

DOI: 10.19650/j.cnki.cjsi.J2412399

基于数据驱动的锂离子电池健康状态 估计研究进展综述*

金 帅,董 静

(哈尔滨商业大学轻工学院 哈尔滨 150028)

摘 要:锂离子电池(LIBs)在电气化交通、电化学储能和移动电子产品等领域广泛使用,精准评估其健康状态(SOH)是确保安全可靠应用的基础。数据驱动法是当前评估 SOH 的主流方法,该方法无需考虑电池内部复杂的物理化学反应,依赖于直接的数据分析,且具有较高的精度。本文从锂离子电池 SOH 影响因素入手分析了基于数据驱动的电池 SOH 估计方法的研究现状,着重比较了机器学习、滤波器和时间序列等方法实施 SOH 估计的原理、优缺点。最后,针对电动汽车实际应用场景,对 SOH 估计方法的未来发展趋势进行了展望。

关键词:锂离子电池;健康状态;数据驱动;电动汽车

中图分类号: TH89 TM93 **文献标识码:** A **国家标准学科分类代码:** 470.40

Review on progress of data-driven based health state estimation for lithium-ion batteries

Jin Shuai, Dong Jing

(School of Light Industry, Harbin University of Commerce, Harbin 150028, China)

Abstract: Lithium-ion batteries (LIBs) are widely used in areas such as electrified transportation, electrochemical energy storage and mobile electronics. Consequently, accurate assessment of their state of health (SOH) is fundamental to ensure safe and reliable applications. Data-driven methods are the mainstream methods to evaluate SOH, which do not need to consider the complex physical and chemical reactions inside the battery, and only rely on direct data analysis to achieve accurate SOH estimation. This paper analyzes the current research progress of data-driven estimation methods for battery SOH under the consideration of the influencing factors of SOH for LIBs, and focuses on comparing the principles, advantages and disadvantages of machine learning, filter and time series methods in implementing SOH estimation. Finally, according to the practical application scenarios of electric vehicles, the future development trend of SOH estimation methods is prospected.

Keywords: lithium-ion batteries; state of health; data-driven; electric vehicles

0 引 言

随着全球燃油汽车的持有量不断增加,人类将面临着化石燃料短缺以及环境污染的严重问题,发展新能源汽车是解决当前问题的关键之一。锂离子电池由于其高能量密度、低自放电特性、无记忆效应、高开路电压以及长寿命等优势被视为最具发展潜力的储能技

术^[1-3]。近年来,特别是高能量密度的锂离子电池广泛用作电动汽车和混合动力电动汽车的理想电源^[4],大大提升电动汽车的行驶里程。然而,在锂离子电池的充放电循环使用过程中,电池会逐渐老化,其内部结构(如电解液)会发生不可避免的副反应,导致电池容量衰减、功率下降以及内阻增大,严重影响电动汽车的行驶里程和使用寿命,是对用户造成“里程焦虑”的关键因素^[5-6]。

电池管理系统(battery management system, BMS)对于确保电动车电池的稳定运行至关重要,其核心职责在于向驾驶者传输关于电池状况的信息,并确保电池始终在安全的操作范围之内。此外,当电池的工作情况发生异样时,BMS会采取适当的措施来预防潜在的安全隐患,以保护电池的长久使用^[7]。电动汽车电池健康状态估计(state of health, SOH)作为BMS的核心之一,是反映电池的健康状态和老化程度的关键指标^[8]。然而,直接测量电池SOH面临诸如敏感性和测定精度的限制等问题,因此通过间接测量表征参数(如电流、电压、内阻等)再进行对电池SOH估算的方法成为主流^[9-10]。

随着国内外众多学者对锂离子电池SOH估计方法的深入研究,出现了一系列先进的技术。然而,由于温度、充电速率和放电深度等的多重耦合特性,电池SOH估计仍然是一个瓶颈任务^[11]。因此,有必要详细阐述这些方法并总结优点和缺点,以便在更广泛的工程应用中提升性能。现有的方法主要有基于模型的方法、数据驱动法和混合方法三类。其中,基于模型的方法和混合方法往往复杂且难以实现,本文将在第2节进行详细的描述。而数据驱动的方法无需考虑电池内部复杂的电化学反应和失效机制^[12-13]。同时,随着大数据时代的到来,由于计算机强大的计算能力和鲁棒性,数据驱动法已经成为电池SOH估计的研究热点^[14]。不同文献对数据驱动法的分类有所差异。Noura等^[15]和Li等^[16]认为数据驱动的方法是实验方法和基于模型的方法相结合的一种机器学习方法,并指出该方法需要大量的电动汽车和混合动力汽车在不同工况和不同电池类型下的真实数据,这种估计技术才能得以进行。Oji等^[17]则根据初始模型是否为现有的模型把基于数据驱动的方法分为基于模型的方法和无模型方法,但基于模型的方法仅仅讨论了等效电路模型和电化学模型。Ge等^[18]对数据驱动方法的进行了较为全面的分析,但主要针对预测电池的剩余使用寿命(remaining useful lifetime, RUL),在电池SOH估计方面,对数据驱动方法的描述较为简略。总体来看,基于数据驱动的方法进行锂离子电池SOH精准估计已成为国内外学者研究的热点,并取得了许多研究成果。然而,详细归纳电池SOH估计方法的文献较少,且大多数文献对基于数据驱动的方法总结不够全面。本文根据所用方法的原理和适用条件,将数据驱动的SOH预测方法分为机器学习方法、滤波方法以及时间序列方法,综述了各种方法的研究现状,对比分析了这些方法的原理以及优缺点。面向实际工程应用,提出了当前SOH估计方法的瓶颈和解决方式,并对未来研究工作提出展望,以利于锂离子电池高效安全发展。

1 电池 SOH 的定义以及影响因素

1.1 锂离子电池 SOH 定义

电池SOH表征当前电池性能与老化程度的关键指标,是评价电池寿命的关键点。然而,电池SOH没有统一的定义。普遍认为,电池容量衰减了20%,其内阻增加到初始值的160%是电池寿命的终止条件^[19]。因此,目前动力电池SOH常用容量或者内阻两个方面进行定义。对于行驶里程要求较高的纯电动汽车,常用锂离子电池当前可用的最大容量与其标称容量之比来衡量锂离子电池SOH,如式(1)所示;而对于功率要求较高的高性能混合动力汽车,常基于内阻增长率来表征锂离子电池SOH,如式(2)所示;此外,也可以通过其它参数,如电量^[20]、循环次数^[21]和峰值功率^[22]等对电池SOH进行定义。值得注意的是,尽管利用容量和内阻作为衡量电池SOH的指标既直观又易于操作,但在现实运用场景下却很难实现实时的估算,同时由于复杂的电化学反应及测量噪音的影响,可能会导致估测结果出现偏差。因此,急需开发一种准确性高、响应速度快的在线预测电池健康状况的新技术。

$$SOH = \frac{C_{aged}}{C_{new}} \times 100\% \quad (1)$$

$$SOH = \frac{R_{EOL} - R}{R_{EOL} - R_{new}} \times 100\% \quad (2)$$

式中: C_{aged} 、 C_{new} 分别表示当前电池最多可释放出的容量和初始电池最多可释放出的容量, R_{EOL} 、 R 、 R_{new} 分别表示电池寿命结束时的内阻、当前内阻和初始电阻。

1.2 锂离子电池 SOH 的影响因素

锂离子电池的SOH会因其日历老化和循环老化以及其他内外部因素的影响而呈整体下降的趋势^[23]。在锂离子电池的使用过程中,温度被认为是影响电池SOH的主要外部影响因素。大多数情况下,电池的使用寿命往往会因温度过高或过低而缩短。低温会降低锂离子的扩散,这可能导致Li⁺损失的加速。高温则会使一些不可逆的化学反应加速发生,导致蓄电池的活性物质降低,从而造成容量衰减以及电池老化^[24]。高温也会促使电池电极表面的固体电解质界面膜(solid electrolyte interphase, SEI)的增长,使得锂离子在正负极之间的嵌入和脱嵌变得更加困难,进而导致锂离子电池内阻增大。除此之外,充放电截止电压、充放电电流倍率、充放电深度等条件也是影响锂离子电池SOH的外部因素。而内部的影响因素主要是电极/电解质表面SEI膜的形成与降解、锂离子沉积、电极结构破坏、活性物质和电解质溶解等原因造成的。如图1所示,总

总结了影响锂离子电池 SOH 的外部因素、内部因素及电池性能退化之间的关系。




图1 电池 SOH 与内外部因素的因果关系

Fig.1 Causal relationship between battery SOH and internal and external factors




图2 锂离子电池健康状态估计方法分类

Fig.2 Classification of health state estimation methods for lithium-ion batteries

2 锂离子电池 SOH 的估计方法

本文将锂离子电池 SOH 的估计方法分为基于模型的方法、基于数据驱动的方法以及混合方法三类,如图2所示。基于模型的方法主要是通过建立电池模型,模拟电池的动态响应特性,从而实现电池 SOH 估计^[25-26],常用有等效电路模型(equivalent circuit model,ECM)、电化学模型和数学模型等。ECM 是一种不考虑电池内部化学成分和电化学反应,只描述电池的电压和电流等外部特征参数的变化从而对 SOH 和 SOC 进行估算的模型。根据锂离子电池特性,利用基本电子元件(如电感、电容和电阻等)和控制电压源建立模型,常见的有 Rint 模型、Thevenin 模型、PNGV 模型、一阶 RC 模型、二阶 RC 模型和复合模型^[27]。并在复频域建立电路方程,利用最小二乘法(包括递归最小二乘法)^[28-33]、极大似然法^[34]在线辨识模型参数。利用滤波算法与构建的 ECM 模型相结合以估计电池的欧姆内阻,并用于衡量电池 SOH。这种基于 ECM 的方法可以有效地模拟电池的特性,同时具备结构简单、识别参数少以及计算效率高优势^[35]。然而,基于 ECM 的方法对电池开路电压(open circuit voltage,OCV)的精度要求高,而且时常需要提前测量,因此在实际电动汽车运行环境下预测效果较差^[36]。

相对于 ECM 模型,电化学模型(electrochemical model,EM)则描述了电池内部物理、化学进程^[37]。以典型代表伪二维(pseudo two-dimension,P2D)电化学模型为例^[38-39],利用偏微分方程描述电池动态特性,可以实现较高的预测精度。然而,过高的模型计算复杂度导致参数辨识困难,计算效率低。基于数学模型的方法包括经验模型和概率模型。经验模型通过模拟电池的老化过

程,建立电池寿命与温度、电流倍率、过充与过放、循环次数等的关系模型,并通过数学方程拟合,实现电池 SOH 的估计。基于经验模型的方法虽然计算简单,能够预估电池寿命,但所需的离线实验数量较大,预测精度不高。概率模型核心理念是计算电压检测数据中各个电压值点出现的可能性,当电池在充放电曲线上呈现出不同的老化阶段时,最终会描绘出概率密度曲线。峰值电压会随着电池老化而发生变化,因此可以建立概率密度曲线峰值电压与 SOH 的映射关系。基于模型的 SOH 估计方法框架图如图3所示。

混合方法是由多种不同方法的组合实现电池 SOH 的估计。目前常见的有同类型方法组合和不同类型方法组合。如 Li 等^[40]提出一种用于联合估计 SOC 和 SOH 的混合机器学习框架,该框架使用卷积神经网络结合高斯过程回归方法来生成状态估计的均值和方差信息,并在传感器的辅助下提取有用特征,提高了联合估计的精确性。数据驱动之间的组合方法在混合方法中最为常见,如 Chen 等^[41]提出了一种基于自回归移动平均模型和 Elman 神经网络的融合模型,实现对锂离子电池 SOH 的准确预测。首先,通过电池生命周期数据获取电池的电压和容量退化变化,并根据电压曲线的变化选择与电池老化相关的健康因子。其次,采用经验模态分解对容量退化数据进行处理,提取多个数据序列及其相关残差;然后,通过对后续时间序列数据和残差数据的训练,分别建立自回归移动平均模型(auto-regressive moving average model,ARMA)模型和 Elman 神经网络模型。最后,将所有单独的预测组合起来生成估计的 SOH 序列。模型和

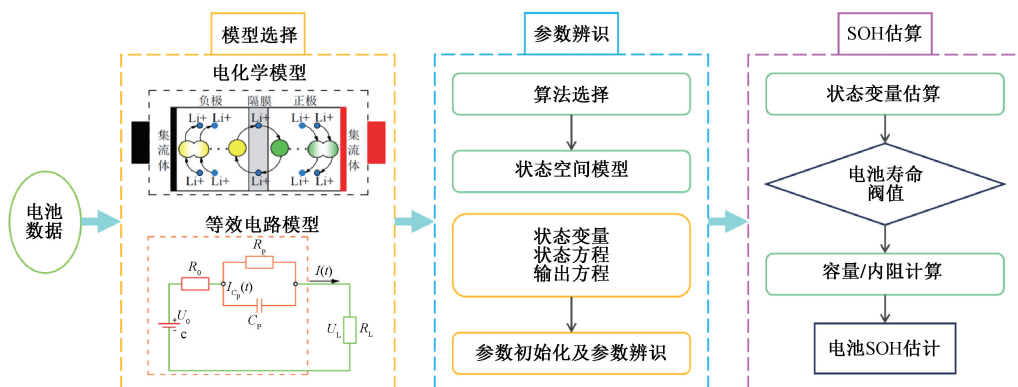


图3 基于模型的锂离子电池 SOH 估计方法框架图

Fig. 3 Frame diagram of model-based SOH estimation method for lithium-ion batteries

数据驱动组合的方法也得到众多学者的关注。如 Lin 等^[42]提出了一种将等效电路模型与数据驱动相结合的方法来估计电池 SOH。简化 ECM 来确定恒流充电条件下的内阻。并提取极性和偏移量作为热电耦合特征。然后结合内阻和热电耦合特征作为模型输入。基于良好的拟合性能和可解释性,利用解释增强机(explanation boosting machine,EBM)构造 SOH 估计器。采用蚁群算法对模型参数进行优化,提高模型的鲁棒性。刘萍等^[43]考虑了单独估计精度不高以及 SOC 与 SOH 之间估计结果的相互影响,提出一种将等效电路模型与数据驱动模型相融合的估计方法,实现 SOC 与 SOH 的联合估计。相对于单一的方法,混合方法具有理想的电池 SOH 估计精度,但是所分析数据量大,其过高的计算复杂度使得其难以在实际 BMS 中应用具有可行性。

3 基于数据驱动的电池 SOH 估计方法

基于数据驱动的方法是建立一个粗略的模型,然后用大量的电池历史退化数据和状态监测数据(电流、电压、温度等)对模型进行拟合,使模型与数据尽可能一致的方法^[44]。基于数据驱动的锂离子电池 SOH 估计方法主要分为机器学习方法、滤波方法以及时间序列方法,这种方法得益于计算机的发展和新能源汽车大数据平台的搭建,而且其灵活性强,无需考虑锂电池内部的物理化学反应和失效机制,在大量数据的支撑下,测量精度往往很高,因此基于数据驱动的方法成为当前的研究热点。

3.1 机器学习方法

机器学习方法(machine learning,ML)是一种可以自动分析和构建模型的数据分析方法。系统可以使用算法解析数据,这些算法主要有神经网络(artificial neural networks,ANN)、支持向量机(support vector machine,SVM)、相关向量机(relevance vector machine,RVM)、线

性回归、随机森林、模糊算法以及高斯过程回归等。然后从电池输出特征量的历史老化数据中学习输入和输出之间的映射关系来反映电池退化、健康指标与电池 SOH 之间的关系。如图 4 所示,基于 ML 技术的电池 SOH 估计由训练过程和估计过程两部分组成,通常训练过程离线进行,而估计过程可以在线进行,也可以离线进行^[45]。模型训练时,基本工作流程分为如下三步:

- 1) 收集老化数据,如电压、电流、温度以及时间等;
- 2) 提取老化过程特征,将所提取的特征与电池 SOH 的真实值构成训练数据集;
- 3) 利用机器学习并更新权重与偏差以适应训练数据。

ANN、SVM 以及 RVM 三种常用的基本方法介绍如下:

1) ANN

ANN 旨在模仿人类大脑的行为,其基本结构包含输入层、隐藏层和输出层三层,如图 5 所示^[46]。在输入层、隐藏层和输出层分别设置人工神经元,输入层接收数据将信息直接传输到隐藏层。然后,隐藏层中的每个神经元进行加权线性组合计算,并通过激活函数将信息传播到下一个隐藏层。

ANN 广泛用于自学习和自适应,并且它们不依赖于电池内部发生的化学物理反应,利用神经网络建立了特征参数与锂离子电池退化寿命之间的映射关系。常用于电池 SOH 估计的 ANN 模型有反向传播神经网络(back propagation neural networks,BPNN)、前馈神经网络(feed forward neural networks,FFNN)以及其他改进神经网络模型。Chen 等^[47]提出了一种新的 BPNN 来预测锂电池的 SOH。该方法使用锂电池的电压、电流和温度以及充电时间作为输入,根据训练数据自适应设置隐层节点数,最后利用四个不同的电池数据集和不同的训练数据集验证了该方案的有效性和鲁棒性。林名强等^[48]考虑了电




图4 ML算法估计电池SOH的总体框架

Fig. 4 Overall framework for estimating battery SOH by ML algorithm




图5 ANN基本结构示意图

Fig. 5 ANN basic structure schematic

池退化过程中的温度变化,提取了温度变化曲线中的3个高相关性的几何特征和增量容量曲线中的峰值作为BPNN的输入,SOH为输出来训练模型,利用牛津数据集验证方法的有效性。实验表明,大多数电池的预测精度在2%以内,少数电池的预测精度甚至达到1%左右。对于FFNN, Pan等^[49]提出了一种基于FFNN的方法,该方法以不同循环次数下的电压、时间、升压点和电池退化曲线数据作为输入,而电池SOH作为输出变量实现电池SOH的精确估计。ANN的一个显著特点是它们能够从经验和例子中学习,以适应不断变化的情况。它们可以通过训练自动建立,而无需识别模型参数和系数。然而,它们需要大量的输入数据进行训练和验证,并且它们的准确性受到训练方法和数据的显著影响。此外,计算成本仍然是其难以大规模应用在电池SOH估计的关键因素。

2) SVM

SVM是一种被引用到许多领域并且非常流行的估计方法,其主要思想是从大量的数据样本中找到一小组仍然可以描述系统的支持向量,适用于复杂小数据集的

分类和回归。因此,许多研究者使用SVM来估计电池的SOH。与ANN相比,SVM有更严格的数学证明,更快的收敛速度。Feng等^[50]建立了基于SVM的预测诊断模型,从新电池的充电数据中找出并确定反映锂离子电池固有特性的支持向量,从而确定不同SOH下电池的SVM系数,以实现电池SOH的估计。Meng等^[51]提出了一种利用SVM技术精确估计电池SOH的新方法,该方法的特征参数通过短期测试获得,在实际应用中具有良好的实用性。智能优化算法在SVM也得到了很好的应用。Li等^[52]引入了集成学习的算法,对粒子群算法(particle swarm optimization, PSO)优化SVM的回归模型进行改进,提高了电池SOH估计的鲁棒性和精度。支持向量回归(support vector regression, SVR)是一种基于SVM的回归预测算法,回归是通过搜索最小边缘拟合来实现的^[8]。该计算旨在解决如式(3)所描述的优化问题,约束条件如式(4)所示。

$$\min \frac{1}{2} \omega^T \omega + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (3)$$

$$\text{s. t. } \begin{cases} y_i - (\omega^T X_i + b) \leq \varepsilon + \xi_i^* \\ (\omega^T X_i + b) - y_i \leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0, i = 1, \dots, l \end{cases} \quad (4)$$

式中: 向量 ω 表示以 $C > 0$ 为正则化参数的模型参数, ξ_i^* 和 ξ_i 表示上下限的松弛变量, y_i 为目标输出, X_i 为特征向量。由于SVR具有强大的非线性拟合特性,其在SOH估计领域得到了众多学者的关注。Klass等^[53]利用SVR方法建立了状态空间模型来表示电池老化。通过对电池充电行为的分析,建立状态空间模型来描述电池的退化参数。从而进一步提出了基于SVR的SOH和RUL的联合预测框架。Wu等^[54]提出了蝙蝠优化算法(bat algorithm, BA)与SVR的联合算法来预测锂离子电池的SOH,使用BA算法找到最优的SVR超参数,并使用灰色关联分析验证其与电池SOH的高相关性。

3) RVM

RVM 基于贝叶斯框架理论,是一种类似于 SVM 的监督学习方法,在主动相关决策理论为基础的前提下移除不相关点,并得到稀疏化的模型。在 RVM 中,使用核映射来实现高维特征空间的非线性转换。核函数是决定 RVM 预测准确性的重要因素之一。常见的核函数包括 sigmoid 核函数、多项式核函数、线性核函数、径向基核函数和复合核函数。其中,高斯核函数作为径向基核函数,具有良好的可分性和局域性,能够建模高度非线性的关系,其表达式如式(5)所示。

$$kx - x_c = \exp\left\{\frac{-x - x_c^2}{2b^2}\right\} \quad (5)$$

式中: x 为预测变量空间中的任意点, x_c 为核函数的中心, b 为带宽参数。同 SVM 相比,RVM 最大的优点就是会产生更加稀疏的模型,从而使得在测试集上的计算速度更快,极大地减少了核函数的计算量。Feng 等^[55]利用 RVM 算法,提出一种具有误差补偿机制的大循环锂离子电池 SOH 估计模型,该方法以等压降放电时间为特征,在电池 SOH 估计方面有较高的精度和较强的鲁棒性。针对单一数据驱动模型在电池 SOH 的在线估计中泛化能力差等问题,优化算法与 RVM 的结合在估计电池 SOH 方面也有很好的鲁棒性。Chen 等^[56]提出了一种基于 BA 优化的 RVM 的锂离子电池 SOH 在线估计方法,并利用 NASA 公开的电池数据验证了该方法的正确性和有效性。张瑛等^[57]提取增量容量曲线中峰值和峰面积两个特征,利用混合核 RVM 建立电池单体容量的估计模型,实现电池单体 SOH 的精确估计,平均相对误差和均方根误差分别为 0.72%、0.91%。

3.2 滤波方法

基于滤波的估计方法主要是通过识别模型中能够表征电池健康状态的参数来进行 SOH 估计,通常该过程包含预测和校正两个环节,并且通过持续调整模型参数来提升 SOH 的估计精度。基于滤波的算法主要用于在线实时估计。常用的滤波算法有卡尔曼滤波(kalman filter, KF)和粒子滤波(particle filter, PF)。

1) KF

KF 是一种估计过程状态的有效方法。该方法旨在通过对先前的预测值和当前的测量值反复迭代,从而得到一个相对准确的值。标准的 KF 方程如式(6)所示:

$$\begin{cases} \hat{x}_{(t|t-1)} = F_t \hat{x}_{(t-1|t-1)} + B_t u_t \\ P_{(t|t-1)} = F_t P_{(t-1|t-1)} + Q_t \\ \hat{x}_{(dt)} = \hat{x}_{(t|t-1)} + K_t (y_t - H_t \hat{x}_{(t|t-1)}) \\ K_t = P_{(t|t-1)} H_t^T (H_t P_{(t|t-1)} H_t^T + R_t)^{-1} \\ P_{(dt)} = P_{(t|t-1)} - K_t H_t P_{(t|t-1)} \end{cases} \quad (6)$$

式中: $\hat{x}$ 为估计状态; F 为状态转移矩阵; B 为控制矩阵;

u 为控制向量; P 为状态方差矩阵; Q 为过程方差矩阵; y 为测量向量; H 为测量矩阵; K 为卡尔曼增益; R 为测量方差矩阵。然而,传统 KF 算法是一种基于线性系统的滤波算法,不能解决电池复杂的非线性系统。因此,众多学者提出了 KF 的改进算法,如扩展卡尔曼滤波(extended kalman filter, EKF)、无迹卡尔曼滤波(unscented kalman filter, UKF)、双卡尔曼滤波(dual extended kalman filter, DEKF)。

EKF 算法类似于经典的线性 Kalman 算法,但其具有更低的计算复杂度、更快的模型更新速度,因此在各种状态预测、趋势追踪等实际应用环境中得到了广泛的运用。Liu 等^[58]通过对锂离子电池进行老化实验,从电池的终端电压中提取出与电池 SOH 有密切联系的健康指标,并采用 EKE 算法对电池的 SOH 进行诊断和预测。另外,基于 EKF 算法广泛用于电池 SOC 和 SOH 联合估计^[59-62]。其中,EKF 的状态方程和测量方程分别如式(7)、式(8)所示。

$$x_{k+1} = f(x_k, u_k) + w_k \quad (7)$$

$$y_k = g(x_k, u_k) + v_k \quad (8)$$

式中: $f(x_k, u_k)$ 为与系统的状态相关的非线性函数; $g(x_k, u_k)$ 为与状态变量和观测变量两者相关联的非线性函数。

UKF 通过 UT 变换来求解近似非线性函数的概率密度。该方法优于 EKF 方法,不仅计算的复杂度没有增加,在锂离子电池 SOH 估计方面也能得到更小的误差。因此,目前先进的滤波算法一般以 UKF 为中心。Lai 等^[63]利用最小二乘法对电池 SOH 进行估计,再利用 UKF 算法进行校核,使得电池 SOH 的估计误差在 2% 以下。刘芳等^[64]提出了基于 UKF 算法的在线闭环校正 SOH 估计架构。值得注意的是,该方法能够利用车载动力电池易于获得的外部指示数据(温度、电压和电流),在随机放电期间快速估计更高精度的 SOH 值。因此,它适用于汽车领域的实时部署场景。

DEKF 算法的核心思想是交替使用两个卡尔曼滤波器来实现同时估计电池参数和状态的目标。两个独立的卡尔曼滤波器分别执行离线与在线的任务:前者对模型的参数进行估计;后者则依据测量数据来调整模型并更新系统的状态,最终实现电池 SOH 实时估计。Fang 等^[65]通过分析欧姆内阻及 SOH 间的关联性,使用基于 DEKF 算法的联合估计器实现 SOC 和 SOH 的联合估计。其中,根据欧姆电阻的变化,电池模型的内阻离散状态空间方程和输出观测方程可以用式(9)、式(10)表示。考虑到电池 SOC 与 SOH 的耦合效应,Jin 等^[66]提出了一种基于 DEKF 的方法,实现 SOC 与 SOH 的协同估计。

$$R_0(k) = R_0(k-1) + r(k-1) \quad (9)$$

$$U(k) = U_{oc}[SOC(k)] - U_{R_{c,c}}(k) - U_{R_{d,d}}(k) -$$

$$i(k) \times R_0(k) + v(k) \quad (10)$$

式中: R_0 为二阶 ECM 的欧姆电阻, $r(k-1)$ 表示欧姆电阻的噪声, R_c 、 R_d 和 C_c 、 C_d 为极化电容和极化电阻, $v(k)$ 表示输出观测的噪声。

2) PF

PF 属于非线性滤波器,最适合于基于参数未知或参数随时间变化的电池模型。它结合了贝叶斯学习技术和采样技术,在控制计算量的同时提供了良好的状态跟踪性能。该滤波方法主要通过寻找一组合适的粒子与概率密度函数进行逼近,进而获得状态最小方差分布的过程。最常用的实现粒子滤波的算法之一是重要性重采样(sampling importance resampling, SIR)^[67]。它有效地用一组加权粒子逼近得到的概率分布,而这些粒子的重要性权重可以近似为它们的相对概率。重要性权重是相对的,所以一个概率分布的权重总和总是为 1。与其他常用的非线性滤波器(如 EKF 等)相比,PF 具有更高的精度、更好的误差界限,并且能自动合并状态约束。基于上述优点,PF 常被用于实时估计老化参数和电池 SOH,其框架图如图 6 所示^[68]。Li 等^[69]采用数据融合方法建立非参数的退化模型,并利用 PF 短期估计电池的 SOH 和长期预测电池的 RUL。然而在标准粒子滤波算法中,序贯重要性采样会引起粒子的退化,因此 Wu 等^[70]提出了一种改进的 FA 算法优化 PF,实现 SOC 与 SOH 的联合估计。Qiu 等^[34]将改进的杜鹃搜索(improved cuckoo search, ICS)算法嵌入到标准 PF 中,通过将先验分布区域的粒子转移到最大似然区域来提高其性能,从而提高了电池 SOH 的估计精度。




图6 基于PF的老化参数和SOH估计框架图

Fig. 6 Aging parameters and SOH estimation frame diagram based on PF

3.3 时间序列

简单来说,基于时间序列的分析方法就是根据过去的的数据为基础,并预测未来的发展趋势,同时考虑到事物

发展的随机性,对历史数据进行处理的过程。基于时间序列预测的方法也广泛用于电池的 SOH 估计,本节提出了 3 种目前较为流行的时间序列预测方法,分别是自回归移动平均模型(auto-regressive moving average model, ARMA)、循环神经网络(recurrent neural network, RNN)和长短期记忆(long-short term memory, LSTM)。其中, RNN 和 LSTM 属于神经网络,但这两种方法基于时间序列的预测效果较好,因此将它们归于基于时间序列的方法。虽然这些方法比较复杂,但是预测效果好、鲁棒性高,也是目前比较热门的电池寿命估计方法。

1) ARMA

ARMA 模型是自回归模型(auto-regressive model, AR)和移动平均模型(moving average model, MA)的结合。它使用前一个时间步骤的观测值的线性组合作为输入来预测后续的时间步骤值。然而, ARMA 模型是线性的,而电池容量衰减过程通常是非线性的,这种差异会使模型拟合效果差,特别是对于长期预测。因此,为了解决这一问题,很多学者提出了差分自回归移动平均模型(auto-regressive integrated moving average, ARIMA),这是一种将 AR 模型、MA 模型和差分过程相结合的框架,该框架可以处理非平稳序列数据。如 Shen 等^[71]提出的一种基于 ARIMA 模型的 SOH 预测方法。该方法通过适当选择模型阶数,根据以往电池 SOH 记录的训练数据估计时间序列模型,然后进行预测,并对预测残差进行分析和验证,证明了该方法的有效性。然而,由于 ARIMA 模型使用单一输入数据,没有考虑外部因素的影响,长期预测的准确性较低。因此很多学者提出了季节性差分自回归移动平均模型(seasonal auto-regressive integrated moving average, SARIMA)、带额外输入的差分自回归移动平均模型(auto-regressive integrated moving average with exogenous variables, ARIMAX)等 ARMA 的扩展模型。Kim 等^[72]对这两种模型进行了比较,提出了考虑用户驾驶模式的电池寿命预测 SARIMA 模型和考虑多变量因素的电池寿命预测 ARIMAX 模型,并比较这两种模型对 SOH 的预测效果。实验结果表明由于 ARIMAX 模型考虑了影响电池退化的外部因素,因此其精度高于 SARIMA 模型。

2) RNN

RNN 是一种表征电池老化数据输入输出相关性的很有前途的方法,已被广泛用于人工智能应用中的序列数据处理。RNN 有一个额外的关联性单元用于存储历史信息。因此,一些隐藏层的输出被反馈到前一层的输入中,这使得 RNN 模型非常强大,能够处理序列数据。RNN 被广泛用于人工智能应用中的序列数据处理,也是最有前途的电池健康预测方法之一。SOH 估计需要使用具有动态特性的电池数据来跟踪电池的退化过程。因此,使用 RNN 来处理 SOH 估计是一种内在策略。联想

记忆特性、电压、电流、温度以及延时电压和电流是 RNN 的关键输入。Raman 等^[73]提出了一种基于艾姆斯研究中心的卓越诊断学中心电池老化数据集的 SOH 估计方法,该方法采用了不同的 RNN 技术建立了电池 SOH 预测模型,并对不同技术的预测结果进行了比较分析,最终验证 RNN 技术估计电池 SOH 的有效性。Chaoui 等^[74]提出了一种基于 RNN 的方法,其中动态驱动的 RNN 被构建用于锂离子电池的 SOC 和 SOH 联合估计。You 等^[75]提出了一种更实用的基于 RNN 的方法,其中电池支持真实环境中的驾驶模式。该研究建议使用可测量的 EV 数据(如电流和电压)来跟踪 SOH。退化模型是基于 RNN 设计的模型,它非常适合于处理序列数据。该验证在各种电动汽车驾驶条件下提供了非常稳健和灵活的结果,所有实验的平均误差低于 2.46%。Elman-NN 是基本的 RNN 结构,其结构图如图 7 所示。上下文单元接收隐藏层的输出值并直接存储这些值。在每个时间步长 k 处,输入的 $x(k)$ 与存储在上下文单元中的先值 $h(k-1)$ 一起决定了当前隐藏层的输出,其表达式如式(11)所示:

$$h_q(k) = g \left(\sum_{p=1}^d [x_{i,p}^{\text{In}}(k) w_{pq}^{\text{H}}(k) + h_p(k-1) v_p(k-1)] + b_q \right), q = 1, \dots, l \quad (11)$$

式中: k 为当前时间步长, $x_{i,p}^{\text{In}}$ 为第 i 个样本点的第 p 个输入特征, w_{pq}^{H} 为连接输入神经元和隐藏神经元的权值, p 为连接上下文单元和隐藏神经元的权值, b_q 为偏置, $g(\cdot)$ 为激活函数。Chen 等^[41]设计了 Elman 神经网络来估计 SOH,并使用经验模态分解方法处理原始老化数据。消除了容量再生现象,生成了两类序列;一种是固有模态函数,其波动较大,可以用 ARMA 估计。另一个是最终残




图7 Elman神经网络的结构原理图

Fig. 7 Structure schematic diagram of Elman neural network

差,它是一条光滑的单调曲线,可以通过预训练的 Elman 神经网络来估计。针对 Elman 神经网络收敛速度慢、寻优难等缺陷, Li 等^[61]采用麻雀搜索算法(sparrow search algorithm, SSA)对网络参数进行优化。此外,增加了数据增量更新机制,提高了 SSA-Elman 模型的泛化能力。

3) LSTM

LSTM 是 RNN 的一种,是对 RNN 的改进。RNN 循环的参数学习可以通过随时间的反向传播算法来学习,当输入序列较长时,就会产生梯度爆炸或甚至消失的问题,也称为长期依赖问题。为了解决这个问题,引入了门控机制来改进 RNN。与 RNN 相比, LSTM 有输入门、遗忘门和输出门,其结构如图 8 所示。门是激活函数的组合,决定哪些信息应该通过关联性单元。LSTM 的计算过程为如(12)所示:

$$\begin{cases} f_t = \sigma(B_f + W_f x_t + V_f h_{t-1}) \\ i_t = \sigma(B_i + W_i x_t + V_i h_{t-1}) \\ C_t^* = \tanh(B_c + W_c x_t + V_c h_{t-1}) \\ C_t = C_{t-1} f_t + i_t C_t^* \\ O_t = \sigma(B_o + W_o x_t + V_o h_{t-1}) \\ h_t = O_t \tanh(C_t) \end{cases} \quad (12)$$

式中: f_t 、 i_t 、 O_t 和 C_t 分别代表遗忘门、输入门、输出门和存储单元。 B 表示偏置; W 表示 x_t 的权重; V 表示 h_{t-1} 的权重; σ 为 sigmoid 激活函数,将输出值限制在 0~1 之间; $\tanh$ 为双曲函数。




图8 LSTM的基本结构

Fig. 8 Basic structure of LSTM

Zhang 等^[76]选择电池容量作为 SOH 的表征,构建电池容量的 LSTM 模型,从时间序列的角度检测和提取容量退化的固有模式,通过实验表明基于 LSTM 模型的预测方法能预测锂离子电池的可用容量和 RUL。周才杰等^[77]为了降低计算的复杂度,提出了利用灰色关联分析对提取的特征进行分析和筛选,将关联度最大的 3 个特征作为 LSTM 神经网络的输入训练模型。实验结果表明,该方法对 SOH 估计的平均误差约为 1%,能够很好地满足实际运用。另外,为了使 LSTM 算法更容易在线实

现,部分学者对网络结构进行了优化。如 Liu 等^[78]提出了一种基于改进增量容量分析(incremental capacity analysis,ICA)和 LSTM 神经网络融合的 SOH 估计方法,该方法根据恒流和恒压充电阶段的数据估算出 SOH。Zhang 等^[79]提出了一种深度 LSTM,它有望在线实现。该方法利用历史数据对模型的参数进行适当的实时调整。此外,该方法允许变量输入维数,可以更好地理解历史数据并保证良好的泛化能力。

综上所述,基于数据驱动的锂离子电池 SOH 估计方法目前已相对成熟,不同数据驱动方法具有各自的优势以及应用场景。国内外研究人员建立了多种数据驱动的锂离子电池 SOH 估计模型,且各类方法的验证也相对较为充分。然而,由于每种方法的复杂性和操作模式都不同,这可能会影响实际应用。因此,本文通过对各种数据驱动算法进行分析,总结出各类数据驱动方法的优势与不足,如表 1 所示。

表 1 各种数据驱动方法的比较
Table 1 A comparison of various data-driven approaches

估计方法	参考文献	运行模式	输入特征	估计精度	优点	缺点	
机器学习方法	ANN	[49]	在线估计	电压、电流、温度	MAE<2.5% RMSE<3%	自主学习能力强、泛化性能好、计算复杂度低、对非线性系统的分析效果好	网络参数复杂,所需训练时间与计算资源随数据量增长急剧增加,不能捕获顺序信息
	SVM	[80]	在线估计	膝点电压 脉冲响应	MSE<0.3%	在数据集小但特征维数高的情况下具有良好的近似能力,高维计算效率高	核函数的选择困难,在大数据集上训练时间长
	RVM	[81]	在线估计	增量容量曲线中的老化特征	平均误差<3%	计算速度快,减少了核函数的计算量,计算复杂度低	数据容易波动,预测结果稳定性差,不适合长期预测
滤波	KF	[82]	离线估计	欧姆内阻	MRE<1.61%	精度高,能够同时得到估计误差,适用于大多数类型电池、应用范围较广	对模型的精度和系统处理能力的要求高
	PF	[68]	在线估计	电流、电压	误差<3%	预测精度高,表达不确定性的能力强	初始化过程很复杂,对退化模型的建立准确性要求高
时间序列	ARMA	[71]	在线估计	原始 SOH 序列	误差<3%	实时性好,适用于小样本预测,计算复杂度低	预测精度低,长期预测效果差,不适用于非线性信号
	RNN	[83]	在线估计	电流、温度、电压	MAE<0.7% MAPE<3%	预测精度高,非线性拟合能力强,由于递归链接的存在,具有很强的长期预测能力	可能导致过拟合问题,当输入序列较长时,会出现梯度爆炸或梯度消失问题
	LSTM	[84]	在线估计	电池组电压,制动踏板行程值,电机转速,车速,电流, SOC,温度,电压	RMSE<0.3% MAE<0.13%	可以计算时间序列中各观测值之间的依赖关系,挖掘特征信息能力强。解决数据体拟合时出现的梯度消失问题,并提高模型的精度和泛化能力	对硬件资源的要求高,大规模数据中仍然会出现梯度消失的问题,计算效率低。

4 结 论

电动化、智能化、网联化是将是未来汽车技术进步的重要途径,新能源汽车与大数据融合发展将成为中国汽车产业迈向世界前列的重要机遇^[36]。电池 SOH 估计对保障电动汽车安全、高效运行具有重要意义。本文综述了基于数据驱动的锂离子电池 SOH 估计方法的最新进展。阐述了基于容量衰减和内阻增大两个常用的电池

SOH 定义,分析了影响电池 SOH 的主要内、外部因素。比较分析了机器学习方法、滤波、时间序列三种基于数据驱动的电池 SOH 估计方法的精度以及优缺点。基于数据驱动的 SOH 估计方法已被众多学者广泛关注,但将这些估计方法应用在实际工程方面仍存在诸多挑战,需要开展深入研究:

1)模型对电池老化机理的识别。纯数据驱动方法,不能提供电池老化机理的深入信息。探究一种将电池老化机理与电池 SOH 在线估计方法相结合的方法很有必

要,因为前者可以帮助找到最敏感的容量损失指标,后者利用机器学习算法实现 SOH 估计。因此,随着具有自学习能力的新型智能算法出现,将机器学习方法与电池老化模型相结合的方法是未来研究的一个很有前途的方向。

2) 模型在不同工况下的自我改进。当前电池的 SOH 估计多基于单一的实验条件下进行,模型大多只使用电池的电压、电流、温度、内阻等观测数据进行分析。而电动汽车实际的工况却是非常复杂多变,用于开发模型的实验室条件与实际操作条件之间的偏差限制了数据驱动方法的实际适用性。因此,亟需建立全工况、多耦合效应的电池系统模型。另外,随着采用 5G 技术的云 BMS 和内置多信号集成传感器的出现,结合机器学习方法的电化学-机械-热耦合模型可能成为远程 SOH 监测的可能。

3) 基于机器学习的 SOH 估计方法的板载实现。由于占用计算资源,基于机器学习的 SOH 估计算法的板载实现还不成熟。此外,由于 SOH 变化缓慢且总是在宏观尺度上进行估计,难以实现显示实时的电池 SOH 估计结果。因此,在未来的电池 SOH 估计中,机器学习算法的发展应该更多地关注板载实现的难度。

4) 模型应用于车用电池包的 SOH 估计。车用电池通常由单个电池串联和/或并联以形成一个电池组。在正常工作条件下,电池组中的电池之间存在着固有的不同变化,随着电池的老化,电池之间的变化会越来越大,这将导致电池组中单个电池之间的 SOH 偏差。然而,现阶段针对电池 SOH 预测的大部分工作都是基于单体电池展开的,单体电池的 SOH 预测方法很可能无法适用于整个电池组的 SOH 预测。尽管上述的一些研究已经在单体电池方面取得了一系列重要突破,但是如何把 SOH 预测的技术由单体电池扩展至电池组依然是当前新能源汽车所面临的一大难题。

参考文献

- [1] 刘大同,宋宇晨,武巍,等. 锂离子电池组健康状态估计综述[J]. 仪器仪表学报, 2020, 41(11): 1-18.
LIU D T, SONG Y CH, WU W, et al. Review of state of health estimation for lithium-ion battery pack [J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 1-18.
- [2] 熊庆,邸振国,汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述[J/OL]. 高电压技术, 1-14 [2024-03-19]. <https://doi.org/10.13336/j.1003-6520.hve.20221843>.
XIONG Q, DI ZH G, JI SH CH. Review on health state estimation and life prediction of lithium-ion batter-

ies[J/OL]. High Voltage Engineering, 1-14 [2024-03-19]. <https://doi.org/10.13336/j.1003-6520.hve.20221843>.

- [3] 朱浩然,陈自强,杨德庆. 基于差分热伏安法和高斯过程回归的锂离子电池健康状态估计[J/OL]. 上海交通大学学报, 1-16 [2024-03-19]. <https://doi.org/10.16183/j.cnki.jsjtu.2023.141>.
ZHU H R, CHEN Z Q, YANG D Q. State of Health Estimation for Li-ion Batteries Based on Differential Thermal Voltammetry and Gaussian Process Regression [J/OL]. Journal of Shanghai Jiaotong University, 1-16 [2024-03-19]. <https://doi.org/10.16183/j.cnki.jsjtu.2023.141>.
- [4] KIM T, SONG W, SON D-Y, et al. Lithium-ion batteries: Outlook on present, future, and hybridized technologies [J]. Journal of Materials Chemistry A, 2019, 7(7): 2942-2964.
- [5] XIONG R, PAN Y, SHEN W, et al. Lithium-ion battery aging mechanisms and diagnosis method for automotive applications: Recent advances and perspectives [J]. Renewable and Sustainable Energy Reviews, 2020, 131: 110048.
- [6] 朱鹏霏,李丽,常泽宇,等. 基于 BMS 与云平台的动力电池健康管理体系[J]. 计算机测量与控制, 2023, 31(9): 190-198, 252.
ZHU P F, LI L, CHANG Z Y, et al. Power battery health management system based on BMS and cloud platform[J]. Computer Measurement & Control, 2023, 31(9): 190-198, 252.
- [7] 张金龙,佟微,孙叶宁,等. 锂电池健康状态估算方法综述[J]. 电源学报, 2017, 15(2): 128-134.
ZHANG J L, TONG W, SUN Y N, et al. Summarize of lithium battery status of health estimation method [J]. Journal of Power Supply, 2017, 15(2): 128-134.
- [8] LIU Z, ZHAO J, WANG H, et al. A new lithium-ion battery SOH estimation method based on an indirect enhanced health indicator and support vector regression in PHMs [J]. Energies, 2020, 13(4): 830.
- [9] LOVE C T, VIRJI M B, ROCHELEAU R E, et al. State-of-health monitoring of 18650 4S packs with a single-point impedance diagnostic [J]. Journal of Power Sources, 2014, 266: 512-519.

- [10] 李超然, 肖飞, 樊亚翔, 等. 基于卷积神经网络的锂离子电池 SOH 估算 [J]. 电工技术学报, 2020, 35(19): 4106-4119.
- LI CH R, XIAO F, FAN Y X, et al. An approach to lithium-ion battery SOH estimation based on convolutional neural network [J]. Transactions of China Electro-technical Society, 2020, 35(19): 4106-4119.
- [11] SHU X, LI G, ZHANG Y, et al. Online diagnosis of state of health for lithium-ion batteries based on short-term charging profiles [J]. Journal of Power Sources, 2020, 471: 228478.
- [12] 贾俊, 胡晓松, 邓忠伟, 等. 数据驱动的锂离子电池健康状态综合评分及异常电池筛选 [J]. 机械工程学报, 2021, 57(14): 141-149, 159.
- JIA J, HU X S, DENG Z W, et al. Data-driven comprehensive evaluation of lithium-ion battery state of health and abnormal battery screening [J]. Journal of Mechanical Engineering, 2021, 57(14): 141-149, 159.
- [13] 岳家辉, 夏向阳, 吕崇耿, 等. 计及健康特征信息量的锂离子电池健康状态与剩余寿命预测研究 [J]. 电力系统保护与控制, 2023, 51(22): 74-87.
- YUE J H, XIA X Y, LYU CH G, et al. Research on the prediction of state of health and remaining useful life of lithium-ion batteries considering the amount of health factors information [J]. Power System Protection and Control, 2023, 51(22): 74-87.
- [14] 车云弘, 邓忠伟, 李佳承, 等. 基于数据驱动的电池系统泛化 SOH 估计方法 [J]. 机械工程学报, 2022, 58(24): 253-263.
- CHE Y H, DENG ZH W, LI J CH, et al. Generalized data-driven SOH estimation method for battery systems [J]. Journal of Mechanical Engineering, 2022, 58(24): 253-263.
- [15] NOURA N, BOULON L, JEMER S. A review of battery state of health estimation methods: Hybrid electric vehicle challenges [J]. World Electric Vehicle Journal, 2020, 11(4): 66.
- [16] LI Y, LIU K, FOLEY A M, et al. Data-driven health estimation and lifetime prediction of lithium-ion batteries: A review [J]. Renewable and Sustainable Energy Reviews, 2019, 113: 109254.
- [17] OJI T, ZHOU Y, CI S, et al. Data-driven methods for battery soh estimation: Survey and a critical analysis [J]. IEEE Access, 2021, 9: 126903-126916.
- [18] GE M F, LIU Y, JIANG X, et al. A review on state of health estimations and remaining useful life prognostics of lithium-ion batteries [J]. Measurement, 2021, 174: 109057.
- [19] BEREICIBAR M, GANDIAGA I, VILLARREAL I, et al. Critical review of state of health estimation methods of Li-ion batteries for real applications [J]. Renewable and Sustainable Energy Reviews, 2016, 56: 572-587.
- [20] LIU Z, TAN C, LENG F. A reliability-based design concept for lithium-ion battery pack in electric vehicles [J]. Reliability Engineering & System Safety, 2015, 134: 169-177.
- [21] BARRÉ A, DEGUILHEM B, GROLLEAU S, et al. A review on lithium-ion battery ageing mechanisms and estimations for automotive applications [J]. Journal of Power Sources, 2013, 241: 680-689.
- [22] CHEN Z, XIONG R, CAO J. Particle swarm optimization-based optimal power management of plug-in hybrid electric vehicles considering uncertain driving conditions [J]. Energy, 2016, 96: 197-208.
- [23] YANG S, ZHANG C, JIANG J, et al. Review on state-of-health of lithium-ion batteries: Characterizations, estimations and applications [J]. Journal of Cleaner Production, 2021, 314: 128015.
- [24] RAMESH S, KRISHNAMURTHY B. A mathematical model to study capacity fading in lithium ion batteries: Formation and dissolution reactions [J]. Journal of The Electrochemical Society, 2015, 162(4): A545.
- [25] DUAN C, LIANG K, ZHANG Z, et al. Recent advances in the synthesis of nanoscale hierarchically porous metal-organic frameworks [J]. Nano Materials Science, 2022, 4(4): 351-365.
- [26] 高昊天, 陈云霞. 基于机器学习的锂离子电池健康状态分类与预测 [J]. 北京航空航天大学学报, 2023, 49(12): 3467-3475.
- GAO H T, CHEN Y X. A machine learning based method for lithium-ion battery state of health classification and prediction [J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(12): 3467-3475.

- [27] 高铭琨, 徐海亮, 吴明铂. 基于等效电路模型的动力电池 SOC 估计方法综述[J]. 电气工程学报, 2021, 16(1): 90-102.
- GAO M K, XU H L, WU M B. Review of SOC estimation methods for power battery based on equivalent circuit model [J]. Journal of Electrical Engineering, 2021, 16(1): 90-102.
- [28] SUN X, JI J, REN B, et al. Adaptive forgetting factor recursive least square algorithm for online identification of equivalent circuit model parameters of a lithium-ion battery[J]. Energies, 2019, 12(12): 2242.
- [29] ZHANG J A, WANG P, GONG Q, et al. SOH estimation of lithium-ion batteries based on least squares support vector machine error compensation model [J]. Journal of Power Electronics, 2021, 21: 1712-1723.
- [30] WEN J, CHEN X, LI X, et al. SOH prediction of lithium battery based on IC curve feature and BP neural network[J]. Energy, 2022, 261: 125234.
- [31] XIONG W, MO Y, YAN C. Online state-of-health estimation for second-use lithium-ion batteries based on weighted least squares support vector machine [J]. Ieee Access, 2020, 9: 1870-1881.
- [32] SHEN P, OUYANG M, LU L, et al. The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles [J]. IEEE Transactions on vehicular technology, 2017, 67 (1): 92-103.
- [33] HE H, ZHANG X, XIONG R, et al. Online model-based estimation of state-of-charge and open-circuit voltage of lithium-ion batteries in electric vehicles [J]. Energy, 2012, 39(1): 310-318.
- [34] QIU X, WU W, WANG S. Remaining useful life prediction of lithium-ion battery based on improved cuckoo search particle filter and a novel state of charge estimation method[J]. Journal of Power Sources, 2020, 450: 227700.
- [35] DU X, MENG J, ZHANG Y, et al. An information appraisal procedure: Endows reliable online parameter identification to lithium-ion battery model [J]. IEEE Transactions on Industrial Electronics, 2021, 69 (6): 5889-5899.
- [36] 王震坡, 王秋诗, 刘鹏, 等. 大数据驱动的动力电池健康状态估计方法综述[J]. 机械工程学报, 2023, 59(2): 151-168.
- WANG ZH P, WANG Q SH, LIU P, et al. Review on techniques for power battery state of health estimation driven by big data methods [J]. Journal of Mechanical Engineering, 2023, 59(2): 151-168.
- [37] 顾菊平, 蒋凌, 张新松, 等. 基于特征提取的锂离子电池健康状态评估及影响因素分析[J]. 电工技术学报, 2023, 38(19): 5330-5342.
- GU J P, JIANG L, ZHANG X S, et al. Estimation and influencing factor analysis of lithium-ion batteries state of health based on features extraction [J]. Transactions of China Electrotechnical Society, 2023, 38 (19): 5330-5342.
- [38] RAHIMIYAN S K, RAYMAN S, WHITE R E. Extension of physics-based single particle model for higher charge-discharge rates [J]. Journal of Power Sources, 2013, 224: 180-194.
- [39] CHEN Q, CHEN X S, LI Z. A fast numerical method with non-iterative source term for pseudo-two-dimension lithium-ion battery model [J]. Journal of Power Sources, 2023, 577: 233258.
- [40] LI Y, LI K, LIU X, et al. A hybrid machine learning framework for joint SOC and SOH estimation of lithium-ion batteries assisted with fiber sensor measurements [J]. Applied Energy, 2022, 325: 119787.
- [41] CHEN Z, XUE Q, XIAO R, et al. State of health estimation for lithium-ion batteries based on fusion of autoregressive moving average model and elman neural network [J]. IEEE access, 2019, 7: 102662-102678.
- [42] LIN M, YAN C, WANG W, et al. A data-driven approach for estimating state-of-health of lithium-ion batteries considering internal resistance [J]. Energy, 2023, 277: 127675.
- [43] 刘萍, 李泽文, 蔡雨思, 等. 基于等效电路模型和数据驱动模型融合的 SOC 和 SOH 联合估计方法 [J]. 电工技术学报, 1-12 [2024-03-19]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.230261>.
- LIU P, LI Z W, CAI Y S, et al. Joint Estimation method of SOC and SOH based on the fusion of equivalent circuit model and data-driven model [J]. Transactions of China Electrotechnical Society, 1-12 [2024-03-19]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.230261>.

- doi.org/10.19595/j.cnki.1000-6753.tces.230261.
- [44] CAI L, MENG J, STROE D-I, et al. Multiobjective optimization of data-driven model for lithium-ion battery SOH estimation with short-term feature [J]. IEEE Transactions on Power Electronics, 2020, 35 (11): 11855-11864.
- [45] SUI X, HE S, VILSEN S B, et al. A review of non-probabilistic machine learning-based state of health estimation techniques for Lithium-ion battery [J]. Applied Energy, 2021, 300: 117346.
- [46] 胡晓亚, 郭永芳, 张若可. 锂离子电池健康状态估计方法研究综述[J]. 电源学报, 2022, 20(1): 126-133.
- HU X Y, GUO Y F, ZHANG R K. Review of state-of-health estimation methods for lithium-ion battery [J]. Journal of Power Supply, 2022, 20(1): 126-133.
- [47] CHEN L, XU C, BAO X, et al. State-of-health estimation of lithium-ion battery based on back-propagation neural network with adaptive hidden layer[J]. Neural Computing and Applications, 2023, 35(19): 14169-14182.
- [48] 林名强, 吴登高, 郑耿峰, 等. 基于表面温度和增量容量的锂电池健康状态估计[J]. 汽车工程, 2021, 43(9): 1285-1290, 1284.
- LIN M Q, WU D G, ZHENG G F, et al. Estimation method of state of health of lithium battery based on surface temperature and incremental capacity [J]. Automotive Engineering, 2021, 43 (9): 1285-1290, 1284.
- [49] PAN H, LÜ Z, WANG H, et al. Novel battery state-of-health online estimation method using multiple health indicators and an extreme learning machine[J]. Energy, 2018, 160: 466-477.
- [50] FENG X, WENG C, HE X, et al. Online state-of-health estimation for Li-ion battery using partial charging segment based on support vector machine [J]. IEEE Transactions on Vehicular Technology, 2019, 68 (9): 8583-8592.
- [51] MENG J, CAI L, LUO G, et al. Lithium-ion battery state of health estimation with short-term current pulse test and support vector machine [J]. Microelectronics Reliability, 2018, 88: 1216-1220.
- [52] LI R, LI W, ZHANG H. State of health and charge estimation based on adaptive boosting integrated with particle swarm optimization/support vector machine (AdaBoost-PSO-SVM) model for lithium-ion batteries[J]. International Journal of Electrochemical Science, 2022, 17(2): 220212.
- [53] KLASS V, BEHM M, LINDBERGH G. A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation[J]. Journal of Power Sources, 2014, 270: 262-272.
- [54] WU T, HUANG Y, XU Y, et al. SOH prediction for lithium-ion battery based on improved support vector regression [J]. International Journal of Green Energy, 2023, 20(3): 227-236.
- [55] FENG H, YAN H. State of health estimation of large-cycle lithium-ion batteries based on error compensation of autoregressive model [J]. Journal of Energy Storage, 2022, 52: 104869.
- [56] CHEN Z, ZHANG S, SHI N, et al. Online state-of-health estimation of lithium-ion battery based on relevance vector machine with dynamic integration [J]. Applied Soft Computing, 2022, 129: 109615.
- [57] 张瑛, 康永哲, 段彬, 等. 基于数据-模型双驱动的电池组容量在线估计[J]. 机械工程学报, 1-12 [2024-03-19]. <http://kns.cnki.net/kcms/detail/11.2187.TH.20230428.1431.020.html>.
- ZHANG Y, KANG Y Z, DUAN B, et al. Online estimation of battery pack capacity based on dual driven method of data and model [J]. Journal of Mechanical Engineering, 1-12 [2024-03-19]. <http://kns.cnki.net/kcms/detail/11.2187.TH.20230428.1431.020.html>.
- [58] LIU E, NIU G, WANG X, et al. SOH diagnostic and prognostic based on external health indicator of lithium-ion batteries [C]. Proceedings of the IECON 2021-47th Annual Conference of the IEEE Industrial Electronics Society, IEEE, 2021.
- [59] VENNAM G, SAHOO A, AHMED S. A novel coupled electro-thermal-aging model for simultaneous SOC, SOH, and parameter estimation of lithium-ion batteries [C]. Proceedings of the 2022 American Control Conference (ACC), IEEE, 2022.
- [60] GHOLIZADEH M, YAZDIZADEH A. Systematic mixed

- adaptive observer and EKF approach to estimate SOC and SOH of lithium-ion battery[J]. IET Electrical Systems in Transportation, 2020, 10(2): 135-143.
- [61] LI P, WANG H, XING Z, et al. Joint estimation of SOC and SOH for lithium-ion batteries based on EKF multiple time scales[J]. Journal of Intelligent Manufacturing and Special Equipment, 2020, 1(1): 107-120.
- [62] PHAM N T, LA P H, CHOI S J. Online cell-by-cell SOC/SOH estimation method for battery module employing extended Kalman filter algorithm with aging effect consideration[J]. Journal of Power Electronics, 2022, 22(12): 2092-2099.
- [63] LAI X, YUAN M, TANG X, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries considering temperature and ageing[J]. Energies, 2022, 15(19): 7416.
- [64] 刘芳, 刘彦鹏, 李静东, 等. 车载动力电池放电过程健康状态在线估计[J]. 东北大学学报(自然科学版), 2022, 43(11): 1544-1551.
- LIU F, LIU Y P, LI J D, et al. Online estimation of state of health during discharging of vehicle power battery[J]. Journal of Northeastern University (Natural Science), 2022, 43(11): 1544-1551.
- [65] FANG L, LI J, PENG B. Online estimation and error analysis of both SOC and SOH of lithium-ion battery based on DEKF method[J]. Energy Procedia, 2019, 158: 3008-3013.
- [66] JIN S, YANG X, WANG C, et al. A novel robust back propagation neural network dual extended Kalman filter model for state-of-charge and state-of-health co-estimation of lithiumion batteries [C]. Proceedings of the 2023 IEEE PES Conference on Innovative Smart Grid Technologies-Middle East (ISGT Middle East), IEEE, 2023.
- [67] UNGUREAN L, CÂRSTOIU G, MICEA M V, et al. Battery state of health estimation: a structured review of models, methods and commercial devices [J]. International Journal of Energy Research, 2017, 41(2): 151-181.
- [68] BI Y, YIN Y, CHOE S Y. Online state of health and aging parameter estimation using a physics-based life model with a particle filter [J]. Journal of Power Sources, 2020, 476: 228655.
- [69] LI X, YUAN C, WANG Z, et al. Lithium battery state-of-health estimation and remaining useful lifetime prediction based on non-parametric aging model and particle filter algorithm[J]. Etransportation, 2022, 11: 100156.
- [70] WU T, LIU S, WANG Z, et al. SOC and SOH joint estimation of lithium-ion battery based on improved particle filter algorithm [J]. Journal of Electrical Engineering & Technology, 2022, 17(1): 307-317.
- [71] SHEN S, CI S, ZHANG K, et al. Lifecycle prediction of second use electric vehicle batteries based on arima model [C]. Proceedings of the 2019 IEEE Globecom Workshops (GC Wkshps), IEEE, 2019.
- [72] KIM S, LEE P Y, LEE M, et al. Improved State-of-health prediction based on auto-regressive integrated moving average with exogenous variables model in overcoming battery degradation-dependent internal parameter variation [J]. Journal of Energy Storage, 2022, 46: 103888.
- [73] RAMAN M, CHAMPA V, PREMA V. State of health estimation of lithium ion batteries using recurrent neural network and its variants [C]. Proceedings of the 2021 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT), IEEE, 2021.
- [74] CHAOUI H, IBE-EKEOCHA C C. State of charge and state of health estimation for lithium batteries using recurrent neural networks [J]. IEEE Transactions on Vehicular Technology, 2017, 66(10): 8773-8783.
- [75] YOU G W, PARK S, OH D. Diagnosis of electric vehicle batteries using recurrent neural networks [J]. IEEE Transactions on Industrial Electronics, 2017, 64(6): 4885-4893.
- [76] ZHANG L, JI T, YU S, et al. Accurate prediction approach of SOH for lithium-ion batteries based on LSTM method[J]. Batteries, 2023, 9(3): 177.
- [77] 周才杰, 汪玉洁, 李凯铨, 等. 基于灰色关联度分析-长短期记忆神经网络的锂离子电池健康状态估计[J]. 电工技术学报, 2022, 37(23): 6065-6073.
- ZHOU C J, WANG Y J, LI K Q, et al. State of health estimation for lithium-ion battery based on gray

- correlation analysis and long short-term memory neural network [J]. Transactions of China Electrotechnical Society, 2022, 37(23): 6065-6073.
- [78] LIU Q, KANG Y, QU S, et al. An online SOH estimation method based on the fusion of improved ICA and LSTM [C]. Proceedings of the 2020 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia), IEEE, 2020.
- [79] ZHANG W, LI X, LI X. Deep learning-based prognostic approach for lithium-ion batteries with adaptive time-series prediction and on-line validation [J]. Measurement, 2020, 164: 108052.
- [80] MENG J, CAI L, STROE D I, et al. An optimized ensemble learning framework for lithium-ion battery state of health estimation in energy storage system [J]. Energy, 2020, 206: 118140.
- [81] LYU Z, WANG G, GAO R. Synchronous state of health estimation and remaining useful lifetime prediction of Li-Ion battery through optimized relevance vector machine framework [J]. Energy, 2022, 251: 123852.
- [82] ZENG M, ZHANG P, YANG Y, et al. SOC and SOH joint estimation of the power batteries based on fuzzy unscented Kalman filtering algorithm [J]. Energies, 2019, 12(16): 3122.
- [83] CHE Y, LIU Y, CHENG Z. SOC and SOH identification method of li-ion battery based on SWPSO-DRNN [J].

IEEE Journal of Emerging and Selected Topics in Power Electronics, 2020, 9(4): 4050-4061.

- [84] HONG J, WANG Z, CHEN W, et al. Online accurate state of health estimation for battery systems on real-world electric vehicles with variable driving conditions considered [J]. Journal of Cleaner Production, 2021, 294: 125814.


作者简介



金帅, 2022 年于哈尔滨商业大学获得学士学位, 现为哈尔滨商业大学硕士研究生, 主要研究方向为锂离子电池健康状态估计。

E-mail: 1534213702@qq.com

Jin Shuai received his B. Sc. degree from Harbin University of Commerce in 2022. He is currently a M. Sc. candidate at Harbin University of Commerce. His main research interests include state of health estimation for lithium-ion battery.



董静 (通信作者), 分别在 2003 年、2006 年和 2013 年于哈尔滨商业大学获得学士学位、硕士学位和博士学位, 现为哈尔滨商业大学教授, 主要研究方向为优化设计。

E-mail: dongjing0320@163.com

Dong Jing (Corresponding author) received her B. Sc. M. Sc. and Ph. D. degree from Harbin University of Commerce in 2003, 2006 and 2013, respectively. She is currently a professor at Harbin University of Commerce. Her main research interests include optimization design.