温度控制和故障预测等功能^[76]。这样的电池管理系统建立在具有一定数据处理能力的片上系统的基础上,这就意味着其计算能力和功耗能够支撑各种估算方法的实现。

如本章前言中所述,在设备计算单元可用的情况下,使用基于等效电路模型的方法、基于电化学模型的方法和神经网络的方法精度更高。这些方法已在电车电池管理系统中得到应用:文献[77]设计的电池管理系统使用 STM32 单片机作为主控芯片,采集电池的放电电流和电压,通过 EKF 估算电池 SOC;其测试结果表明,安时积分法的估算误差随时间增加,最大误差超过 15%,使用 EKF 算法后最大误差小于 5%;文献[78]使用基于神经网络的方法估算电池 SOC;该方法先对动力电池进行仿真实验,实验得到的电压、电流和 SOC 值组成样本集交由神经网络训练,建立神经网络模型,实际工况下电池管理系统实时采集电池的电流、电压和温度值,对采集到的电压值进行温度修正,将电压和电流值输入电池管理系统中训练好的神经网络模型,得到输出的 SOC 估计值。

目前的电车系统均已联网,这为云计算方案带来便利。在电车系统外部进行 SOC 估算可以减少复杂的计算带来的时间消耗,还可以降低计算带来的额外功耗。基于物联网的云计算方案已经成为现实;如:文献[79]设计的电池管理系统使用了云计算方案;该系统分为电池端和云

端计算模块,电池端负责采集电池充放电的电压、电流、温度、气体和所受压力等信息,储存并上传至云端,云端计算模块实时估算电池 SOC,检测电池故障,并对电池充放电状态进行管理优化。

由于电动汽车的电池储能高,能够适配各种 SOC 估算方法,并且能够联网实现云计算方案,激励着各种方法不断推陈出新、相互融合。

7.2 在植入式设备中的应用

植入式医疗设备受到尺寸和功耗的制约,现行的植入式电池电量监测系统几乎都使用直接的方法进行 SOC 估算;这些方法不需要 CPU 进行复杂运算,单靠模拟电路就能完成,精度不高但功耗能够降到最低。

Webster 设计的心脏起搏器使用如图 11 所示电路检测电池内阻,用内阻表征电池电量。电路中开关 S₁ 闭合、S₂ 打开时电池 V_{BAT} 为电容 C_B 充电,平衡后关闭 S₂ 为 C_T 充电,起搏器由 C_B 供电,记录 C_T 充电时间 τ ,由 $\tau = RC_T$ 可计算出电池内阻 R,查表获得电池 SOC。

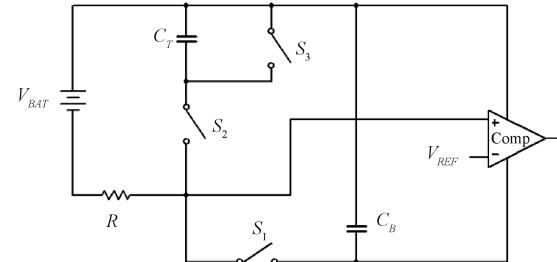


图 11 电池内阻监测电路

Fig. 11 Battery internal resistance monitoring circuit

2020 年索林公司用于有源植入式医疗设备的专利^[80]使用电压表征的方法监测电池电量。该专利测量射频通信结束后的电池电压值,并与通信功能失效的参考电压相比较,决定是否发出警告以表示功能即将失效,该电压值同时可与电池电量耗尽的参考电压比较以确定设备是否可用。专利表示该方法需要电池制造商提供准确参考电压,即便如此仍有较大误差。

2023 年美敦力公司的植入式设备电池电量监测系统专利^[81]使用安时积分法获取电池 SOC, 电路系统包括电阻传感器、抗混叠滤波器、比较器和数字控制电路, 获取每单位时间的电流值并储存, 累积得到消耗的电量。

文献[82]在植入式设备外部进行电池寿命终止预测。使用多个相同型号电池进行放电实验,采集放电电压变化数据,将多条放电电压变化曲线归一化得到一条标准放电曲线。随时采集植入式设备内部电池电压变化数据,根据实际放电电压和标准放电曲线之间的下降率,修正标准放电曲线,得到此电池的预测放电曲线,预测电池寿命终止时间。

可见,因植入式设备大都具有通信功能,现行的植入式设备 SOC 估算方案倾向于将 SOC 计算的负担转移到外

部设备,以降低在设备内部的功耗。因此,若想要提高估算精度,或将更多SOC估算方法应用于植入式设备中,物联网和云计算的模式是必不可少的。

8 结 论

本文综述了锂电池SOC估算的相关方法,分析各方法的优劣,说明容量和温度因素对SOC估算结果的影响及修正方法,阐明了各方法在电子设备中的应用场景,介绍了估算方法在电动汽车和植入式设备中的应用。未来的SOC估算方法,将考虑更多影响因素,相互融合,不断提高估算精度;人工智能的发展可能催生出更精确、更便于实现的方法;物联网也将为估算方法的实现提供便利。因此,SOC估算方法的进步和应用还有相当多的工作需要研究者们完成。

参考文献

- [1] RIVERA-BARRERA J P, MUÑOZ-GALEANO N, SARMIENTO-MALDONADO H O. SoC estimation for lithium-ion batteries: Review and future challenges[J]. Electronics, 2017, 6(4):102.
- [2] 徐超.锂离子电池SOC估计和循环寿命预测方法研究[J].天津化工,2024, 38(1): 112-115.
XU CH. Research on SOC estimation and cycle life prediction methods for lithium-ion batteries [J]. Tianjin Chemical Industry, 2024, 38(1): 112-115.
- [3] 赵珈卉,田立亭,程林.锂离子电池状态估计与剩余寿命预测方法综述[J].发电技术,2023, 44(1): 1-17.
ZHAO J H, TIAN L T, CHENG L. Review on state estimation and remaining useful life prediction methods for lithium-ion battery[J]. Power Generation Technology, 2023, 44(1): 1-17.
- [4] 付诗意,吕桃林,闵凡奇,等.电动汽车用锂离子电池SOC估算方法综述[J].储能科学与技术,2021, 10(3): 1127-1136.
FU SH Y, LYU T L, MIN F Q, et al. Review of estimation methods on SOC of lithium-ion batteries in electric vehicles [J]. Energy Storage Science and Technology, 2021, 10(3): 1127-1136.
- [5] 李军,李虎林.电动汽车锂离子电池荷电状态估算方法综述[J].科学技术与工程,2022, 22(6): 2147-2158.
LI J, LI H L. Review of state of charge estimation methods for electric vehicle lithium-ion batteries[J]. Science Technology and Engineering, 2022, 22 (6): 2147-2158.
- [6] RIVASTAVA P, SOON T K, IDRIS M Y. Overview of model-based online state-of-charge estimation using Kalman filter family for lithium-ion batteries [J]. Renewable and Sustainable Energy Reviews, 2019, 113: 109233.
- [7] MOHAMMADI F. Lithium-ion battery state-of-charge estimation based on an improved coulomb-counting algorithm and uncertainty evaluation [J]. Journal of Energy Storage, 2022, 48: 104061.
- [8] 张永凯,赵建平,陶明超,等.基于库仑计法的锂电池电量检测[J].化工自动化及仪表,2016, 43(2): 191-194.
ZHANG Y K, ZHAO J P, TAO M CH, et al. Lithium battery detection based on coulometer [J]. Control and Instruments in Chemical Industry, 2016, 43(2): 191-194.
- [9] 杨洁,曾云,杨艳军.一种高精度CMOS库仑计的设计[J].微电子学,2015, 45(2): 188-191.
YANG J, ZENG Y, YANG Y J. Design of a high accuracy CMOS coulomb meter[J]. Microelectronics, 2015, 45(2): 188-191.
- [10] JIANG C, WANG SH L, WU B, et al. A state-of-charge estimation method of the power lithium-ion battery in complex conditions based on adaptive square root extended Kalman filter [J]. Energy, 2021, 219: 119603.
- [11] HAN H CH, XU H P, YUAN Z Q, et al. A new SOH prediction model for lithium-ion battery for electric vehicles [C]. 2014 17th International Conference on Electrical Machines and Systems (ICEMS), IEEE, 2014: 997-1002.
- [12] CHOI W, SHIN H C, KIM J M, et al. Modeling and applications of electrochemical impedance spectroscopy (EIS) for lithium-ion batteries [J]. Journal of Electrochemical Science and Technology, 2020, 11(1): 1-3.
- [13] BABAEIYAZDI I, REZAEI-ZARE A, SHOKRZADEH S. State of charge prediction of EV Li-ion batteries using EIS: A machine learning approach[J]. Energy, 2021, 223: 120116.
- [14] ZHANG M, LIU Y SH, LI D ZH, et al. Electrochemical impedance spectroscopy: A new chapter in the fast and accurate estimation of the state of health for lithium-ion batteries[J]. Energies, 2023, 16(4): 1599.
- [15] 杨杰,王婷,杜春雨,等.锂离子电池模型研究综述[J].储能科学与技术,2019, 8(1): 58-64.
YANG J, WANG T, DU CH Y, et al. Overview of the modeling of lithium-ion batteries [J]. Energy Storage Science and Technology, 2019, 8(1): 58-64.
- [16] TRAN M K, MATHEW M, JANHUNEN S, et al. A comprehensive equivalent circuit model for lithium-ion

- batteries, incorporating the effects of state of health, state of charge, and temperature on model parameters [J]. Journal of Energy Storage, 2021, 43: 103252.
- [17] 张禹轩. 电动汽车动力电池模型参数在线辨识及 SOC 估计[D]. 长春: 吉林大学, 2014.
ZHANG Y X. Parameter identification and SOC estimation of power battery for electric vehicle [D]. Changchun: Jilin University, 2014.
- [18] NASERI F, SCHALTZ E, STROE D I, et al. An enhanced equivalent circuit model with real-time parameter identification for battery state-of-charge estimation [J]. IEEE Transactions on Industrial Electronics, 2021, 69(4): 3743-3751.
- [19] 赵可沧, 江境宏, 邓进, 等. 基于遗忘因子递推最小二乘法的锂电池等效电路模型参数辨识方法[J]. 电子测量技术, 2022, 45(23): 53-58.
ZHAO K L, JIANG J H, DENG J, et al. Parameter identification method of lithium battery equivalent circuit model based on forgetting factor recursive least squares [J]. Electronic Measurement Technology, 2022, 45(23): 53-58.
- [20] 吴小慧, 张兴敢. 锂电池二阶 RC 等效电路模型参数辨识[J]. 南京大学学报, 2020, 56(5): 754-761.
WU X H, ZHANG X G. Parameters identification of second order RC equivalent circuit model for lithium batteries [J]. Journal of Nanjing University Nature Science, 2020, 56(5): 754-761.
- [21] LI Y, WANG L F, LIAO CH L, et al. Recursive modeling and online identification of lithium-ion batteries for electric vehicle applications [J]. Science China Technological Sciences, 2014, 57: 403-413.
- [22] SUN D, CHEN X K. Adaptive parameter identification method and state of charge estimation of lithium ion battery [J]. 2014 17th International Conference on Electrical Machines and Systems (ICEMS), IEEE, 2014: 855-860.
- [23] 李思. 电动汽车锂离子电池等效电路模型的参数辨识研究[D]. 北京: 北京理工大学, 2015.
LI S. Study on parameter identification of the equivalent circuit model in lithium-ion battery in electric car [D]. Beijing: Beijing Institute of Technology, 2015.
- [24] 汪葵, 魏民祥, 赵万忠, 等. 基于递推最小二乘法与模糊自适应扩展卡尔曼滤波相结合的车辆状态估计[J]. 中国机械工程, 2017, 28(6): 750-755.
WANG Y, WEI M X, ZHAO W ZH, et al. Vehicle state estimation based on combined RLS and FAEKF [J]. China Mechanical Engineering, 2017, 28(6): 750-755.
- [25] 李美莹. 新能源电动汽车动力电池剩余电量评估方法研究[D]. 呼和浩特: 内蒙古工业大学, 2021.
LI M Y. Research on the state of charge estimation for power battery of new energy electric vehicles [D]. Hohhot: Inner Mongolia University of Technology, 2021.
- [26] XING H M, DING F, ZHANG X, et al. Highly-efficient filtered hierarchical identification algorithms for multiple-input multiple-output systems with colored noises [J]. Systems & Control Letters, 2024, 186: 105762.
- [27] 孙功武, 谢基榕, 王俊轩. 基于动态遗忘因子递推最小二乘算法的船舶航向模型辨识[J]. 计算机应用, 2018, 38(3): 900-904.
SUN G W, XIE J R, WANG J X. Ship course identification model based on recursive least squares algorithm with dynamic forgetting factor [J]. Journal of Computer Applications, 2018, 38(3): 900-904.
- [28] ROZAQI L, RIJANTO E. SOC estimation for Li-ion battery using optimum RLS method based on genetic algorithm [J]. In 2016 8th International Conference on Information Technology and Electrical Engineering (ICITEE), IEEE, 2016: 1-4.
- [29] 郑超逸. 基于遗传粒子滤波算法的动力锂电池状态研究[D]. 合肥: 合肥工业大学, 2021.
ZHENG CH Y. Research on the power lithium battery state based on genetic particle filter algorithm [D]. Hefei: Hefei University of Technology, 2021.
- [30] 李岩, 袁弘宇, 于佳乔, 等. 遗传算法在优化问题中的应用综述[J]. 山东工业技术, 2019(12): 242-243, 180.
LI Y, YUAN H Y, YU J Q, et al. Overview of the application of genetic algorithm in optimization problems [J]. Journal of Shandong Industrial Technology, 2019(12): 242-243, 180.
- [31] SLOWIK A, KWASNICKA H. Evolutionary algorithms and their applications to engineering problems [J]. Neural Computing and Applications, 2020, 32: 12363-12379.
- [32] KATOCH S, CHAUHAN S S, KUMAR V. A review on genetic algorithm: Past, present, and future [J]. Multimedia Tools and Applications, 2021, 80: 8091-8126.
- [33] 冯茜, 李擎, 全威, 等. 多目标粒子群优化算法研究综述[J]. 工程科学学报, 2021, 43(6): 745-753.
FENG Q, LI Q, QUAN W, et al. Overview of multiobjective particle swarm optimization algorithm [J]. Chinese Journal of Engineering, 2021, 43(6): 745-753.

- [34] SHAMI T M, EL-SALEH A A, ALSWAITTI M, et al. Particle swarm optimization: A comprehensive survey[J]. IEEE Access, 2022, 10: 10031-10061.
- [35] 杨世春,华旸,顾启蒙,等.锂离子电池SOC及容量的多尺度联合估计[J].北京航空航天大学学报,2020,46(8): 1444-1452.
YANG SH CH, HUA Y, GU Q M, et al. Multi-scale joint estimation of SOC and capacity of lithium-ion battery [J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46 (8): 1444-1452.
- [36] 田元武,张诗建,周博雅,等.基于ARWLS-AEKF的锂电池SOC估计[J].电子测量技术,2022,45(17): 43-50.
TIAN Y W, ZHANG SH J, ZHOU B Y, et al. Lithium battery SOC estimation based on ARWLS-AEKF joint algorithm [J]. Electronic Measurement Technology, 2022, 45(17): 43-50.
- [37] HE L, WANG Y Y, WEI Y J, et al. An adaptive central difference Kalman filter approach for state of charge estimation by fractional order model of lithium-ion battery[J]. Energy, 2022, 244: 122627.
- [38] SHRIVASTAVA P, SOON T K, IDRIS M Y, et al. Combined state of charge and state of energy estimation of lithium-ion battery using dual forgetting factor-based adaptive extended Kalman filter for electric vehicle applications[J]. IEEE Transactions on Vehicular Technology, 2021, 70(2): 1200-1215.
- [39] 华菁,阮观强,胡星,等.基于TVFFRLS-ACKF的锂离子电池SOC估算[J].电子测量技术,2022,45(24): 22-28.
HUA J, RUAN G Q, HU X, et al. SOC estimation of lithium-ion battery based on TVFFRLS-ACKF[J]. Electronic Measurement Technology, 2022, 45(24): 22-28.
- [40] 邢丽坤,詹明睿,郭敏,等.基于FFMILS-MIUKF算法的锂电池SOC估计[J].电子测量技术,2022,45(16): 53-60.
XING L K, ZHAN M R, GUO M, et al. SOC estimation of lithium battery based on FFMILS-MIUKF algorithm [J]. Electronic Measurement Technology, 2022, 45(16): 53-60.
- [41] 王法胜,鲁明羽,赵清杰,等.粒子滤波算法[J].计算机学报,2014,37(8): 1679-1694.
WANG F SH, LU M Y, ZHAO Q J, et al. Particle filtering algorithm[J]. Chinese Journal of Computers, 2014, 37(8): 1679-1694.
- [42] XU Y H, CHEN X, ZHANG H G, et al. Online identification of battery model parameters and joint state of charge and state of health estimation using dual particle filter algorithms[J]. International Journal of Energy Research, 2022, 46(14): 19615-19652.
- [43] LI Y, WEI ZH B, XIONG B Y, et al. Adaptive ensemble-based electrochemical-thermal degradation state estimation of lithium-ion batteries [J]. IEEE Transactions on Industrial Electronics, 2021, 69(7): 6984-6996.
- [44] 武龙星,庞辉,晋佳敏,等.基于电化学模型的锂离子电池荷电状态估计方法综述[J].电工技术学报,2022,37(7): 1703-1725.
WU L X, PANG H, JIN J M, et al. A review of SOC estimation methods for lithium-ion batteries based on electrochemical model [J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1703-1725.
- [45] 庞辉.基于电化学模型的锂离子电池多尺度建模及其简化方法[J].物理学报,2017,66(23): 312-322.
PANG H. Multi-scale modeling and its simplification method of Li-ion battery based on electrochemical model [J]. Acta Physica Sinica, 2017, 66 (23): 312-322.
- [46] 刘征宇,杨昆,魏自红,等.包含液相扩散方程简化的锂离子电池电化学模型[J].物理学报,2019,68(9): 251-258.
LIU ZH Y, YANG K, WEI Z H, et al. Electrochemical model of lithium ion battery with simplified liquid phase diffusion equation [J]. Acta Physica Sinica, 2019, 68(9): 251-258.
- [47] WU L X, PANG H, GENG Y F, et al. Low-complexity state of charge and anode potential prediction for lithium-ion batteries using a simplified electrochemical model-based observer under variable load condition [J]. International Journal of Energy Research, 2022, 46(9): 11834-11848.
- [48] WANG J R, MENG J H, PENG Q, et al. Lithium-ion battery state-of-charge estimation using electrochemical model with sensitive parameters adjustment[J]. Batteries, 2023, 9(3): 180.
- [49] HOW T N D, HANNAN A M, LIPU H S M, et al. State-of-charge estimation of li-ion battery in electric vehicles: A deep neural network approach[J]. IEEE Transactions on Industry Applications, 2020, 56(5): 5565-5574.
- [50] CUI ZH H, WANG L CH, LI Q, et al. A comprehensive review on the state of charge estimation for lithium-ion battery based on neural network [J]. Energy, 2022, 46(5): 5423-5440.

- [51] ISMAIL M, DLYMA R, ELRAKAYBI A, et al. Battery state of charge estimation using an artificial neural network [J]. 2017 IEEE Transportation Electrification Conference and Expo (ITEC), 2017: 342-349.
- [52] DANG X J, YAN L, JIANG H, et al. Open-circuit voltage-based state of charge estimation of lithium-ion power battery by combining controlled auto-regressive and moving average modeling with feedforward-feedback compensation method [J]. International Journal of Electrical Power & Energy Systems, 2017, 90: 27-36.
- [53] 刘齐, 吴松荣, 邓鸿柄, 等. 基于 ASSA-RBF 联合算法的三元锂离子电池 SOC 估计 [J]. 电子测量技术, 2024, 47(1): 71-78.
LIU Q, WU S R, DENG H L, et al. SOC estimation of ternary lithium-ion battery based on ASSA-RBF joint algorithm [J]. Electronic Measurement Technology, 2024, 47(1): 71-78.
- [54] YANG F F, ZHANG SH H, LI W H, et al. State-of-charge estimation of lithium-ion batteries using LSTM and UKF[J]. Energy, 2020, 201: 117664.
- [55] 张心成, 李翔晟, 李藏龙, 等. 基于改进 GRU 模型算法的锂电池 SOC 估计 [J]. 电子测量技术, 2023, 46(11): 57-65.
ZHANG X CH, LI X SH, LI C L, et al. SOC estimation of lithium battery based on improved gated recurrent unit model algorithm [J]. Electronic Measurement Technology, 2023, 46(11): 57-65.
- [56] YANG F F, LI W H, LI CH, et al. State-of-charge estimation of lithium-ion batteries based on gated recurrent neural network [J]. Energy, 2019, 175: 66-75.
- [57] WEI M, YE M, LI J B, et al. State of charge estimation of lithium-ion batteries using LSTM and NARX neural networks[J]. IEEE Access, 2020, 8: 189236-189245.
- [58] BHATTACHARJEE A, VERMA A, MISHRA S, et al. Estimating state of charge for xEV batteries using 1D convolutional neural networks and transfer learning [J]. IEEE Transactions on Vehicular Technology, 2021, 70(4): 3123-3135.
- [59] SONG X L, YANG F F, WANG D, et al. Combined CNN-LSTM network for state-of-charge estimation of lithium-ion batteries [J]. IEEE Access, 2019, 7: 88894-88902.
- [60] HUANG ZH L, YANG F F, XU F, et al. Convolutional gated recurrent unit-recurrent neural network for state-of-charge estimation of lithium-ion batteries[J]. IEEE Access, 2019, 7: 93139-93149.
- [61] CUI ZH H, KANG L, LI L W, et al. A hybrid neural network model with improved input for state of charge estimation of lithium-ion battery at low temperatures [J]. Renewable Energy, 2022, 198: 1328-1340.
- [62] TIAN Y, LAI R C, LI X Y, et al. A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter [J]. Applied Energy, 2020, 265: 114789.
- [63] CUI ZH H, KANG L, LI L W, et al. A combined state-of-charge estimation method for lithium-ion battery using an improved BGRU network and UKF [J]. Energy, 2022, 259: 124933.
- [64] FENG F, TENG S L, LIU K L, et al. Co-estimation of lithium-ion battery state of charge and state of temperature based on a hybrid electrochemical-thermal-neural-network model[J]. Journal of Power Sources, 2020, 455: 227935.
- [65] 王辉, 严欢, 张晓滨, 等. 基于分数阶的锂电池 SOC 和 SOH 联合在线估计 [J]. 电源学报, 2024, 1-14 [2024-08-31]. <http://kns.cnki.net/kcms/detail/12.1420.tm.20240110.1721.002.html>.
WANG H, YAN H, ZHANG X B, et al. Joint online estimation of SOC and SOH for lithium batteries based on fractional order models[J]. Journal of Power Supply, 2024, 1-14 [2024-08-31]. <http://kns.cnki.net/kcms/detail/12.1420.tm.20240110.1721.002.html>.
- [66] GAO Y ZH, LIU K L, ZHU CH, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model[J]. IEEE Transactions on Industrial Electronics, 2021, 69(3): 2684-2496.
- [67] LI X Y, WANG ZH P, ZHANG L. Co-estimation of capacity and state-of-charge for lithium-ion batteries in electric vehicles[J]. Energy, 2019, 174: 33-44.
- [68] ELEFTHERIADIS P, GIAZITZIS S, KOWAL J, et al. Joint state of charge and state of health estimation using bidirectional LSTM and Bayesian hyperparameter optimization[J]. IEEE Access, 2024, 12: 80244-80254.
- [69] SU ZH, LI Q, YU J SH, et al. Joint estimation of SOC and SOH for lithium-ion battery based on multi-time scale [C]. 2024 IEEE 3rd International Conference on Electrical Engineering, Big Data and Algorithms(EEBDA), 2024: 11-19.

- [70] SHI N, CHEN Z W, NIU M, et al. State-of-charge estimation for the lithium-ion battery based on adaptive extended Kalman filter using improved parameter identification [J]. Journal of Energy Storage, 2022, 45: 103518.
- [71] 陈贵升,许杨松,李俊达,等.基于不同温度下SOC-OCV曲线重构的锂离子电池SOC估计[J].电源学报,2024,1-11[2024-08-31].<http://kns.cnki.net/kcms/detail/12.1420.TM.20240124.1613.008.html>. CHEN G SH, XU Y S, LI J D, et al. SOC estimation of lithium-ion batteries based on reconstructed SOC-OCV curves under different temperatures[J]. Journal of Power Supply, 2024, 1-11[2024-08-31].<http://kns.cnki.net/kcms/detail/12.1420.TM.20240124.1613.008.html>.
- [72] XIE Y, LI W, HU X S, et al. Coestimation of SOC and three-dimensional SOT for lithium-ion batteries based on distributed spatial-temporal online correction[J]. IEEE Transactions on Industrial Electronics, 2022, 70(6): 5937-5948.
- [73] DONG ZH K, JI X Y, WANG J Y, et al. ICNCS: Internal cascaded neuromorphic computing system for fast electric vehicle state of charge estimation[J]. IEEE Transactions on Consumer Electronics, 2023, 70(1): 4311-4320.
- [74] LI W H, RENTEMEISTER M, BADED A J, et al. Digital twin for battery systems: Cloud battery management system with online state-of-charge and state-of-health estimation [J]. Journal of energy storage, 2020, 30: 101557.
- [75] 陈昂辉,夏鲲,李峰,等.基于IoT的电池组云管理装置设计[J].电子测量技术,2019,42(4):6-13. CHEN ANG H, XIA K, LI ZH, et al. Design of the cloud-management device about the battery group based on IoT [J]. Electronic Measurement Technology, 2019, 42(4): 6-13.
- [76] LIU W, PLACKE T, CHAU K T. Overview of batteries and battery management for electric vehicles[J]. Energy Reports, 2022, 8: 4058-4084.
- [77] 李演明,陈忠会,杨晓冰,等.一种用于低速电动汽车的锂电池管理系统研究[J].电力电子技术,2018,52(12): 61-64. LI Y M, CHEN ZH H, YANG X B, et al. Research on a lithium battery management system for low speed electric vehicles [J]. Power Electronics, 2018, 52(12): 61-64.
- [78] 郭展岩,张鹏,侯亚飞,等.一种电动汽车的电量管理方法、装置、设备及介质:CN202210604561[P].2022-05-30. GUO ZH Y, ZHANG P, HOU Y F, et al. A method, device, equipment, and medium for power management of electric vehicles: CN202210604561[P]. 2022-05-30.
- [79] 杨世春,王锐,闫啸宇,等.一种动力电池云端监控及大数据分析系统:CN202311482283[P].2023-11-08. YANG SH CH, WANG R, YAN X Y, et al. A cloud based monitoring and big data analysis system for power batteries: CN202311482283[P]. 2023-11-08.
- [80] E·贝甘.有源植入式医疗设备和用于确定其电池可用容量的方法:CN202011398755[P].2021-06-18. E · BEGAIN. Active implantable medical devices and methods for determining their available battery capacity: CN202011398755[P]. 2021-06-18.
- [81] TERRY M B. Battery depletion monitor: WO2023IB57003[P]. 2023-07-06.
- [82] 李京波,欧恒悦,林开斌,等.一种电池使用寿命的估计系统及方法:CN202010943518[P].2023-05-26. LI J B, OU H Y, LIN K B, et al. Estimation system and method for battery life: CN202010943518[P]. 2023-05-26.

作者简介

崔相东,硕士研究生,主要研究方向为锂电池能量管理系统、锂电池荷电状态估计等。

E-mail: 23210720147@m.fudan.edu.cn

黄彦淇,工程师,主要研究方向为心脏电生理仿真、医学电子系统设计、医学信号处理等。

E-mail: yqhuang@fudan.edu.cn

邬小玫(通信作者),教授,主要研究方向为医学电子学、心脏电生理诊断/治疗方法及系统。

E-mail: xiaomeiwu@fudan.edu.cn