

# Review of the State of Health Estimation Methods for Lithium-Ion Battery

Ping Xiong, Qian Tao

Electric Power Research Institute, State Grid Hubei Electric Power Co., Ltd., Wuhan Hubei  
Email: px\_joey@163.com, 12558865@qq.com

Received: Aug. 7<sup>th</sup>, 2020; accepted: Aug. 20<sup>th</sup>, 2020; published: Aug. 27<sup>th</sup>, 2020

---

## Abstract

Due to the declining non-renewable energy sources, electric vehicles (EVs) are becoming more and more popular due to their zero carbon emissions and comfortable and light transportation. However, due to various internal and external factors, it is not easy to accurately predict the state of health (SOH) of lithium-ion battery employed in electric vehicles. For this purpose, this paper will comprehensively review and compare the current various SOH prediction models. This paper also examines some of the factors and possible solutions that affect the prediction of battery status and lifetime. Finally, this paper provides some suggestions for further technological developments in the SOH estimates for lithium-ion batteries and provides some ideas for developing advanced SOH methods for future electric vehicles.

## Keywords

Lithium-Ion Battery, Electric Vehicle, State of Health, Estimate

---

# 动力锂电池健康状态评估方法综述

熊平, 陶骞

国网湖北省电力有限公司电力科学研究院, 湖北 武汉  
Email: px\_joey@163.com, 12558865@qq.com

收稿日期: 2020年8月7日; 录用日期: 2020年8月20日; 发布日期: 2020年8月27日

---

## 摘要

由于不可再生能源的日益减少, 而电动汽车(Electric vehicles, EV)由于其具有零碳排放, 乘坐舒适和轻便等特点变得越来越受欢迎。然而, 由于各种内部和外部因素, 要准确预测电动汽车的锂电池健康状况

(state of health, SOH)等并不是一件容易的事情。基于此目的, 本文全面的回顾目前各种不同的SOH预测模型, 并进行比较, 此外本文还分析了影响电池状态和寿命的预测的一些因素。本文为锂离子电池的SOH估算的技术发展提供了一些选择性的建议。

## 关键词

锂离子电池, 电动汽车, 健康状态, 预测

Copyright © 2020 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

据估计, 以汽油和柴油为基础的燃油车辆占全球 14%碳排放量, 这也是导致全球变暖和气候变化问题的主要原因之一。电动车辆(electric vehicles, EV)由于其零排放的特点, 为解决温室气体排放和全球变暖问题提供了新的思路[1], 同时由于电动汽车近年来持续改善的性能和效率, 使得其在工业中受到越来越广泛的认可。电动汽车的性能取决于它的可靠性, 安全性, 续航能力以及电源管理系统, 然而, 最重要的是它高度依赖储能设备预测和控制电池健康问题的功能[2]。锂离子电池有寿命长, 充电快, 能量大, 电压高等显著的优点, 因此广泛的用做电动汽车的储能设备[3], 而 SOH 是用来衡量和评估锂电池健康状态的两个关键参数。准确同时又可靠的锂离子 SOH 估计方法能确保电动汽车的稳定运行。除此以外, 锂离子电池的性能还因充放电循环, 温度变化和老化等不同情况有所变化[4]。因此, 准确且健壮的 SOH 算法是必不可少的, 既可以应对挑战, 又可以改善性能从而优化车辆运行。

锂动力电池的性能随着使用次数的增加而衰减, 当锂动力电池性能下降到原性能的 80%时, 将不能达到电动汽车的使用标准, 但仍可用在对锂动力电池性能要求低的场合。经过检测、维护、重组等环节后, 仍可进一步在储能、分布式光伏发电、家庭用电、低速电动车等领域再利用。电池储能技术在电网发电、输电、配电、用电各个环节均有非常广阔的应用前景, 尤其在可再生能源并网、电网辅助服务、分布式及微网、用户侧储能等场景, 储能技术已经展现出了较高的实际应用价值。梯次利用最重要的前提是能够准确估算动力电池当前容量, 对动力电池荷电状态(State of Charge, SOC)进行实时准确估算, 而且有利于把握梯次利用每个阶段之间的临界点, 使得梯次利用更加合理, 避免能量的浪费, 降低电池利用成本。

本文将回顾和阐述目前已知的 SOH 的估算方法和策略, 以及影响 SOH 估算性能的影响因素, 为 SOH 评估提供有益的帮助。

## 2. SOH 估算方法

SOH 描述的是健康的状态, 具体来说就是一个使用过的电池当前能够提供的电量和电池在未使用时初始电量的比值, 即 SOH 为实际容量除以名义容量, 如下式所示[5]:

$$\text{SOH} = \frac{Q_{\text{act}}}{Q_{\text{nom}}} \quad (1)$$

其中  $Q_{\text{act}}$  和  $Q_{\text{nom}}$  代表实际容量和标称容量值。

SOH 反应的时电池老化或者退化状态, 并在需要更换电池的时候发出警报。一般来说, 当实际容量降到额定容量 80% 的时候, 则认为该电池已经不适用于车辆应用, 应予以更换。本文首先讨论四种用于预测锂离子电池 SOH 的方法, 分别是直接评估方法, 自适应方法, 数据驱动方法和其他方法, 如图 1 所示。

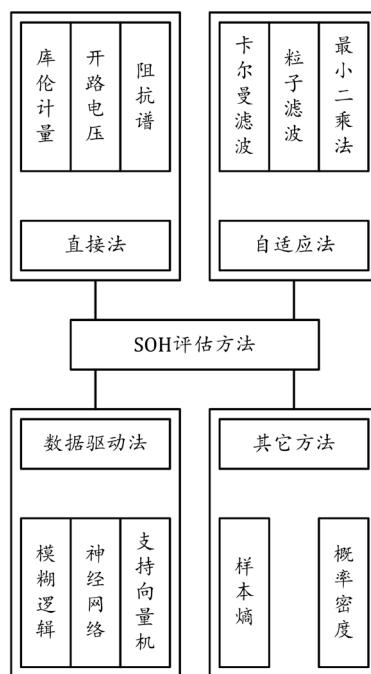


Figure 1. Evaluation method of SOH  
图 1. SOH 评估方法

## 2.1. 直接评估法

### 2.1.1. 库仑计数

库仑计数(Coulomb counting, CC)方法是用来估算 SOH 最简单直接的方法。它包括两个步骤:

- 1) 首先确定电池的  $Q_{act}$ , 将电池放电到荷电状态(State of Charge, SOC)为 0%, 对放电的电流对时间积分可以得到  $Q_{act}$ ;
- 2) 用  $Q_{act}$  除以标称容量  $Q_{nom}$ , 就可以得到 SOH 的值。

$$\begin{cases} Q_{act} = \int_0^T I(t) dt \\ SOH[\%] = \frac{Q_{act}}{Q_{nom}} \times 100\% \end{cases} \quad (2)$$

这种方法主要需要测量和控制的电池参数是: 电池的充/放电电流, 电压, 电量和温度。如果在每次放电循环中计算式(2)中的两个参数, 本方法可以很容易的实际上就变换成为一种自适应方法。

在充/放电的循环中可以发现, 随着充/放电循环次数的增加,  $Q_{act}$  的值在不断的减少[6], 从而导致 SOH 的值随着电池的使用不断降低。一般来说, 当锂电池的 SOH 值低于 80% 的时候, 就认为电池不适合用于车辆使用。很显然, 这种方法的准确性非常依赖于测量设备的精度, 因此需要对测量设备定期校准。

作者在文献[6]中指出, 库仑积分的方法很大程度依赖于对电流和初始 SOC 的准确程度。文章中提出

了一个新的参量放电深度(depth of discharge, DoD)来表征放电率, 和 SOC 类似, 如下:

$$\text{DoD}[\%] = \frac{Q_{\text{rel}}}{Q_{\text{nom}}} \times 100\% \quad (3)$$

其中  $Q_{\text{rel}}$  表示的是当前释放的电量, 在某个给定的时刻, DoD 可以表示如下:

$$\begin{cases} \text{DoD}(t) = \text{DoD}(t) + \eta \Delta \text{DoD}(t) \\ \Delta \text{DoD}(t) = \frac{-\int_{t_0}^{t_0+\tau} I_b(t) dt}{Q_{\text{nom}}} \times 100\% \end{cases} \quad (4)$$

其中,  $I_b$  是充/放电电流,  $\eta$  是工作效率。很显然, 当电池容量消耗完毕时, DoD 的值就是 SoH。在每一个充放电的循环中, 利用  $\eta$  来对 DoD 进行补偿, 此外, 在完全充电和完全放电的时刻要进行重新校准。该方法有众多优点, 比如: 检测设备成本低, 算法的功耗低, 而且容易集成[7]。预测的精度和充放电循环的次数有关, 当循环次数达到 28 次以上时, 精度可以达到 1%。

### 2.1.2. 开路电压

基于开路电压(Open circuit voltage, OCV)的 SOH 估算方法的理论基础是将 SOH 定义为被测电池 OCV 的函数。

对应于图 2, 文献[8]将 OCV 定义如下:

$$U_{\text{OCV}} = U + IR \quad (5)$$

其中,  $U_{\text{OCV}}$  是电池的开路电压,  $I$  是电池输出的电流,  $R$  是电池内阻,  $U$  是端口电压。




Figure 2. Simplified battery circuit model  
图 2. 简化电池电路模型

然而 OCV-SOH 曲线也会受到其他条件的影响, 如环境温度[8]等, 并且在测精度要求很高时, 这些影响是不可忽视的。图 3 显示了不同温度下的 OCV-SOC 曲线, 从图 3(a)可以看出, OCV 相等时, 0°C 时的 SOC 比温度高于 0°C 时的 SOC 大很多, 这说明在温度较低时, 电池释放出的能量小, 图 3(b)可以看出在温度不变的情况下, OCV 变化 0.01 V 会带来 SOC 较大的变化。在大量的实验数据的基础上, 离线的预测方式表现出了较好的精度。

Guo [9]等人监测不同寿命电池的充电曲线来评估容量的退化和模型的参数, 从而达到准确预测 SOH 的目的。借助电化学模型和恒流-恒压充电方法, 采用变换函数和非线性最小二乘法, 在各个阶段下对 SOH 的估计误差均小于 3%。

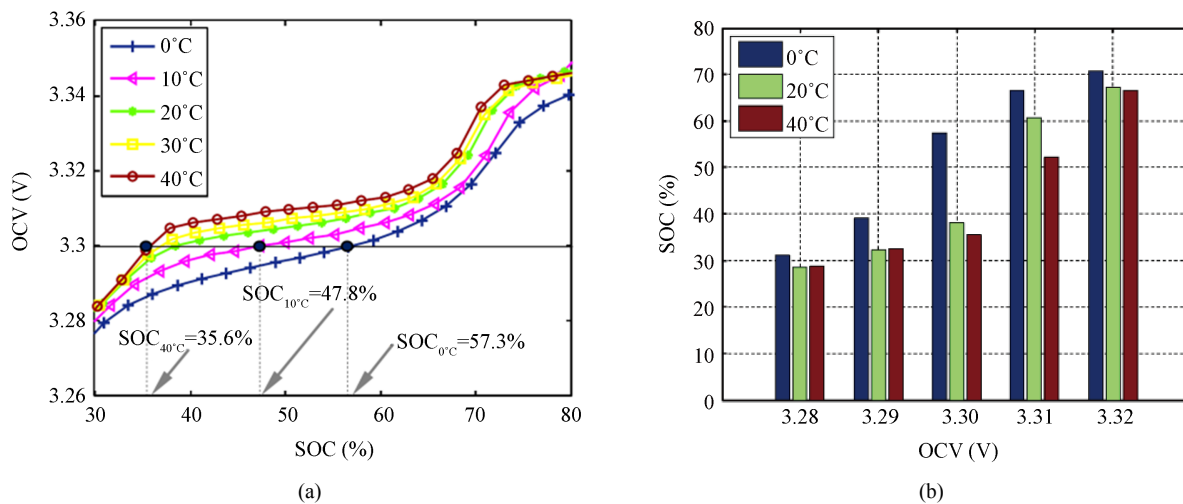
Weng 等人同样使用 OCV 模型评估 SOH [10], 并将增量容量分析的方法(ICA)用于预测不同工作温度下的电池老化特性, 采用该模型对电池进行监测, 估计的误差为 1%。

### 2.1.3. 阻抗谱

电化学阻抗谱(Electrochemical impedance spectroscopy, EIS)是一种能在小电流下对电池单元实现高


精度宽频谱测量的方法。现有的文献证明 EIS 是衡量电池 SOC 的可靠指标, 同时也用来评估 SOH。

EIS 方法通常用来确定电化学电池模型的参数[11]。对一个特定环境中的锂电池而言, 它的电化学模型含有 16 个参数, 在这 16 个参数中, 有 6 个参数是固定的, 将这 6 个参数固定的原因是它们有些对模型的拟合和输出不敏感, 或者可能会产生过拟合, 剩下的 10 个参数通过混合多粒子群算法来进行优化。



**Figure 3.** (a) OCV-SOC at different temperature; (b) SOC under specified OCV at 0°C, 20°C and 40°C [8]  
**图 3.** (a) 不同温度下的 OCV-SOC 曲线; (b) 0°C, 20°C 和 40°C 时特定 OCV 下的 SOC 值[8]

对全充满和半充满状态下的锂电池在不同循环次数下进行测试, 得到在 0.025 Hz~4 KHz 频率范围内的阻抗谱, 图 4 所示的是全充满状态下的锂电池在 200 次循环后的阻抗谱拟合曲线, 显然, 文献[11]提出的方法和测试数据的拟合更接近。对利用阻抗谱设计的模型和 Randle 模型进行对比, 其平均的均方根误差为 0.65 mΩ, 仅为 Randle 模型的 1/8。



**Figure 4.** Fitting results of fully charged battery impedance after aging cycle of 200 [11]  
**图 4.** 全充满状态下进行 200 次循环后电池阻抗谱匹配结果[11]

EIS 的方法作为一种离线的分析方法, 可以用来计算等效电路模型的参数, 并结合其它的分析方法(如:

递归神经网络等)来对电池的 SOH 进行预测分析[12]。

## 2.2. 自适应方法

### 2.2.1. 卡尔曼滤波

卡尔曼滤波(kalman filter, KF)是对过程状态进行估计非常有效的算法,它利用线性系统状态方程,通过系统输入输出观测数据,对系统状态进行最优估计。尽管卡尔曼滤波的计算复杂度比较高,但是仍然得到了非常广泛的应用,如:汽车,雷达跟踪,空间技术和导航等等。卡尔曼滤波的自纠正特性是其最吸引人的特点,将它用于电池状态的估计时它可以容忍较大的电流波动。它包含两个部分:预测阶段和更新阶段。

$$x_{k+1} = A_k x_k + B_k u_k + w_k \quad (6)$$

$$y_{k+1} = C_k x_k + D_k u_k + v_k \quad (7)$$

其中  $x$  表示系统状态,  $u$  是控制输入,  $w$  是过程噪声,  $y$  是测量输入,  $v$  是测量噪声,  $A$ ,  $B$ ,  $C$  和  $D$  是用来描述系统动态特性的时变协方差矩阵。

Ting 等人[13]采用含有 RC 电池模型的的电池管理系统(battery management system, BMS)进行卡尔曼滤波建模,从 RC 模型中导出的数学表达形式采用状态空间模型来描述电池的动态特性,实验结果显示采用卡尔曼滤波对电池的 SOC 估计结果的均方根误差为  $1.92 \times 10^{-4}$  V,相对于测量误差(1.0013 V)来说是相当小的。卡尔曼滤波主要用于线性系统的预测,而双扩展卡尔曼滤波器(dual extended Kalman filter, DEKF),无损卡尔曼滤波器(unscented kalman filter, UKF)则可以用于对非线性系统的估计。

Kim 等人[14]采用基于 DEKF 的协同互补算法对电池的 SOH 进行预测。结合电池的参数,选取了两种模式识别作为具有代表性的模式,即充/放电电压模式(discharging/charging voltage pattern, DCVP)和容量模式(capacity pattern, CP),选择汉明神经网络用于确定一阶 Randle 电路模型参数,并利用 DEKF 实现对 SOC/容量的估计和 SOH 的预测,结果显示估算的误差为 $\pm 5\%$ 。

天津大学谷苗等给出一种综合型卡尔曼滤波算法[15]。该算法采用递推最小二乘算法(RLS)对锂离子电池模型参数进行实时在线辨识和参数更改;采用综合型卡尔曼滤波器估计电池 SOH,即针对模型状态空间方程中的线性部分和非线性部分,分别使用线性卡尔曼滤波器和平方根高阶容积卡尔曼滤波器(Square-root High-degree Cubature Kalman Filter, SHCKF, SHCKF)计算。两种卡尔曼滤波器结合的综合型策略能够有效减小计算复杂度。其中,SHCKF 结合了五阶球面-径向容积法则和平方根滤波技术,比扩展卡尔曼滤波器、无迹卡尔曼滤波器和容积卡尔曼滤波器(Cubature Kalman, CKF)等传统非线性滤波器的估计精度更高,数值稳定性更强。实验结果证明了该综合型算法的可行性和有效性,估算误差被控制在 0.6%以内,实现了 SOH 精确估计。

### 2.2.2. 粒子过滤器

粒子滤波(Particle filter, PF)采用采样重要性重采样(sampling importance resampling, SIR)算法和一系列的加权粒子来估计概率密度函数(probability density function, PDF)。

通过采用蒙特卡罗抽样技术,粒子滤波器通过用一组粒子或样本近似各自的概率密度函数,提供了处理任何类型分布的可能性。对于具有开路电压迟滞的  $\text{LiFePO}_4$  电池,这提供了使用多模态分布随机建模这种行为的可能性。基于此,Schwunk 等[16]提出了一种处理困难和模糊电池的框架,如  $\text{LiFePO}_4$ /石墨电池。开路电压的模糊范围是随机模拟的,通过蒙特卡罗表示电池的状态分布和样本,开辟了多模态估计电池充电状态的可能性。因此,该算法既能找到正确的起始值,又能正确地跟踪电荷状态,这为正确估计电池的 SOH 奠定了基础。与跟踪迟滞行为的物理方法相比,这种随机建模的主要优点是建模快速,不需要迟滞的起始状态,并且有可能用它们的概率指示几个合理的状态。该算法在文中给出的实例中达

到了较高的精度, SOC 和 SOH 估计的误差值均处于很低的水平。

随着仿真模拟时间的增加, 算法过程中的重要性权值可能集中在少数粒子上, 使预测结果偏离, 这称为粒子退化现象。标准 PF 的重采样步骤虽然减缓了粒子退化, 但是预测值和实际值的误差没有得到补偿。诸多学者在粒子滤波的重采样步骤提出了算法改进, 保证了滤波算法的质量。Jun Bi 等[17]提出基于遗传重采样粒子滤波算法(Genetic Particle filter, GPF), 其基本思想是将进化思想(即选择, 交叉和变异)整合到 PF 算法中, 由于遗传算法具有特殊的搜索优化能力, 能有效地增加粒子的多样性, 解决粒子退化问题, 提高状态估计的准确性。GPF 将欧姆电阻用作电池 SOH 的评估指标, 实验结果表明 GPF 算法的电池内阻估算值明显大于 PF 算法, 如图 5 所示。林娜等[18]提出基于引力场粒子滤波算法, 用于更新粒子滤波完成一步权重计算后的粒子群体的位置, 通过随机分组, 寻找权值最大的中心粒子, 并计算中心粒子对周围粒子引力、排斥力作用, 更新每个粒子的位置, 再进行权值更新和重采样。与 PF 算法的跟踪结果比较, GPF 算法能有效的避免粒子退化问题。




Figure 5. Comparison of estimation results for internal resistance by GPF and PF [17]

图 5. GPF 算法和 PF 算法对内阻估算结果的比较[17]

### 2.2.3. 最小二乘法

最小二乘法(least squares, LS)是一种数学回归分析的形式, 用于确定一组数据的最佳拟合线, 描述数据点之间关系, 每个数据点表示已知自变量和未知因变量之间的关系。最小二乘法具有实现简单, 计算复杂程度低等优点, 因此 LS 及其改进的各类算法被广泛的应用于参数识别的应用之中。利用非线性 LS 算法很容易实现对模型参数的离线识别, 但是不适用于在线实时参数的识别, 在线的参数识别通常是采用递归最小二乘算法(recursive least squares, RLS), Duong 等提出了一个新颖的 RLS 算法, 算法基于一个简化的模型并采用多个自适应遗忘因子, 来准确捕获实时变量和动态参数[19]。提出的方法在城市道路循环工况(Urban Dynamometer Driving Schedule, UDSS)和欧洲新行驶工况下(New European Driving Cycle, NEDS)进行了验证, 实验结果表明, 不仅 SOC 估计的绝对误差小于 2.8%, 而且电池模型参数更准确。

山东大学朱瑞等以锂离子电池二阶 RC 等效电路模型为研究对象, 提出一种基于分布式最小二乘的

模型辨识参数方法[20]。此方法根据电池不同时间尺度可以分离的特性, 将电池模型细分为两个子模型分别进行辨识, 避免了待估参数的相互干扰, 因而能够取得更好的参数估计效果。试验结果表明, 相比传统的递推最小二乘辨识方法, 提出的方法在城市道路循环(Urban Dynamo-meter Driving Schedule, UDDS)和联邦城市运行工况(Federal Urban Driving Schedule, FUDS)工况下能够将平均绝对误差分别降低约 50.0% 和 28.57%, 均方根误差分别减小约 46.43%和 29.17%, 验证了所提方法的有效性和可行性。

## 2.3. 数据驱动的方法

### 2.3.1. 模糊逻辑

模糊逻辑(Fuzzy Logic, FL)通过使用模糊逻辑理论的规则处理测量数据, 从而对非线性和复杂系统进行建模, 并在计算中引入一定的不确定性。FL 所用到的测量的数据可以分为清晰集或模糊集。清晰集采用确定性对数据进行分类, 而模糊集中的数据则具有不确定性。比如, 对学生的成绩进行分类, 成绩在 80~90 之间的集合就是清晰集, 而用“中等”对成绩进行归类的话, 即得到一个模糊集。每个模糊子集由其所谓的隶属函数(membership function, MF)定义, 集合中的每个元素都有一个隶属度, 表示属于不同子集的程度。

文献[21]基于模糊逻辑建模, 对锂/二氧化硫和镍/金属氢化物两种电池系统进行了 SOC 和 SOH 预测。基于此理论, 设计了一个电池测试设备原型, 同时对设备进行了测试, 并计划实现到商业应用。该设备原型采用一个 LM35CZ 温度传感器和一个用于电流传感的 0.1 V 电阻器通过信号调理电路与摩托罗拉 68HC11 微控制器的模数 A/D 转换器线路连接。为确定和显示电池 SOC, 软件使用了四个模块。第一个模块采样 A/D 线, 获取感测电流和温度; 第二个模块是 FL 模型, 由它确定随电流和温度的变化的电池放电效率; 第三个模块是一个显示驱动程序; 第四个模块是对其他三个模块进行调度, 实现对当前的电池 SOC 的计算和显示。通过对锂/二氧化硫电池的测试表明预测的容量和实际容量一致, 误差在 5%以内。

SOH 的准确预测取决于对 MF 的适当选择。Landi 和 Gross [22]使用两个指数函数计算 SOH 指数, 如下所示,

$$y_{fit} = a_0 + a_1 e^{-\left(\frac{x}{a_1}\right)^{\beta_1}} + a_2 e^{-\left(\frac{x}{a_2}\right)^{\beta_2}} \quad (8)$$

其中  $x$  表示循环数,  $y$  表示归一化容量值。采用模糊算法对拟合函数进行估计。在第一步中, FL 使用拟合曲线计算健康指数, 误差介于 5%和 10%之间。在第二步中, 使用神经网络来评估健康指数, 以将误差降低到低于 5%。

### 2.3.2. 神经网络

神经网络算法即通过神经网络建模及不断学习调整结构参数模拟电池的真实输入与输出关系, 实现 SOH 估算目的。应用较为广泛的有 BP (Back Propagation)神经网络、Elman 神经网络、RBF (Radical Basis Function)神经网络等。

BP 神经网络典型结构如图 6 所示。神经网络的输入通常是与电池健康状态相关的变量, 输出层根据应用场景的不同, 可能是电池直流内阻或电池容量。

神经网络(Neural Network, NN)有许多优点, 它具有处理复杂非线性系统的大量数据的能力, 用于对电池 SOH 的预测时, 不需要详细的电池特性信息, 此外, NN 具有在不同操作条件下准确预测 SOH 的鲁棒算法[23] [24]。然而, 高计算成本是实现 NN 算法的缺点之一, 此外, NN 的另一缺点是训练网络需要大量的历史数据。神经元激活函数可以用来模拟电池的电化学性能[25]。



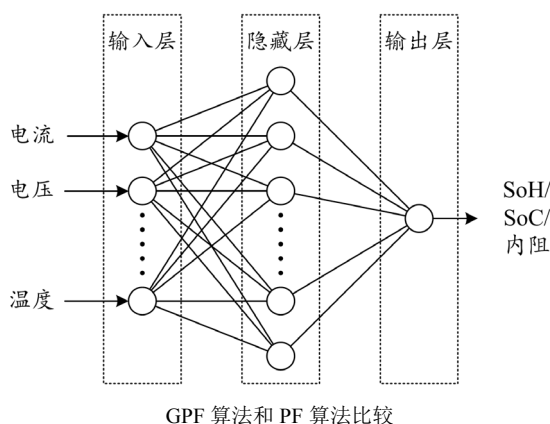


Figure 6. Standard BP neural network  
图 6. 典型 BP 神经网络结构

NN 的输入向量由  $r_k = [V_k \ I_k \ SOC_k]^T$  表示, 其中  $V_k$ ,  $I_k$ ,  $SOC_k$  指示采样时刻  $k$  的电压, 电流和 SOC。 $\sigma_i$  表示标准差,  $M$  表示隐藏层中的神经元个数。神经网络输出的是在第  $k+1$  时刻的端口电压, 然后利用模糊系统以及电压 - 容量曲线来对 SOH 进行估计, 为了获取较高的预测精度, 需要离线的电池循环特性来对网络进行训练。

Elman 神经网络隐含层存在反馈环节, 能记录以前时刻隐含层状态。刘婉晴[26]选用遗传与蚁群的混合算法(GAAA)对 Elman 神经网络进行改进, 改善了电池 SOH 预测的运算速度和精度。韩丽等[27]建立 Elman 神经网络模型, 并结合遗传算法(Genetic Algorithm, GA)对初始权值和阈值进行优化, 预测电池劣化程度。

RBF 神经网络是一种局部逼近网络, 相比于 BP 神经网络, 它只需要对少量权值和阈值进行修正, 因此训练速度快。Lin 等人采用概率神经网络(Probabilistic Neural Network, PNN)的方法, 对 Li-Co 电池 SOH 进行了估算[28]。Zhang 等利用粒子群优化(Particle Swarm Optimization, PSO)算法来优化 RBF 神经网络权值, 预测精度可提高 20%, 节省 66.7% 以上的优化时间[29]。

### 2.3.3. 支持向量机

支持向量机(Support vector machine, SVM)能分析数据并识别非线性系统的模式, 它使用回归分析来解决非线性问题, 需要运用到支持向量机在回归问题上的推广算法 - 支持向量回归(Support Vector Regression, SVR) [30], 因此可以作为预测锂离子电池 SOH 合适的技术。

锂电池 SOH 估算属于线性不可分问题, 因此需要引入核方法(kernel methods, KMs)将数据映射到高维空间, 转化为线性可分问题[31]。核函数的选取和超参数优化关系着模型的计算量和准确性。SVR 方法所需存储空间小, 且泛化能力强, 理论基础完善, 是锂电池 SOH 估算领域最有效的方法之一; 为了解决 SVR 模型中的超参数优化问题, 刘皓等人[32]提出一种结合遗传算法和 SVR (Genetic algorithm-support vector regression, GA-SVR)的锂电池 SOH 预测算法, 利用 GA 算法进行参数寻优; 卢明哲[33]从电池的实验室充放电循环数据出发, 采用 C-SVR 算法估计了电池的健康状态; 孙猛猛[34]基于锂离子电池部分恒流充电数据和 SVM 方法估算 SOH, 建立了 LS-SVM (Least Squares Support Vector Machine)模型。

Nuhicet 等人[35]结合支持向量机算法与训练和测试数据一起用于估计不同环境和负载条件下的 SOH 值。通过对锂离子电池不同老化程度的密集测量, 从锂离子电池中收集了大量的数据。使用不同温度下的驱动循环进行了验证, 在诊断电池健康方面取得了满意的结果。

## 2.4. 其他

### 2.4.1. 样本熵

近似熵(Approximate Entropy, ApEn)和样本熵(Sample entropy, SampEn)是量化时间序列复杂性和研究时间序列特征的重要工具, 广泛应用于许多领域。SampEn 是 ApEn 的一种改进形式。SampEn 不仅具有 ApEn 的所有优点, 而且消除了自匹配, 加快了计算速度。而 SampEn 对记录长度不敏感, 与 ApEn 相比, 一致性有所提高。当它应用于电池老化过程中有变化的电池数据时, 它可以作为 SOH 估计[36]的指标。

混合脉冲功率特性(Hybrid pulsepower characterization, HPPC)电压序列对电池老化高度敏感, 通常选择 SampEn 作为 SOH 指示器。Hu 等人[37]采用基于最小二乘优化的容量估计器的样本熵来获得三个不同温度下 8 个锂离子电池的老化数据集。利用混合脉冲功率特性(Hybrid pulsepower characterization, HPPC), 获得了具有容量损耗的样本熵单元电压。结果表明, 该模型具有较好的鲁棒性, 平均相对误差为 2%。

为了获得更好、更准确的结果, SampEn 可以与机器学习方法相结合, Widodo [36]采用以电池放电电压为特征的 SampEn, 将支持向量机 SVM、关联向量机 RVM 与 SampEn 相结合, 表现出很好的性能。除了电压外, 电池的表面温度也可以作为 SampEn 的特性之一。

样本熵方法具有良好的估计精度, 绝对误差约为 2%, 可在线运行、离线运行或两者结合运行。主要的缺点是需要进行向量/矩阵和指数函数的运算, 所需的计算复杂度很高。

### 2.4.2. 概率密度函数

概率密度函数(Probability Density Function, PDF)是一个描述连续型随机变量的输出值, 在某个确定的取值点附近的可能性的函数。Feng 等[38]使用了基于充放电数据的 PDF 算法计算电池容量。PDF 可用来对 SOH 进行监测, 首先离线计算 SOH 和 PDF 曲线之间的关系, 然后在线解决方案模型使用离线数据进行预测。使用 PDF 估计 SOH 的优点简单, 而且它比曲线拟合算法更精确, 但是它需要高精度的电流和电压测量, 从而使得成本较高。该方法的估计误差在 2%以下, 计算复杂度较高。电池的离线特性需要通过大量的电池测试获取, 是这种技术的一个重要缺点。

## 3. 影响 SOH 的其它因素

随着时间的推移, 因为各种内部和外部因素, 造成电池性能的下降, 因此这些因素对锂离子电池的 SOH 的估算也会有很大的影响。影响 SOH 的因素包括, 电池材料, 温度, 过度充放电, 迟滞现象以及电池老化等等。

锂离子电池的性能取决于各种内部材料性能。锂离子电池由阴极、阳极、电解液和分离器四部分组成。正极材料的选择控制着电池的动力、安全性、成本和寿命等特性。正极材料有钴酸锂(lithium cobalt oxide, LCA)、锰酸锂(lithium manganese oxide, LMO)、磷酸铁锂(lithium iron phosphate, LFP)、镍锰钴酸锂(lithium nickel manganese cobalt oxide, NMC)和镍钴铝酸锂(lithium nickel cobalt aluminum oxide, NCA)。不同材料电池其性能也会不同, 比如 LCA 的有限的负载能力会影响它的性能[39], 需要控制充放电速率; LMO 电池的优点是倍率性能好, 但是由于锰的溶解导致高温性能和循环性能不佳; LFP 的低温性能差, 使用寿命受到温度变化的影响很大[5]; 三元锂(NMC、NCA)表现出良好的整体性能[40], 电池体积小、能力密度高、耐低温, 但是其高温性能较差。

因为在任何放电电流倍率下都会发生电池活性物质的转变, 从而导致电池的可用电量减少, 而容量衰减与温度有很大关系。Jaguemont 等[41]在 $-20^{\circ}\text{C}$ ,  $-10^{\circ}\text{C}$ ,  $0^{\circ}\text{C}$ ,  $25^{\circ}\text{C}$ 下, 以三种不同的电流对 100 Ah  $\text{LiFeMnPO}_4$  正极锂离子电池进行放电实验, 实验结果表明以 50 A 电流进行放电,  $-20^{\circ}\text{C}$ 时电池容量只有  $25^{\circ}\text{C}$ 温度下时容量的 60%。

重复的充放电会导致电池物理性质的变化, 串联连接的锂离子电池会产生充电不平衡的问题[43] [44], 频繁的过放电和大电流放电会缩短电池寿命[45]。过充测试表明, 当电池以 150%过量充电时, 电池材料会发生不可逆转的损失[46]。相反, 过度放电测试说明, 过度放电的电池会加速电池老化速度[47]。电池的性能会随着老化而降低, 研究人员发现阳极/阴极材料, 表面膜形成/改性, 以及相变是电极发生老化的主要因素[48]。Leng 等[42]探索了温度从 25°C到 55°C变化时, 老化行为对锂离子电池的影响。结果表明电阻和电容的值随着老化周期的增加而变化, 如图 7 所示。




Figure 7. The aging of resistance vs. temperature [42]

图 7. 不同温度下老化对电池内阻的影响[42]




Figure 8. OCV curves of the  $\text{LiFePO}_4$ -based cells depending on the previous current direction, measured after various rest periods at each step [50]

图 8.  $\text{LiFePO}_4$  电池在不同休息间隔下充放电的 OCV-SOC 曲线[50]

由于极化电阻的影响, 锂离子电池充电电压高于放电电压, 这种现象称为迟滞效应, 会对 SOC 估算结果产生错误[49]。图 8 所示的是 LiFePO<sub>4</sub> 电池在充、放电期间 OCV 和 SOC 之间的关系曲线[50]。发生迟滞现象的主要原因是锂离子电池具有欧姆电阻, 电化学极化和浓差极化。此外, 在相变过程中电极中的能量耗散也可能产生迟滞效应[51]。为了刻画锂电池的迟滞现象需要适当的算法, 基于 OCV-SOC 之间的关系, Zhu 等[52]建立了 LiFePO<sub>4</sub> 电池的自适应离散 Preisach 模型以减少迟滞的影响, SOC 估算性能取得了显著的提高, 误差降低到 1% 以内。

由于电池正负极材料的不同, 环境温度的影响, 老化以及迟滞现象等因素对电池 SOC/SOH 估计的影响, 未来电池模型和深度学习模型的更新和开发, 必须使其更适合于老化过程的参数表征, 多模型融合方法是提高模型适应性的新研究方向。

#### 4. 结论

本文旨在全面分析关于估计 SOH 的各种方法, 对不同方法的算法、特点、精度、优缺点进行了阐述, 同时本文详细讨论了各种对 SOH 有影响的因素。

对 SOH 的估算采用的方法有传统方法、基于模型的方法和智能算法等方法。传统的估计方法功耗低, 易于实现, 但极易受到老化、温度和外界干扰的影响。基于模型的估计具有计算量小、时间效率高等优点。然而, 由于模型的不确定性, 这些方法的鲁棒性较差。电池老化、温度和噪声可以通过智能算法来解决, 然而, 这些方法具有复杂的计算能力, 需要大量的数据来进行适当的训练。

#### 参考文献

- [1] Hofmann, J., Guan, D., Chalvatzis, K. and Huo, H. (2016) Assessment of Electrical Vehicles as a Successful Driver for Reducing CO<sub>2</sub> Emissions in China. *Applied Energy*, **184**, 995-1003. <https://doi.org/10.1016/j.apenergy.2016.06.042>
- [2] Sulaiman, N., Hannan, M.A., Mohamed, A., Majlan, E.H. and Wan Daud, W.R. (2015) A Review on Energy Management System for Fuel Cell Hybrid Electric Vehicle: Issues and Challenges. *Renewable & Sustainable Energy Reviews*, **52**, 802-814. <https://doi.org/10.1016/j.rser.2015.07.132>
- [3] Opitz, A., Badami, P., Shen, L., Vignarooban, K. and Kannan, A.M. (2017) Can Li-Ion Batteries Be the Panacea for Automotive Applications. *Renewable & Sustainable Energy Reviews*, **68**, 685-692. <https://doi.org/10.1016/j.rser.2016.10.019>
- [4] Lipu, M.S.H., Hannan, M.A., Hussain, A., Saad, M.H.M., Ayob, A. and Blaabjerg, F. (2018) State of Charge Estimation for Lithium-Ion Battery Using Recurrent NARX Neural Network Model Based Lighting Search Algorithm. *IEEE Access*, **6**, 28150-28161. <https://doi.org/10.1109/ACCESS.2018.2837156>
- [5] Chen, Y., Miao, Q., Zheng, B., Wu, S. and Pech, M. (2013) Quantitative Analysis of Lithium-Ion Battery Capacity Prediction via Adaptive Bathtub-Shaped Function. *Energies*, **6**, 3082-3096. <https://doi.org/10.3390/en6063082>
- [6] Ng, K.S., Moo, C.S., Chen, Y.P. and Hsieh, Y.C. (2009) Enhanced Coulomb Counting Method for Estimating State-of-Charge and State-of-Health of Lithium-Ion Batteries. *Applied Energy*, **86**, 1506-1511. <https://doi.org/10.1016/j.apenergy.2008.11.021>
- [7] Waag, W., Fleischer, C. and Sauer, D.U. (2014) Critical Review of the Methods for Monitoring of Lithium-Ion Batteries in Electric and Hybrid Vehicles. *Journal of Power Sources*, **258**, 321-339. <https://doi.org/10.1016/j.jpowsour.2014.02.064>
- [8] Xing, Y.J., He, W., Pecht, M. and Tsui, K.L. (2014) State of Charge Estimation of Lithium-Ion Batteries Using the Open Circuit Voltage at Various Ambient Temperatures. *Applied Energy*, **113**, 106-115. <https://doi.org/10.1016/j.apenergy.2013.07.008>
- [9] Guo, Z., Qiu, X.P., Hou, G.D., Liaw, B.Y. and Zhang, C.S. (2014) State of Health Estimation for Lithium Ion Batteries Based on Charging Curves. *Power Sources*, **249**, 457-462. <https://doi.org/10.1016/j.jpowsour.2013.10.114>
- [10] Weng, C.H., Sun, J. and Peng, H. (2014) A Unified Open-Circuit-Voltage Model of Lithium-Ion Batteries for State-of-Charge Estimation and State-of-Health Monitoring. *Power Sources*, **258**, 228-237. <https://doi.org/10.1016/j.jpowsour.2014.02.026>
- [11] Li, S.E., Wang, B., Peng, H. and Hu, X. (2014) An Electro-Chemistry Based Impedance Model for Lithium-Ion Batteries. *Journal of Power Sources*, **258**, 9-18. <https://doi.org/10.1016/j.jpowsour.2014.02.045>

- [12] Eddahech, A., Briat, O., Bertrand, N., Deletage, J.Y. and Vinassa, J.M. (2012) Behavior and State-of-Health Monitoring of Li-Ion Batteries Using Impedance Spectroscopy and Recurrent Neural Networks. *International Journal of Electrical & Power Energy Systems*, **42**, 487-494. <https://doi.org/10.1016/j.ijepes.2012.04.050>
- [13] Ting, T.O., Man, K.L., Lim, E.G. and Leach, M. (2014) Tuning of Kalman Filter Parameters via Genetic Algorithm for State-of-Charge Estimation in Battery Management System. *The Scientific World Journal*, **2014**, Article ID: 176052. <https://doi.org/10.1155/2014/176052>
- [14] Kim, J., Lee, S. and Cho, B.H. (2012) Complementary Cooperation Algorithm Based on DEKF Combined with Pattern Recognition for SOC/Capacity Estimation and SOH Prediction. *IEEE Transactions on Power Electronics*, **27**, 436-451. <https://doi.org/10.1109/TPEL.2011.2158554>
- [15] 谷苗, 夏超英, 田聪颖. 基于综合型卡尔曼滤波的锂离子电池荷电状态估算[J]. 电工技术学报, 2019, 34(2): 419-426.
- [16] Schwunk, S., Armbruster, N., Straub, S., Kehl, J. and Vetter, M. (2013) Particle Filter for State of Charge and State of Health Estimation for Lithium-Iron Phosphate Batteries. *Journal of Power Sources*, **239**, 705-710. <https://doi.org/10.1016/j.jpowsour.2012.10.058>
- [17] Bi, J., Zhang, T., Yu, H.Y. and Kang, Y.Q. (2016) State-of-Health Estimation of Lithium-Ion Battery Packs in Electric Vehicles Based on Genetic Resampling Particle Filter. *Applied Energy*, **182**, 558-568. <https://doi.org/10.1016/j.apenergy.2016.08.138>
- [18] 林娜, 朱武, 邓安全. 基于引力场粒子滤波算法估算锂电池健康状态[J]. 科技创新与应用, 2019(25): 32-33.
- [19] Duong, V., Bastawrous, H.A., Lim, K., See, K.W., Zhang, P. and Dou, S.X. (2015) Online State of Charge and Model Parameters Estimation of the LiFePO<sub>4</sub> Battery in Electric Vehicles Using Multiple Adaptive Forgetting Factors Recursive Least-Squares. *Journal of Power Sources*, **296**, 215-224. <https://doi.org/10.1016/j.jpowsour.2015.07.041>
- [20] 朱瑞, 段彬, 温法政, 张君鸣, 张承慧. 基于分布式最小二乘法的锂离子电池建模及参数辨识[J]. 机械工程学报, 2019(20): 1-9.
- [21] Salkind, A.J., Fennie, C., Singh, P., Atwater, T. and Reisner, D.E. (1999) Determination of State-of-Charge and State-of-Health of Batteries by Fuzzy Logic Methodology. *Journal of Power Sources*, **80**, 293-300. [https://doi.org/10.1016/S0378-7753\(99\)00079-8](https://doi.org/10.1016/S0378-7753(99)00079-8)
- [22] Landi, M. and Gross, G. (2014) Measurement Techniques for Online Battery State of Health Estimation in Vehicle-to-Grid Applications. *IEEE Transactions on Instrumentation and Measurement*, **63**, 1224-1234. <https://doi.org/10.1109/TIM.2013.2292318>
- [23] Hannan, M.A., Hoque, M.M., Hussain, A., Yusof, Y. and Ker, P.J. (2018) State-of-the-Art and Energy Management System of Lithium-Ion Batteries in Electric Vehicle Applications: Issues and Recommendations. *IEEE Access*, **6**, 19362-19378. <https://doi.org/10.1109/ACCESS.2018.2817655>
- [24] Hannan, M.A., Lipu, M.S.H., Hussain, A., Saad, M.H. and Ayob, A. (2018) Neural Network Approach for Estimating State of Charge of Lithium-Ion Battery Using Backtracking Search Algorithm. *IEEE Access*, **6**, 10069-10079. <https://doi.org/10.1109/ACCESS.2018.2797976>
- [25] Shahriari, M. and Farrokhi, M. (2013) Online State-of-Health Estimation of VRLA Batteries Using State of Charge. *IEEE Transactions on Industrial Electronics*, **60**, 191-202. <https://doi.org/10.1109/TIE.2012.2186771>
- [26] 刘婉晴. 电池健康状态估算[J]. 华南理工大学学报(自然科学版), 2017, 39(1): 91-95.
- [27] 韩丽, 戴广剑, 李宁. 基于 GA-Elman 神经网络的电池劣化程度预测研究[J]. 电源技术, 2013, 37(2): 249-250.
- [28] Li, H.T., Liang, T.J. and Chen, S.M. (2013) Estimation of Battery State of Health Using Probabilistic Neural Network. *IEEE Transactions on Industrial Informatics*, **9**, 679-685. <https://doi.org/10.1109/TII.2012.2222650>
- [29] Zhang, R., Xu, F., Chen, J.L., et al. (2016) Li-Ion Battery SOH Prediction Based on PSO-RBF Neural Network. *China Mechanical Engineering*, **27**, 2975-2981.
- [30] Basak, D., Srimanta, P. and Patranbis, D.C. (2007) Support Vector Regression. *Neural Information Processing Letters & Reviews*, **11**, 203-224.
- [31] 李睿琪, 汪玉洁, 陈宗海. 一种基于支持向量机的锂电池健康状态评估方法[M]. 合肥: 中国科技大学出版社, 2016: 55-60.
- [32] 刘皓, 胡明昕, 朱一亨, 等. 基于遗传算法和支持向量回归的锂电池健康状态预测[J]. 南京理工大学学报, 2018, 42(3): 329-334.
- [33] 卢明哲. 动力电池 SOH 估计及故障预测方法研究[D]: [硕士学位论文]. 北京: 北京工业大学, 2015.
- [34] 孙猛猛. 基于数据驱动方法的锂离子电池健康状态估计[D]: [硕士学位论文]. 昆明: 昆明理工大学, 2018.
- [35] Nuhic, A., Terzimehic, T., Soczka-Guth, T., Buchholz, M. and Dietmayer, K. (2013) Health Diagnosis and Remaining

- Useful Life Prognostics of Lithium-Ion Batteries Using Data-Driven Methods. *Journal of Power Sources*, **239**, 680-688. <https://doi.org/10.1016/j.jpowsour.2012.11.146>
- [36] Widodo, A., Shim, M.-C., Caesarendra, W. and Yang, B.-S. (2011) Intelligent Prognostics for Battery Health Monitoring Based on Sample Entropy. *Expert Systems with Application*, **38**, 11763-11769. <https://doi.org/10.1016/j.eswa.2011.03.063>
- [37] Hu, X., Li, S.E., Jia, Z. and Egardt, B. (2014) Enhanced Sample Entropy-Based Health Management of Li-Ion Battery for Electrified Vehicles. *Energy*, **64**, 953-960. <https://doi.org/10.1016/j.energy.2013.11.061>
- [38] Feng, X., Li, J., Ouyang, M., Lu, L., Li, J. and He, X. (2013) Using Probability Density Function to Evaluate the State of Health of Lithium-Ion Batteries. *Journal of Power Sources*, **232**, 209-218. <https://doi.org/10.1016/j.jpowsour.2013.01.018>
- [39] Kim, M.Y., Kim, J.H. and Moon, G.W. (2014) Center-Cell Concentration Structure of a Cell-to-Cell Balancing Circuit with a Reduced Number of Switches. *IEEE Transactions on Power Electronics*, **29**, 5285-5297. <https://doi.org/10.1109/TPEL.2013.2292078>
- [40] Omar, N., Verbrugge, B., Mulder, G., Van Den Bossche, P., Van Mierlo, J., Daowd, M., Dhaens, M. and Pauwels, S. (2010) Evaluation of Performance Characteristics of Various Lithium-Ion Batteries for Use in BEV Application. *IEEE Vehicle Power and Propulsion Conference*, Lille, 1-6. <https://doi.org/10.1109/VPPC.2010.5729083>
- [41] Jaguemont, J., Boulon, L., Dube, Y. and Poudrier, D. (2014) Low Temperature Discharge Cycle Tests for a Lithium-Ion Cell. 2014 *IEEE Vehicle Power and Propulsion Conference (VPPC)*, Coimbra, 1-6. <https://doi.org/10.1109/VPPC.2014.7007097>
- [42] Leng, F., Tan, C.M. and Pecht, M. (2015) Effect of Temperature on the Aging Rate of Li-Ion Battery Operating above Room Temperature. *Scientific Reports*, **5**, Article No. 12967. <https://doi.org/10.1038/srep12967>
- [43] Bragard, M., Soltau, N., Thomas, S. and De Doncker, R.W. (2010) The Balance of Renewable Sources and User Demands in Grids: Power Electronics for Modular Battery Energy Storage Systems. *IEEE Transactions on Power Electronics*, **25**, 3049-3056. <https://doi.org/10.1109/TPEL.2010.2085455>
- [44] Cao, J. and Emadi, A. (2012) A New Battery/Ultracapacitor Hybrid Energy Storage System for Electric, Hybrid, and Plug-In Hybrid Electric Vehicles. *IEEE Transactions on Power Electronics*, **27**, 122-132. <https://doi.org/10.1109/TPEL.2011.2151206>
- [45] Kim, J., Shin, J., Chun, C. and Cho, B.H. (2012) Stable Configuration of a Li-Ion Series Battery Pack Based on a Screening Process for Improved Voltage/SOC Balancing. *IEEE Transactions on Power Electronics*, **27**, 411-424. <https://doi.org/10.1109/TPEL.2011.2158553>
- [46] Belov, D. and Yang, M.-H. (2008) Failure Mechanism of Li-Ion Battery at Overcharge Conditions. *Journal of Solid State Electrochemistry*, **12**, 885-894. <https://doi.org/10.1007/s10008-007-0449-3>
- [47] Maleki, H. and Howard, J.N. (2006) Effects of Overdischarge on Performance and Thermal Stability of a Li-Ion Cell. *Journal of Power Sources*, **160**, 1395-1402. <https://doi.org/10.1016/j.jpowsour.2006.03.043>
- [48] Danzer, M.A., Liebau, V. and Maglia, F. (2015) Aging of Lithium-Ion Batteries for Electric Vehicles. In: *Advances in Battery Technologies for Electric Vehicles*, Elsevier, Amsterdam, 359-387. <https://doi.org/10.1016/B978-1-78242-377-5.00014-5>
- [49] Marongiu, A., Nußbaum, F.G.W., Waag, W., Garmendia, M. and Sauer, D.U. (2016) Comprehensive Study of the Influence of Aging on the Hysteresis Behavior of a Lithium Iron Phosphate Cathode-Based Lithium Ion Battery—An Experimental Investigation of the Hysteresis. *Applied Energy*, **171**, 629-645. <https://doi.org/10.1016/j.apenergy.2016.02.086>
- [50] Roscher, M.A. and Sauer, D.U. (2011) Dynamic Electric Behavior and Open-Circuit-Voltage Modeling of LiFePO<sub>4</sub>-Based Lithium Ion Secondary Batteries. *Journal of Power Sources*, **196**, 331-336. <https://doi.org/10.1016/j.jpowsour.2010.06.098>
- [51] Barai, A., Widanage, W.D., Marco, J., McGordon, A. and Jennings, P. (2015) A Study of the Open Circuit Voltage Characterization Technique and Hysteresis Assessment of Lithium-Ion Cells. *Journal of Power Sources*, **295**, 99-107. <https://doi.org/10.1016/j.jpowsour.2015.06.140>
- [52] Zhu, L., Sun, Z., Dai, H. and Wei, X. (2015) A Novel Modeling Methodology of Open Circuit Voltage Hysteresis for LiFePO<sub>4</sub> Batteries Based on an Adaptive Discrete Preisach Model. *Applied Energy*, **155**, 91-109. <https://doi.org/10.1016/j.apenergy.2015.05.103>