

DOI: 10.3901/JME.2023.02.151

大数据驱动的动力电池健康状态估计方法综述^{*}

王震坡^{1, 2, 3, 4} 王秋诗^{1, 2} 刘 鹏^{1, 2, 3, 4} 张照生^{1, 2, 3, 4}

(1. 北京理工大学电动车辆国家工程实验室 北京 100081;

2. 北京电动车辆协同创新中心 北京 100081;

3. 新能源汽车北京实验室 北京 100081

4. 北京理工大学重庆创新中心 重庆 401120)

摘要: 动力电池健康状态估计是电池管理系统关键算法之一, 对提高动力电池能量利用效率、降低电池热失控风险, 以及动力电池的维保和残值评估具有重要意义。对比分析试验法、模型法、数据驱动法的优势和不足, 并以数据驱动方法为核心, 分别从动力电池健康状态数据集构建、健康状态特征参数提取、健康状态估计模型三个方面对现阶段健康状态估计方法的理论基础和技术方案进行综述。总结常用的大数据采集方法以及数据预处理方法, 明确大数据在健康状态评估中的意义。比较现有健康状态特征提取方法, 对其优劣以及适用场景做了分析。阐述不同健康状态估计模型的基本原理, 提出模型融合是未来技术发展方向。最后, 面向未来大数据实车应用场景, 对动力电池健康状态估计方面存在的问题和发展前景进行了总结和展望。

关键词: 大数据; 新能源汽车; 动力电池; 健康状态

中图分类号: TM912

Review on Techniques for Power Battery State of Health Estimation Driven by Big Data Methods

WANG Zhenpo^{1, 2, 3, 4} WANG Qiushi^{1, 2} LIU Peng^{1, 2, 3, 4} ZHANG Zhaosheng^{1, 2, 3, 4}

(1. National Engineering Laboratory for Electric Vehicles, Beijing Institute of Technology, Beijing 100081;

2. Collaborative Innovation Center for Electric Vehicles in Beijing, Beijing 100081;

3. Beijing Laboratory of New Energy Vehicles, Beijing 100081;

4. Beijing Institute of Technology Chongqing Innovation Center, Chongqing 401120)

Abstract: State of health estimation of power batteries is one of the key algorithms of the battery management systems, which is of great significance for improving power battery energy utilization efficiency, reducing thermal runaway risk, as well as power battery maintenance and residual value evaluation. Comparative analysis has been done on experimental-based, model-based and data-driven methods, and data-driven methods are elaborated from three aspects: dataset construction, health indicators extraction, model establishment. The big data collection methods and data preprocessing methods are summarized. The health indicators extraction methods are compared by their pros and cons and applicable scenarios. The basic principles of different health state estimation models are discussed. The conclusion that model fusion is the direction of future technology development is proposed. Finally, facing the future application scenarios of big data in electric vehicles, the current issue and prospective are depicted.

Key words: bid data; new energy vehicle; power battery; state of health

0 前言

面对日益严峻的化石能源短缺以及环境污染问

题, 发展新能源汽车成为世界各国的共识^[1]。作为一项新兴产业, 新能源汽车是“中国制造 2025”以及国家“十四五”时期重点发展的战略产业之一, 近年来技术水平发展迅速, 产业链日趋完善^[2]。2019 年, 我国新能源汽车产销量超过 120 万辆, 保持全球领先地位。2020 年 11 月 2 日, 国务院办公厅印

^{*} 国家重点研发计划(2019YFB1600800)和国家自然科学基金(5207120585)资助项目。20220128 收到初稿, 20220925 收到修改稿

发的《新能源汽车产业发展规划(2021—2035 年)》中明确了新能源汽车在国家能源结构调整过程中的重要地位,新能源汽车长期趋势向好。然而,近年来国内外频发的起火、自燃事故也成为新能源汽车发展的一大挑战。与此同时,随着互联网技术、信息技术的迅猛发展,数据已经成为重要的战略资源,美国、欧盟、日本等纷纷开展大数据战略布局。我国高度重视大数据发展,党的十八届五中全会将大数据上升为国家战略^[3]。新能源汽车电气化程度高,在运行过程中将会产生大量结构化和半结构化数据^[4],包括整车状态数据、电池包数据、电机数据等,在国家大数据战略的背景下,新能源汽车与大数据的融合发展必将成为汽车工业新的发展契机。

锂离子电池由于其能量密度高、循环寿命长、自放电率低等特点逐渐成为目前新能源汽车应用最为普遍的动力电池类型。然而,由于副反应的存在,锂离子电池性能会随使用时间的延长而衰减^[5],也称为老化现象,一般认为容量衰减至初始容量的 80% 或内阻升高一倍即达到电池寿命终止(End of life, EOL)^[6],无法满足新能源汽车的使用需求。随着新能源汽车保有量的不断提升,锂离子电池将会在未来几年迎来“退役潮”。此外,随着电池老化,隔膜的损伤会导致内短路,增加热失控风险。因此,准确评估动力电池健康状态(State of health, SOH)在新能源汽车动力电池全寿命周期能量精细化管理、维护维保、安全预警,以及梯次利用电池残值评估等方面具有重要意义。

动力电池健康状态一般通过容量衰减或内阻增加两个方面来定义。在注重续驶里程的纯电动汽车上,常用当前可用容量与初始可用容量的比来表征 SOH,如式(1)所示;而在对功率要求较高的混合动力汽车上,常用内阻增长率来表征 SOH,如式(2)所示。此外,动力电池的功率状态(State of power, SOP)也是电池老化的表现之一,可由式(3)计算。可见,动力电池的 SOH 并不能直接通过传感器获取,而需要在规定条件下,通过间接测量其表征参数,从而进行估算。因此,亟需建立高精度、在线、快速、无损的 SOH 估计方法。

$$\text{SOH}_C = \frac{C_i}{C_0} \times 100\% \quad (1)$$

$$\text{SOH}_R = \frac{R_{\text{EOL}} - R_i}{R_{\text{EOL}} - R_0} \times 100\% \quad (2)$$

$$\begin{cases} \text{SOP}_{\max}^{\text{chg}}(t) = \max(P_{\min}, U(t + \Delta t) \cdot I_{\min}^{\text{chg}}) \\ \text{SOP}_{\max}^{\text{dis}}(t) = \min(P_{\max}, U(t + \Delta t) \cdot I_{\max}^{\text{dis}}) \end{cases} \quad (3)$$

式中, SOH_C 、 SOH_R 分别表示以容量、内阻定义的健康状态, C_i 、 C_0 分别表示当前最大可用容量和初始最大可用容量, R_i 、 R_0 、 R_{EOL} 分别表示当前内阻、初始内阻和寿命截止时内阻。记放电电流为正,充电电流为负,则 $\text{SOP}_{\max}^{\text{chg}}(t)$ 、 $\text{SOP}_{\max}^{\text{dis}}(t)$ 分别表示电池 t 时刻的充电、放电功率状态, P_{\min} 、 P_{\max} 分别表示电池厂商所允许的最大充、放电功率, I_{\min}^{chg} 、 I_{\max}^{dis} 分别表示由于截止电压、荷电状态(State of charge, SOC)等限制,使电池可以持续充、放电 Δt 时间的最大充、放电电流, $U(t + \Delta t)$ 为电池在的 $(t + \Delta t)$ 时刻的电压。

国内外学者在 SOH 估计算法方面做出了重要贡献,现有算法可以分为试验法、模型法、以及数据驱动法三类,如图 1 所示。试验法主要根据 SOH 的定义,在严格控制的试验条件下对电池进行测试。其中,电池容量一般需要在恒温恒流的工况下对电池进行完全的充放电,并采用安时积分法计算;内阻的精确测定常常需要用到混合脉冲功率特性(Hybrid pulse power characteristic, HPPC)方法或电化学阻抗谱(Electrochemical impedance spectroscopy, EIS)分析法。因此,基于试验的方法无一例外地需要严格的试验条件以及复杂的试验设备,测试周期较长,不能应用于电池 SOH 的在线评估。

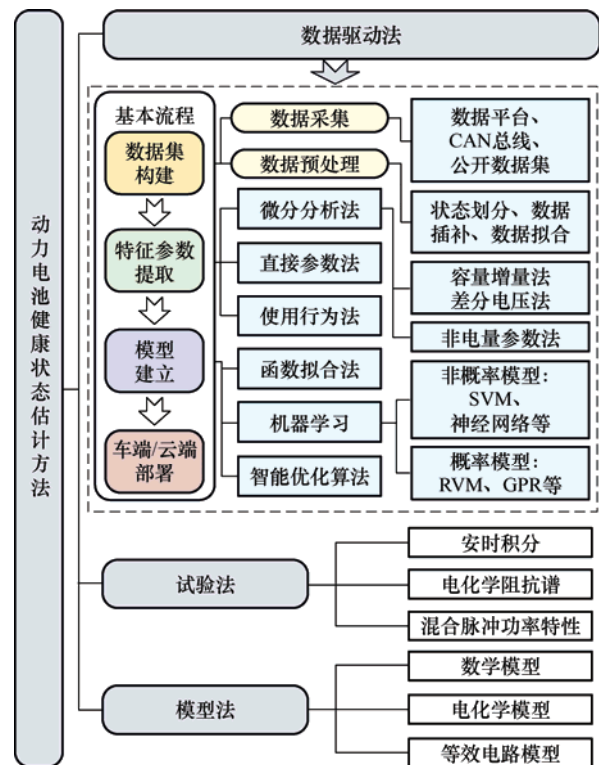


图 1 动力电池健康状态估计方法分类

为克服试验法的不足, 模型法通过建立电池模型, 模拟电池的动态响应特性, 从而实现健康状态估计。常用的电池模型有数学模型、电化学模型、等效电路模型等。数学模型主要包括经验模型和半经验模型, 它们通过试验模拟电池的循环老化和日历老化过程, 测定电流倍率、放电深度、温度、循环次数等动态应力对电池寿命的影响, 并通过数学方程拟合, 实现健康状态的估计^[7]。这种方法计算较为简单, 具有寿命预估的能力, 但需要大量离线试验, 且精度往往不高。基于电化学模型(Electrochemical model, EM)的方法使用偏微分方程来描述电池动态特性, 以及副反应所造成容量衰减和内阻增长的老化机理, 例如固体电解质界面(Solid electrolyte interface, SEI)膜的生长、锂损失(Loss of lithium inventory, LLI)和正负极活性物质损失(Loss of active material, LAM)等, 可以实现较高的精度^[8]。然而, 过高的模型计算复杂度限制了其在实际电池管理系统(Battery management system, BMS)中应用的可行性^[9]。等效电路模型(Equivalent circuit model, ECM)是一种应用广泛的电池模型^[10-11], 它使用电压源、电阻、电容等电路元件, 将电池动态特性用集总参数等效电路模拟, 并通过递推最小二乘法(Recursive least squares, RLS)^[12]、卡尔曼滤波(Kalman filter, KF)^[13-15]、 H^∞ 观测器^[16]、粒子滤波(Particle filter, PF)^[17-18]等状态估计算法辨识模型参数, 用以表征电池 SOH。此外, 有学者建立了用于 SOC 和 SOH 联合估计的双卡尔曼滤波器算法^[18], 以及多尺度扩展卡尔曼滤波^[20]等 SOH 估计方法。基于 ECM 的方法可以较好地模拟电池特性, 但常常需要提前精确地测定电池开路电压(Open circuit voltage, OCV), 给实车电池系统的应用带来了困难。

近年来, 大数据技术的蓬勃发展催生了大量数据驱动的 SOH 估计算法, 这类算法具有较高的灵活性, 并且无需对电池电化学机理的深入描绘^[21]。数据驱动的 SOH 估计方法从大量试验或实车运行数据中提取与电池健康状态相关的特征参数, 再通过模型的训练, 实现健康状态的估计。其主要涉及三个方面: ①健康状态数据集构建。不同于传统试验数据, 动力电池实际使用过程中产生的大数据具有数据规模大而价值密度低的特点, 因此, 数据的采集、预处理等方法都是数据驱动的 SOH 估计中的难点; ②健康状态特征参数提取^[22]。特征工程是把原始数据转变为模型的训练数据的过程, 它决定了模型精度的上限, 是数据驱动的 SOH 估计中的重要步骤; ③健康状态估计模型。数据驱动模型的意义

是建立输入与输出之间的映射关系, 是数据驱动的 SOH 估计算法的核心。

现有综述文献对基于试验、基于模型的动力电池健康状态估计方法已经有了较为详尽的分析和总结, 但在数据驱动算法方面, 往往仅针对模型的不同做了分类, 而对于数据集构建方法、健康状态特征参数提取过程中所使用的关键方法与技术, 并没有进行系统的分析和总结, 从而导致多种技术方案归类模糊、重复、交叉, 难以使读者掌握清晰的技术体系以及研究逻辑思路。因此, 本文将聚焦数据驱动的动力电池健康状态估计方法, 依据大数据分析基本流程(图 1), 从数据集构建、特征参数提取以及模型建立三方面对大数据技术在 SOH 估计方面的研究现状进行探讨和分析。

1 动力电池健康状态数据集构建方法

动力电池的老化与其历史使用行为密切相关。高温会加快负极 SEI 膜的增长以及电解液的分解, 导致锂离子损失和内阻升高; 低温和过充电导致的析锂反应会使电池容量衰减; 高倍率充放电不仅会导致析锂, 其产生的焦耳热也加速了电池老化。因此, 构建包括电池历史使用温度、电流、放电深度等参数的动力电池全寿命周期使用行为数据集是健康状态估计的必要前提, 其主要包括数据集的采集、预处理等内容。

1.1 动力电池老化大数据采集

在新能源汽车动力电池使用过程中, 车载终端传感器数据、道路交通数据、天气信息等多种结构化和非结构化数据构成了典型的大数据应用场景, 体现了新能源汽车运行数据大体量、多样性、时效性、准确性、价值深度的“5V”特点^[23]。随着车联网技术的发展, 云端数据平台在动力电池老化大数据采集中发挥着越来越重要的作用, 其基本功能架构如图 2 所示。通过云端监管, 可以实现均衡充电, 故障检测以及用于二次利用的电池衰退评估^[24]。美国 Analog Devices(ADI)公司宣布推出业内首个无线电池管理系统(wBMS), 可实现动力电池全生命周期数据监控。我国工业和信息化部建立了新能源汽车国家监测与管理平台(以下简称“国家平台”)^[25]和新能源汽车国家检测与动力电池回收利用溯源管理平台(以下简称“溯源平台”)。截至 2022 年 4 月, 国家平台接入新能源汽车已超过 800 万辆, 其存储数据类型包括车辆类型、生产厂商、电池系统标称能量等静态数据以及车辆状态、车速、里程、动力

电池总电压、总电流、SOC 等动态数据。静态数据和动态数据相结合, 构成了用于动力电池健康状态分析的关键数据集。溯源平台则对生产、使用、维

修、报废、梯次利用、回收利用等各个环节的信息进行监控, 实现了新能源汽车动力电池的全寿命周期信息管理。

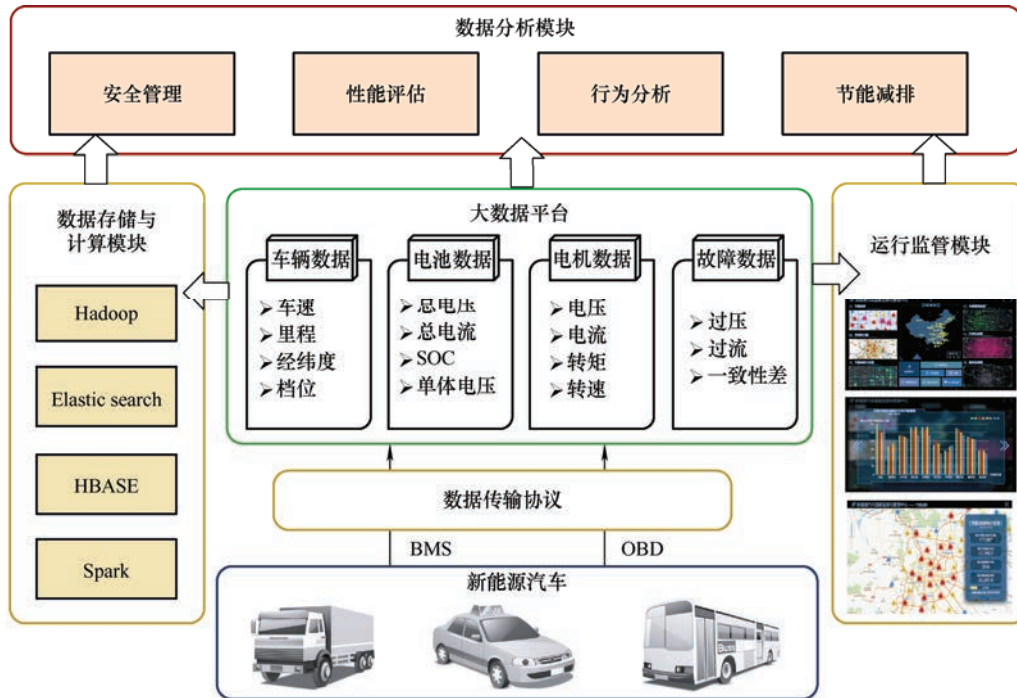


图2 云端数据平台主要功能架构

除以上数据采集方式外, 国内外科研人员通过采集车辆控制器所存储的车辆运行数据, 或通过试验测试模拟复杂的实车运行环境, 也构建了用于新能源汽车动力电池健康状态估计的多源异构大数据集。例如, KLASS 等^[26]读取沃尔沃 V70 插电式混合动力试验车时长一年的控制器局域网络(Controller area network, CAN)总线数据, 获得了实车运行条件下的电池包电压、电流、温度以及 SOC 等数据, 从而进行了 SOH 模型的建立, 其所使用电池包容量为 $32 \text{ A} \cdot \text{h}$, 采样频率为 2 Hz 。韩国三星先进技术研究院(Samsung advanced institute of technology, SAIT)YOU 等^[27]对 $3.1 \text{ A} \cdot \text{h}$ 的 18650 电池在 $10^\circ\text{C}/25^\circ\text{C}/45^\circ\text{C}/60^\circ\text{C}$ 多种温度下进行多种充放电循环工况组合测试, 建立了健康状态估计所需数据集。其中, 对于放电过程, YOU 等研究人员选取了 10 种车辆行驶工况, 包括 UDDS、LA92DDS、J1015、NYCC 等, 并考虑车辆质量、功率等因素, 将以车速表示的工况转换成以电流表示的电池工况, 并针对快充和慢充两种充电模式, 建立了 CC20(以 1C 倍率恒流充电 20 min)、CC40、CC60、以及 CCCV(以 0.3C 倍率充电至 4.2 V 后转换为恒流充电, 直至电流降低至 $1/20 \text{ C}$)四种充电工况。最后, 将温度、放电工况、充电工况随机组合, 形成了多

种模拟新能源汽车实际运行的工况。北京理工大学樊杰等^[28]对北京市内多款新能源乘用车动力电池老化行为进行了分析, 通过样本车辆筛选、数据采集器安装、数据回收及转换、数据存储与共享、数据预处理等步骤^[29], 对车载诊断系统(On board diagnostics, OBD)数据进行处理, 形成了实车动力电池运行大数据集。

由于锂离子电池老化试验时间周期较长, 试验条件要求较为严苛, 一些高校、科研机构以及企业进行了长达数月以至于数年的电池循环充放电加速寿命测试, 并将试验数据公开, 以推动电池健康状态估计与预测算法的开发。美国国家航空航天局(National Aeronautics and Space Administration, NASA)卓越故障预测研究中心(Prognostics Center of Excellence, PCoE)对 $2 \text{ A} \cdot \text{h}$ 锂离子电池在 4°C 、 25°C 、 40°C 等多种温度条件下进行了随机工况以及固定工况的充放电循环老化试验, 并测试了不同放电截止电压对电池寿命的影响^[30]。美国马里兰大学先进寿命循环工程中心(Center for Advanced Life Cycle Engineering, CALCE)的试验包括 $2 \text{ A} \cdot \text{h}$ NCM、 $2.23 \text{ A} \cdot \text{h}$ LiFePO_4 (LFP)圆柱形电池, $1.1 \text{ A} \cdot \text{h}$ LiCoO_2 (LCO)方形电池以及 1.5 Ah LCO 软包电池等, 通过改变不同温度、放电倍率、充放电截止电

压以及 SOC 区间等应力条件,对锂离子电池剩余寿命(Remaining useful life, RUL)进行了大量试验研究^[31-32]。此外,英国牛津大学^[33]、美国桑迪亚国家实验室^[34]也提供了锂离子电池老化试验的公开数据集。

实车动力电池采集数据与实验室测试数据的多源融合,构成了大数据驱动的动力电池健康状态估计的数据基础。

1.2 健康状态大数据集预处理

由于传感器采集精度的限制以及数据采集过程中不可避免的噪声影响,所构建的电池数据集常常存在一定的数据异常问题,而对于新能源汽车实车运行大数据,虽然目前车载终端稳定性较高,但在大量数据长时间的传输过程中,数据传输故障概率大大增加,造成数据准确性、完整性和一致性变差。因此,如何对含噪声、不完整的原始数据进行预处理,是基于大数据的电池健康状态估计方法的一大挑战与难点。数据的预处理方式一般包括数据清洗、数据集成、数据归约、数据变换与离散化、数据重构和数据降维等^[35]。

在动力电池健康状态估计模型建立过程中,需要对电池的充、放电过程进行分别讨论和分析,并提取与 SOH 相关的特征参数,而新能源汽车大数据常常为时序数据,并没有车辆行驶、停止、充电等状态的切分。因此,在进行 SOH 建模分析前,车辆状态的切分与重构非常关键。北京理工大学崔丁松^[36]建立了基于车辆运行数据的状态切分规则,如图 3 所示。将每一个数据帧状态划分为行驶、充电、停止、熄火和满电待机状态后,对数据进行有效性检验、数据跳变检验、长间隔连续性检验以及切分片段开始-结束连续性判断,最后,形成包括充电、行驶、满电待机状态的车辆状态统计初表。

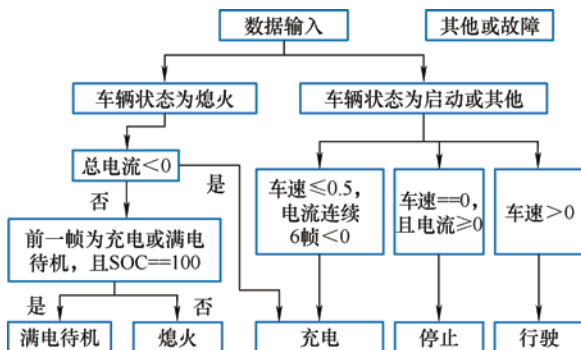


图 3 车辆状态切分规则

在动力电池大数据的数据清洗方面,很多学者针对不同数据异常类型提出了针对性的解决方案。北京理工大学赵洋^[37]将车联网数据故障划分为丢

包和误码两种,针对数据丢包问题,若数据为某时刻数据整行丢失,或某列属性值丢失,当丢失数据数量占比较低时,可采取删除处理;若某属性值小部分缺失,可以采用插补法,如均值差值、中值插值、样条插值等。针对数据误码问题,需要综合车辆技术参数、行驶地域特征等因素,确定误码判断的阈值。SHE 等^[9]利用支持向量回归(Support vector regression, SVR)算法对新能源汽车充电过程的电压曲线异常进行了滤波处理,如图 4 所示为所研究新能源汽车的电压-容量曲线^[9],从放大视图中可以看出,原始电压曲线在充电过程中出现了异常的降低,而经过 SVR 拟合后的曲线很好地避免了这个问题。LIANG 等^[38]通过箱型图分析法剔除了动力电池内阻辨识结果中的异常值,为模型的搭建提供了更为有效的数据集。SUN 等^[39]利用小波变换法对试验得到的电压数据进行去噪处理,并通过试验确定了三层分解具有最好的效果。




图 4 容量-电压曲线的 SVR 回归结果

2 健康状态特征参数提取方法

特征参数提取是机器学习中的重要环节,适当的特征构建和选择可以在降低模型复杂度的同时大幅提升模型精度。由于以容量、内阻来定义的动力电池健康状态难以直接获取,因此,常常需要从电池易于采集的电压、电流、温度等参数中提取能反映其健康状态变化的特征,这种特征参数被称为健康因子(Health indicator, HI)。本节将分类总结现有的健康因子提取方法,并进行对比分析。

2.1 微分分析法

在恒流充放电过程中,电池电-热-机械参数的变化可以反映其内部电化学反应机理,进而可以用来推测电池健康状态。本节从容量增量/微分电压法、差热伏安法以及机械参数微分分析法三个方面介绍常用的健康因子。

2.1.1 容量增量/微分电压法

容量增量分析(Incremental capacity analysis, ICA)和微分电压分析(Differential voltage analysis, DVA)法是电池健康状态估计的重要方法^[40]。在锂离子电池充放电过程中,其内部的相平衡状态会在外特性上表现为电压平台期,而电压平台的变化是电池衰退的直接反映。容量增量法能够将平缓的电压平台特征转化为容易识别的容量增量峰,是一种原位非破坏的 SOH 分析方法^[41]。容量增量即恒流充放电过程中一段电压间隔 ΔV 内的容量变化量 ΔQ ,其表达式如式(4)所示,将容量增量和电压的关系绘制在图上,即 IC 曲线,如图 5 所示^[10]。而微分电压为容量增量的倒数,其与容量的关系称作 DV 曲线,如图 6 所示,曲线峰值之间的距离可以表征相变过程中转移的电量^[42]。为降低极化现象带来的影响,常用较小的电流倍率(如 C/20)进行容量增量/微分电压试验,然而,极低的电流降低了测试的效率,阻碍了实车的应用。因此,有学者提出可以采用 C/3^[43]、C/2^[45] 的电流倍率进行容量增量分析,在精度相近的基础上提高了检测速度。

$$\frac{dQ}{dV} \approx \frac{\Delta Q}{\Delta V} = \frac{Q_i - Q_{i-1}}{V_i - V_{i-1}} \quad (4)$$




图5 锂离子电池容量增量曲线




图6 锂离子电池微分电压曲线

IC 和 DV 曲线通过对电压曲线的处理,可以从电化学机理上反映电池老化过程。因此,曲线上的多种特征都可以作为评估电池健康状态的健康因子^[44],如峰的位置^[45]、高度^[46]、面积^[47],以及不同峰值之间的距离^[48-49]等。由于完整的 IC 曲线在实车应用条件下难以获取,LI 等^[10]利用部分容量增量曲线特征实现了 SOH 的估计,如图 5 所示,在 3.4~3.8 V 电压区间,不同循环次数电池的 IC 曲线没有明显差异,而 3.8~4.1 V 区间内,IC 曲线发生了显著变化,因此,LI 在 3.8~4.1 V 区间内,每隔 30 mV 选取一个特征点,并通过皮尔逊相关系数分析法,选出了 6 个与 SOH 相关性最高的特征点作为健康因子,以进行后续的模式搭建。WANG 等^[49]的研究表明,DV 曲线两峰值之间的电压区间与电池容量呈线性相关,可以用来对 SOH 进行估计。虽然推导过程相似,但相比于 IC 方法,DV 曲线以容量作为横坐标,而新能源汽车 SOC 估计的不准确性会导致 DV 峰位的偏差,限制了其在实际车辆上的应用。

在容量增量分析过程中,由于测量噪声的存在,通过式(4)直接得到的容量增量曲线可能存在较大的波动,甚至出现 dV 为零的情况,难以进行曲线的绘制和特征的提取,如图 7 所示。因此,研究人员使用多种滤波算法对 IC 曲线进行了平滑处理,如滑动均值滤波^[50]、高斯滤波^[9,45]、Savitzky-Golay 滤波^[51]以及小波变换^[46]等。LI 等^[10]通过对比发现,相比于将数据用邻域内数值的均值代替的滑动均值滤波方法,高斯滤波对邻域内数据采取加权的方式,可以更好地识别 IC 曲线的峰值,如式(5)和图 7 所示。此外,电压间隔 ΔV 的大小以及滤波窗口的大小,也会影响 IC 曲线的结果^[52]。




图7 不同滤波方法得到的 IC 曲线对比^[10]

$$G(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \quad (5)$$

式中, μ 和 σ 分别为均值和标准差。

2.1.2 非电量参数法

除电压、电流外, 电池的温度以及压力等非电量参数也会随老化而发生变化, 可以辅助 SOH 的估计。差热伏安法 (Differential thermal voltammetry, DTV) 通过恒流充放电条件下电池表面温度在单位电压区间内的变化量来反应电池的热力学特征^[53], DTV 曲线的峰值和峰位可以反应相变过程中熵的信息。MERLA 等^[54]将 DTV 曲线分解为多个峰, 分别代表正负电极的不同相, 进而分析电池 SOH, 此方法也可以拓展到电池包上应用^[55]。与 IC/DV 法相比, DTV 在较高的电流倍率下同样可以实现与低倍率试验相近的结果, 降低了测试所需时间。然而, DTV 方法容易受环境温度的影响, 变化的温度会带来较大的测量噪声。

锂离子在正负极中嵌入/脱嵌的过程会导致电极体积的膨胀或收缩^[6], 使电芯表面产生一定的应力。基于此, 有学者在电池表面安装负载传感器, 并提取其机械应力和应变的情况以估计电池健康状态^[56-57], 这种方法称为机械参数微分分析法 (Differential mechanical parameter, DMP)。DMP 法同样可以在高电流倍率下使用, 但是基于应变的测量方法在空间受限的成组电池上难以应用, 而且需要额外在电池包内添加光纤传感器等设备, 增加了测量成本。

2.2 直接参数法

微分分析法需要将电压、温度等曲线进行微分运算, 计算量较大, 并且容易放大测量噪声的影响, 常常需要平滑算法。针对此类问题, 国内外学者提出了多种直接基于 BMS 所能采集的电压、电流、温度等参数的健康因子提取方法^[58], 这类方法无需电池模型和曲线微分, 数据的获取较为便捷, 称为直接参数法。LI 等^[59]将电池恒流充电过程分为 3.4~3.6 V、3.6~3.8 V、3.8~4.0 V 三个特征片段, 在每个片段内以 30 mV 为间隔提取电压-容量曲线上的特征点, 用特征点的横、纵坐标作(即电压、容量值)为动力电池健康因子, 并验证了 3.6~3.8 V 电压区间的数据可以实现高精度的电池健康状态估计。类

似的, RICHARDSON 等^[60]从电池恒流充电时的时间-电压曲线上选取多个特征点进行 SOH 估计, 并验证了该方法相比于 IC 法具有更高的精度。GUO 等^[61]从电池 CCCV 充电的电压、电流、温度曲线上提取了 14 个健康因子, 包括恒流恒压段时间、电流曲线下面积、温度曲线下面积、电压电流曲线最大斜率等, 利用灰色关联分析法, 确定了 8 个与容量相关度较高的参数, 结合主成分分析 (Principal component analysis, PCA), 进一步将特征降维。此外, 研究人员还提出了固定电压区间所用的充电时间^[62]、等时间段内电压变化^[63]、满电静置状态的开路电压^[64]、电压曲线概率密度函数^[65]等健康因子来表征电池容量随老化过程的衰减。

除此之外, 国内外科研人员还提出了 HPPC 工况下的电压样本熵^[66]、超声波检测法^[67]等 SOH 评估方法。然而, 这些方法需要严格的试验条件, 或需要在电池包内加装传感器, 应用场景有一定的限制。

2.3 基于使用行为的方法

上述方法多采用恒流充放电过程中的数据, 取得了较高的 SOH 估计精度, 而在实际的应用中, 恒流放电工况很少出现, 而充电也常常采用阶梯型电流模式。为适应复杂多变的工况, 学者建立了结合电池历史使用行为的 SOH 估计方法。YOU 等^[27]对电池进行了多种工况的老化试验, 将 BMS 可以直接获取的电流(I)、电压(V)、温度(T)三个数据以三维散点图的形式表示, 如图 8 所示, 图 8a~8e 为在 LA92DDS、HWY、ECE 等不同工况循环下, 电流-电压-温度(I - V - T)三个参数的分布情况^[27]。其中, ECE 工况展示了电池在新、中、老三个不同老化状态下的参数分布, 左侧是 3 种工况下的电池容量衰退路径。进而, 将所有测试工况数据融合, 并聚类为 80 个区域, 以每个区域的数据点密度分布作为电池健康因子, 利用神经网络模型计算 SOH。RICHARDSON 等^[68]利用公开的 NASA 随机充放电数据集, 除常见的电压、电流、温度参数外, 还使用温度和电流的分布等电池使用行为标签, 得到了适用范围更广的 SOH 模型。这类方法具有很大的创新性, 突破了原有方法需要恒流充放电数据的限制, 以电池历史使用行为作为模型输入, 提高了实车可用性。

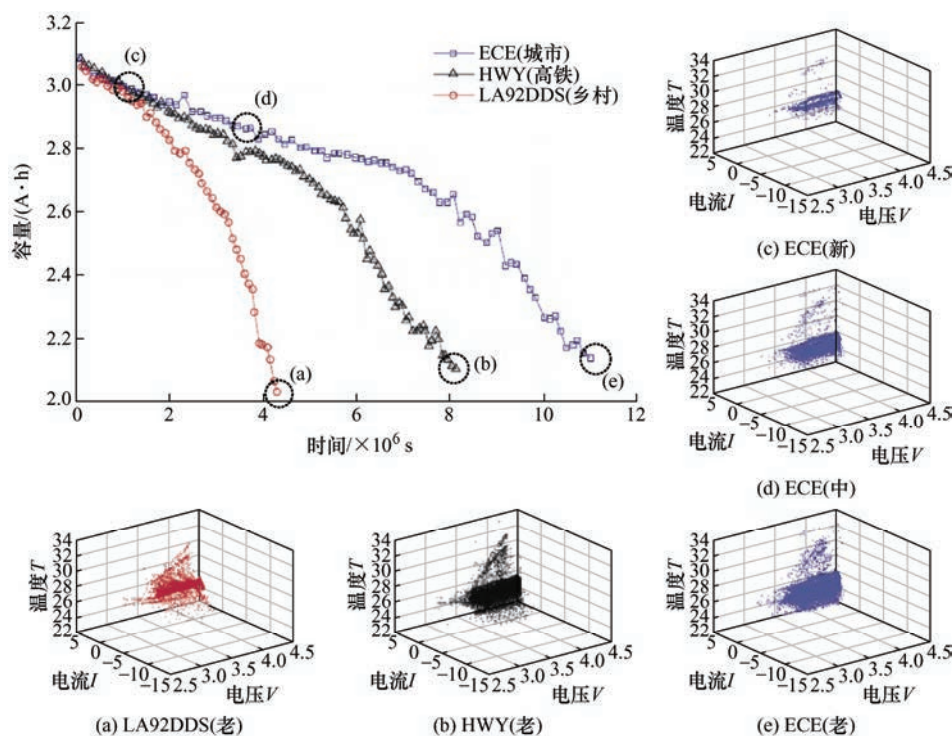


图 8 不同老化状态下历史数据分布

SHE 等^[9]以容量增量曲线第二峰值作为健康状态评价参数, 基于新能源公交车运行监控大数据, 系统分析了实车条件下影响车辆健康状态的因素, 并提取每一符合条件的恒流充电段的累计行驶里程、充电起始 SOC、平均充电电流、平均充电温度、两次充电间的平均行驶过程温度、以及依据不同衰退模式所确定的分类因子作为模型输入, 以容量增量第二峰值为模型输出, 利用径向基函数神经网络(Radial basis function neural network, RBFNN)进行了健康状态的估计, 如图 9 所示^[9]。北京理工大学洪吉超^[69]基于实车运行监控大数据, 提取新能源汽车每次行驶与充电过程的累计里程、总电压、电流、温度、SOC、车速等数据作为健康因子, 对每一行驶/充电过程的 SOH 损耗量进行准确估计。LIANG 等^[38]通过相关系数分析, 发现行驶里程和温度是影响新能源汽车电池系统欧姆内阻的主要因素, 进而用车辆行驶里程和电池包温度实现了欧姆内阻的估计和预测^[70]。FRISK 等^[71]分析了欧洲 5 个国家 33 603 辆车的的历史数据, 并基于车载铅酸电池更换记录, 提取包括温度、压力、电流和电压分布等特征, 对电池

使用寿命进行预估。这类数据驱动方法基于实车运行大数据, 能适应复杂多变的工况, 未来具有较好的发展前景。

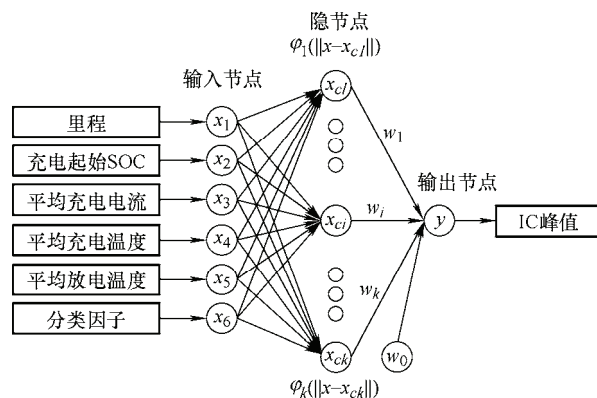


图 9 基于实车运行数据的健康状态估计模型

特征参数提取的好坏直接关系到动力电池健康状态估计模型精度的上限。本章从微分分析法、直接参数法以及基于使用行为的方法三方面对现有健康状态特征参数提取方法做了介绍和分析, 每种方法均存在一定的优势与不足。三类方法的对比分析如表 1 所示。

表 1 不同健康状态特征参数提取方法对比

	优势	不足	应用场景
容量增量法/微分电压法	所需测量参数少(电压、电流) 易于 BMS 实施或在线应用 可反映电池衰退机理	需要恒流工况，且电流倍率不能过大 对噪声较敏感，需要滤波处理 结果受温度影响较大	以恒流充放电工况为主的 锂离子电池使用场景
微分分析法		DTV 方法受限于目前车载温度传感器精度限制 DMP 方法需要额外加装传感器	电池系统具有高精度的 温度、负载传感器的场景
非电量参数法	可以在较高倍率工况下应用 在并联电池组 SOH 分析上具有优势		
直接参数法	无需微分运算，降低了计算成本 可实现在线应用	受工况影响较大 需要特定的充放电片段	数据采集精度和频率较高的场景
基于使用行为的方法	可应用于多种工况，鲁棒性高 可实现在线应用	需要大量数据进行模型训练	车辆历史行为数据较为完整的场景

3 数据驱动的健康状态估计模型

数据驱动算法的关键步骤是建立特征参数(输入)与目标参数(输出)之间的映射关系，即使用大量已标定数据训练模型，优化模型结构和参数，从而实现目标参数的估计和预测。本节从函数拟合法、机器学习模型、以及智能优化算法三方面重点阐述现有健康状态估计模型。

3.1 函数拟合法

如前所述，研究人员通过试验发现健康因子与电池健康状态存在线性相关关系，或可直接找到其解析函数，因此，利用一次函数、二次函数、幂函数等函数对其进行拟合，实现了 SOH 快速计算。

LI 等^[45]对 NCM-石墨电池进行了试验，发现 IC 曲线上第一峰值 A、第二峰值 B 以及谷值 D 在横坐标轴上的位置随循环次数的增加具有单调变化趋势，如图 10a、10b 所示，并进一步发现三个特征参数与电池 SOH 存在线性相关关系，A、B 和 D 的拟合优度分别达到 0.98、0.99 和 0.98，如图 10c、10d。由此，根据 SOC 不同区间，提出了利用 A、B、D 三个参数进行 SOH 估计的方法。WENG 等^[46]通过曲线拟合，利用容量增量峰值高度实现了 SOH 估计。这种方法在试验中取得了较好的结果，且计算简单，易于进行车载系统集成。然而，函数拟合法常常在某种特定工况下得到，而对于不同电池类型，以及实车复杂交变的使用情况，其鲁棒性难以得到保证。

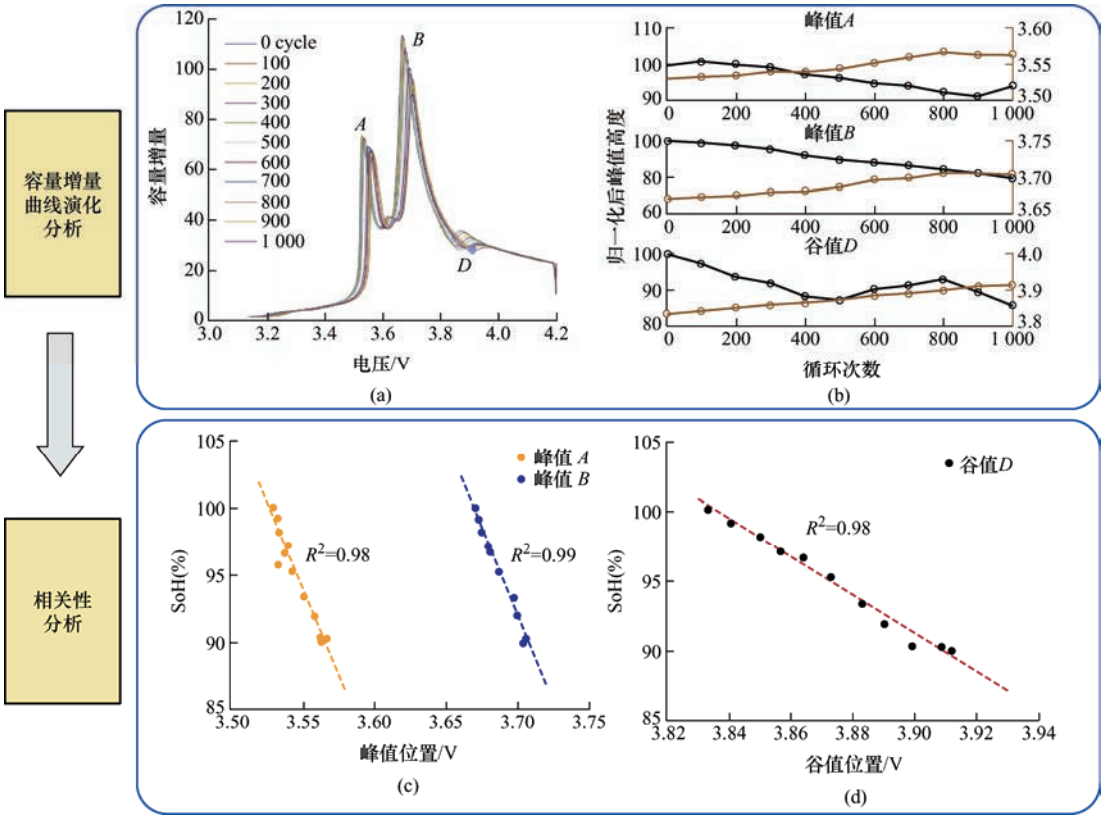


图 10 容量增量曲线特征值与电池健康状态之间的关系^[45]

3.2 基于机器学习的方法

机器学习致力于研究如何通过计算的手段,利用经验来改善系统自身的性能^[72]。随着大数据技术的发展,机器学习方法作为人工智能最重要的实现方式之一,得到了迅速的发展,并广泛应用于图像识别、生物医学等各行各业。在新能源汽车领域,机器学习也已经深入到动力电池状态估计^[73]、故障诊断^[74]、驾驶行为分析^[75]、能耗预测^[76]、充电基础设施选址以及需求预测^[77-78]等方方面面。在动力电池健康状态估计方面,常用的机器学习模型可以分为非概率模型和概率模型^[6]。非概率模型仅学习输入和输出之间的映射关系,并不考虑其概率分布;而概率模型基于贝叶斯理论,可以同时定量计算模型不确定度。

3.2.1 非概率模型

支持向量机(Support vector machine, SVM)通过核函数将原始非线性数据映射到高维特征空间,使样本在此特征空间内线性可分,进而寻找最大划分间隔的超平面,实现对非线性数据的分类^[79]。由于健康状态估计是机器学习中的回归问题,因此支持向量机常被用作连续数值的回归,称为支持向量回归(SVR)。此时,寻找最大划分间隔平面则变成寻找最佳拟合平面。SVR 算法的目标是实现如式(6)所示的优化问题。

$$\begin{aligned} \min \quad & \frac{1}{2} \omega^T \omega + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t.} \quad & \begin{cases} y_i - (\omega^T x_i + b) \leq \varepsilon + \xi_i^* \\ (\omega^T x_i + b) - y_i \leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0, i=1, \dots, l \end{cases} \end{aligned} \quad (6)$$

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 是目标输出, x_i 是特征向量。

由于其较强的非线性拟合能力,SVR 在 SOH 估计方面得到广泛应用。VERENA 等^[80]将循环试验所测得的电池电流、温度以及 SOC 三个参数作为输入,以电池端电压作为输出,训练了 SVR 模型来拟合电池动态特性。对电池 SOH 进行估计时,通过人为设置的电流(HPPC 工况或恒流充放电工况等)、温度以及 SOC 值输入训练完成的模型,进行仿真测试,进而通过模型预测的电压曲线间接计算电池内阻以及容量。NUHIC 等^[81]将电池循环次数、使用时间、温度等参数归一化处理,使用 SVR 建立了特征参数与健康状态的对应关系。ZHAO 等^[82]以充电和放电阶段经过恒定电压区间的时间作为模型输入,

将特征向量选择与 SVR 算法进行融合,有效减小了训练数据集的大小,提高了模型计算效率。除此之外,SVR 也可以与 IC/DV 方法^[46]、ECM 模型方法^[83]结合,提高原有模型精度。然而,SVR 算法所消耗的计算量较大,为此,有学者提出利用增量学习方法改善 SVR 的计算效率^[84]。

人工神经网络(Artificial neural network, ANN)模拟了生物神经网络的基本原理,是一种可以模拟人脑对信号激励处理方式的数学模型。ANN 由输入层、隐含层和输出层组成,每层又由一定数量的神经元组成。神经网络有多种类型,而在 SOH 估计领域,最常用的是前馈神经网络(Feed forward neural network, FFNN)和循环神经网络(Recurrent neural network, RNN),其中,前馈神经网络的输入层与隐含层之间采用全连接的方式,隐含层神经元对输入层神经元数据进行加权求和,经过偏置项阈值的处理,再通过激活函数传递给下一层神经元。在神经网络的实际应用中,隐含层的数量、每层的神经元数量、神经元的激活函数以及学习率等是需要人为调整的超参数,其确定后,FFNN 一般采用误差反向传播算法(Back propagation, BP)进行权值和阈值的更新。YOU 等^[27]利用随机梯度下降算法训练了前馈神经网络,实现了通过电池历史使用数据分布估计电池 SOH。WU 等^[85]以电池恒流充电曲线作为预测电池健康状态和剩余寿命的特征参数,将重要性采样策略应用到前馈神经网络输入选取,以减少神经元数量。SHE 等^[9]采用 RBF 神经网络实现了基于实车运行数据的健康状态评估,RBF 神经网络用径向基函数作为隐层的激活函数,将输入特征映射至高维空间,因此,RBF 神经网络仅有一个隐含层,且可以避免陷入局部最优^[86]。

以长短时记忆网络(Long short-term memory, LSTM)为代表的循环神经网络对前后相关的时间序列数据具有较强的拟合能力,而电池老化也是一个随时间而逐步变化的过程,因此循环神经网络被广泛应用于电池健康状态估计和剩余寿命预测^[87-88]。YOU 等^[89]通过测量电池充电过程中的电流和电压数据,利用 LSTM-池化-回归的三级模型结构实现了 SOH 的准确估计。LI 等^[90]将 Elman 神经网络与 LSTM 网络进行结合,以预测电池健康状态,并通过试验证明了其与单一模型相比具有更高的精度。ZHANG^[91]基于 LSTM 神经网络实现了电池健康状态预测,并利用 Dropout 和正则化技术防止过拟合。LIU 等^[92]提出自适应 RNN 模型,从阻抗的角度预测了锂离子电池的健康状态。

近年来, 基于决策树的机器学习模型获得了学者的广泛关注。决策树是一种非参数模型, 它可以根据数据的复杂度生成一个由“根节点”“枝节点”和“叶节点”组成的特征判定序列。特征属性的划分主要通过信息增益以及基尼指数等方式。LI 等^[59]将随机森林算法应用于 SOH 估计。随机森林是决策树的拓展, 它将数据集进行随机采样, 生成多颗决策树, 并通过其之间的加权求和, 获得最终的预测结果。LIANG 等^[38]运用了基于决策树理论的极端梯度提升(eXtreme gradient boosting, XGBoost)模型实现了电池欧姆内阻的准确计算和预测。

3.2.2 概率模型

概率模型认为预测均存在一定的不确定性, 输出结果的同时也会输出相应的置信度和置信区间。最常用的概率模型有相关向量机(Relevance vector machine, RVM)和高斯过程回归(Gaussian process regression, GPR)等。相关向量机是一种贝叶斯稀疏核方法, 其具有与支持向量机相似的结构, 可以用于分类和回归问题。LIU 等^[93]利用相关向量机对电池的健康状态进行估计和预测, 从电池放电电压中提取健康因子, 利用 Box-Cox 变换进行优化, 以改进剩余寿命预测的性能。LI 等^[94]使用小波分析法降低信号噪声, 建立了基于相关向量机和平均熵理论的非线性时间序列 SOH 及剩余寿命预测模型。

高斯过程回归是一种基于贝叶斯理论的非参数概率模型, 其适用于高维度、小样本等复杂问题, 并且可以实现不确定性的概率输出, 对动力电池 SOH 的评估以及预测具有重要意义。LI 等^[95]利用高斯滤波对 IC 曲线进行处理, 并提取片段 IC 曲线作为健康因子, 进而基于高斯过程回归建立了 SOH 估计模型。RICHARDSON 等^[96]运用多输出 GPR 模型实现了电池寿命预测。然而, 电池容量在环境因素影响下可能出现短暂的再生, 使 GPR 模型难以精确捕捉, 对此, LIU 等^[97]利用 GPR 中协方差函数和均值函数的组合来进行多步预测, 解决了这一问题。

除以上方法外, 马尔可夫链^[98]、模糊逻辑^[99]、蒙特卡罗方法^[100]等也在健康状态估计领域得到应用。机器学习方法可以在 SOH 估计方面取得很高的精度, 但需要大量有标签数据对模型进行训练, 需要消耗大量的计算资源, 使模型的在线训练变得困难。随着大数据技术的发展, 数据平台云计算使各种机器学习算法的训练变为可能, 也为车辆健康的

实时管理提供了支撑。

3.3 智能优化算法

机器学习的超参数寻优是一个非常消耗计算资源的过程。传统的梯度下降算法对初始值的依赖较高, 由于系统的非凸性, 很容易陷入局部最优, 因此, 研究人员应用了多种对初始值依赖程度低、无需计算函数梯度的智能优化算法, 也叫做元启发式算法。其中, 遗传算法(Genetic algorithm, GA)和粒子群优化(Particle swarm optimization, PSO)在 SOH 估计领域获得广泛关注, 它们启发式的特征大大提高了超参数寻优的效率。

遗传算法是模拟生物进化过程的一种随机搜索的全局优化算法^[101], 该方法借助生物进化过程中的“适者生存”的规律, 通过对目标问题的解集中个体的遗传变异操作, 使得适应目标问题的解获得较大的遗传概率, 进而逐步逼近最优解或最优解集合^[102]。WANG 等^[103]阐述了一种基于多岛遗传算法和高斯过程回归融合的 SOH 估计方法。其中, 多岛遗传算法突破了传统遗传算法种群单一的限制, 通过种群内部遗传和种群间的交叉, 使得子代具有更高的概率获得优良基因, 从而降低陷入局部收敛的风险^[104]。

粒子群优化算法采用粒子群在解空间中追随最优粒子进行搜索^[105], 通过计算每个适应度使粒子不断学习个体最优解和群体最优解, 并更新搜索方向, 从而实现全局最优。QIN 等^[106]将粒子群优化算法与 SVR 相结合, 以优化 SVR 的核参数, 从而提高寿命预测精度。GAO 等^[107]建立了以径向基为核函数的支持向量机模型来预测电池容量, 同样应用了粒子群优化算法对超参数进行调优。

智能优化算法还可以与 ECM 模型法结合, 以辨识模型参数。YANG 等^[108]首先离线建立了容量-SOC-开路电压的三维响应面, 并结合一阶 RC 等效电路模型, 使用遗传算法辨识模型 SOC 和容量, 实现 SOH 估计。然而, 这种方法应用于 OCV 曲线随老化变化不大的电池类型时, 会出现较大误差。CHEN 等^[109]提出电池扩散电容与 SOH 具有强相关性, 并建立二阶等效电路模型, 利用遗传算法辨识了模型参数。

综上所述, 为建立健康状态特征参数与动力电池健康状态之间的映射关系, 以通过片段的、离散的数据特征实现 SOH 的估计, 国内外研究人员建立了多种数据驱动的健康状态估计模型, 其对比分析如表 2 所示。

表 2 不同健康状态估计模型构建方法对比

	优势	不足	应用场景
函数拟合法	计算便捷, 易于应用	对不同电池类型的泛化能力较差	特征线性度较高的场景
支持向量机	对非线性数据有较好的拟合能力 对离群点的鲁棒性好 可以处理非线性问题	训练数据量过大时, 过多的支持向量导致训练速度缓慢	特征非线性较强的场景
神经网络	循环神经网络对时间序列数据具有较好的拟合能力	深度神经网络和循环神经网络模型训练计算量大, 所需时间长	存在一定比例的误码和缺失值的场景
机器学习	决策树	容易出现过拟合问题 不均衡的数据集会导致特征选择的偏差 容易出现过拟合问题	
	概率模型	核函数的选取对模型精度影响较大 容易陷入局部最优	
智能优化算法	可实现全局最优 可与机器学习算法、等效电路模型算法结合, 实现参数寻优	启发式算法需要多次迭代, 难以在线计算	离线计算场景

4 当前主要问题及展望

电动化、智能化、网联化是未来汽车技术的发展方向^[110], 新能源汽车与大数据融合发展将成为中国汽车产业未来发展的重要机遇。目前, 在动力电池健康状态管理方面, 还存在许多待解决的问题。随着大数据、云计算、5G 通信等技术的发展与成熟, 动力电池健康管理技术亟需一场大数据驱动的变革。

(1) 面向梯次利用及安全管理需求, 构建多维度健康状态评价体系。

梯次利用是应对即将到来的动力电池“退役潮”的重要途径, 而余能检测、残值评估、安全性及不一致性评价、电池分选等是梯次利用过程的关键技术。传统以容量和内阻定义的健康状态并不能综合反映动力电池尤其是动力电池系统的综合老化程度, 在梯次利用过程中容易出现不匹配的问题。因此, 应拓展现有健康状态评价维度, 结合电池峰值功率能力、不一致性等参数进行综合评估。构建多维度融合的健康状态评价体系有利于更为全面地反映电池老化特征, 从而推动梯次利用的精准匹配和高效应用。

(2) 基于多源耦合稀疏大数据, 挖掘动力电池使用行为与 SOH 的关联规则。

传统数据分析方法仅使用少量、低维数据, 而在大数据应用场景下, 数据具有量级大、多源耦合、结构化与非结构化并存、以及时间维度稀疏等特点, 因此, 需要开发兼容多类型数据的分布式存储与计算框架, 优化数据清洗、数据降维以及数据重构技术。此外, 由于电池健康状态与其历史使用行为息

息相关, 因此应发挥大数据特点, 除电压、电流、温度等数据外, 结合环境数据、驾驶行为数据, 并探索超声波检测等多传感器数据融合技术, 挖掘电池在新能源汽车上的实际使用行为与健康状态的关联规则。

(3) 突破单一应用场景, 建立全工况系统级 SOH 精确估计方法。

现有 SOH 估计和寿命预测的技术手段多基于精确控制的试验条件, 而实际新能源汽车的运行工况非常复杂, 存在多影响因素耦合效应, 基于环境工况的试验方法难以在实际车辆上应用。此外, 现有研究多基于电池单体或少量电池模组开展, 其结果与实车电池包存在较大差异, 影响了模型的实用性。因此, 需要考虑复杂交变应力对动力电池健康状态的影响, 研究多参数耦合及解耦机制, 建立电池系统模型, 探索全工况、系统级的 SOH 估计方法。

(4) 推动模型-数据融合, 实现 SOH 快速无损在线辨识。

近年来, 模型融合技术获得了广泛的关注。以 Adaboost、随机森林为代表的集成学习方法即是多个学习器的集成技术, 并已经证明了在 SOH 估计领域的优秀效果。此外, 动力电池 EM 模型、黑箱模型与数据驱动算法的融合也将成为未来发展的重要方向。而随着机器学习技术的发展, 强化学习、迁移学习, 以及无监督学习技术也有望在 SOH 估计方面取得重要突破。

5 结论

综述了大数据驱动的新能源汽车动力电池健康状态估计的主要方法与技术方

(1) 在健康状态数据集构建方法方面, 从数据采集、数据预处理方法等角度对当前动力电池数据集构建方法进行了总结。

(2) 在健康状态特征参数提取方面, 总结了包括机-电-热等方面的多种动力电池健康状态特征参数, 并对其优劣以及适用场景做了分析。

(3) 在健康状态估计模型方面, 总结了以数据驱动方法为核心的动力电池健康状态估计模型, 并对每种模型的特点进行了简要分析。

动力电池 SOH 估计对新能源汽车安全运行具有重要意义, 而大数据技术的发展为 SOH 估计提供了有力的工具。虽已取得大量理论和试验成果, 但动力电池 SOH 估计方法在实车电池系统上的应用还面临诸多挑战。

参 考 文 献

- [1] 孙振宇, 王震坡, 刘鹏, 等. 新能源汽车动力电池系统故障诊断研究综述[J]. 机械工程学报, 2021, 57(14): 87-104.
SUN Zhenyu, WANG Zhenpo, LIU Peng, et al. Overview of fault diagnosis in new energy vehicle power battery system[J]. Journal of Mechanical Engineering, 2021, 57(14): 87-104.
- [2] 中国工程科技发展战略研究院. 中国战略性新兴产业发展报告(2019)[M]. 北京: 科学出版社, 2018.
Chinese Institute of Engineering Development Strategies. Developing report on China's strategic emerging industries (2019) [M]. Beijing: Science Press, 2018.
- [3] 梅宏. 大数据发展现状与未来趋势[J]. 交通运输研究, 2019, 5(5): 1-11.
MEI Hong. Current situation and future trends of big data development[J]. Transport Research, 2019, 5(5): 1-11.
- [4] WANG Z, HONG J, LIU P, et al. Voltage fault diagnosis and prognosis of battery systems based on entropy and Z-score for electric vehicles[J]. Applied Energy, 2017, 196: 289-302.
- [5] HU X, XU L, LIN X, et al. Battery lifetime prognostics[J]. Joule, 2020, 4(2): 310-346.
- [6] 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.
- [7] 张永志. 车用锂离子动力电池健康状态识别与剩余寿命预测[D]. 北京: 北京理工大学, 2018.
ZHANG Yongzhi. State of health identification and remaining useful life prediction of lithium-ion batteries for electric vehicles[D]. Beijing: Beijing Institute of Technology, 2018.
- [8] MARKEVICH E, SALITRA G, AURBACH D. Fluoroethylene carbonate as an important component for the formation of an effective solid electrolyte interphase on anodes and cathodes for advanced Li-ion batteries[J]. ACS Energy Letters, 2017, 2(6): 1337-1345.
- [9] SHE C, WANG Z, SUN F, et al. Battery aging assessment for real-world electric buses based on incremental capacity analysis and radial basis function neural network[J]. IEEE Transactions on Industrial Informatics, 2020, 16(5): 3345-3354.
- [10] LI X, WANG Z, YAN J. Prognostic health condition for lithium battery using the partial incremental capacity and Gaussian process regression[J]. Journal of Power Sources, 2019, 421: 56-67.
- [11] 胡晓松, 唐小林. 电动车辆锂离子动力电池建模方法综述[J]. 机械工程学报, 2017, 53(16): 20-31.
HU Xiaosong, TANG Xiaolin. Review of modeling techniques for lithium-ion traction batteries in electric vehicles[J]. Journal of Mechanical Engineering, 2017, 53(16): 20-31.
- [12] GUO X, KANG L, YAO Y, et al. Joint estimation of the electric vehicle power battery state of charge based on the least squares method and the Kalman filter algorithm[J]. Energies, 2016, 9(2): 100.
- [13] ZOU Y, HU X, MA H, et al. Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan for electric vehicles[J]. Journal of Power Sources, 2015, 273: 793-803.
- [14] HE H, XIONG R, GUO H. Online estimation of model parameters and state-of-charge of LiFePO₄ batteries in electric vehicles[J]. Applied Energy, 2012, 89(1): 413-420.
- [15] QIUTING W, YINZHU J, YUNHAO L. State of health estimation for lithium-ion battery based on D-UKF[J]. International Journal of Hybrid Information Technology, 2015, 8(7): 55-70.
- [16] CHEN C, XIONG R, SHEN W. A Lithium-ion battery-in-the-loop approach to test and validate multiscale dual H infinity filters for state-of-charge and capacity estimation[J]. IEEE Transactions on Power Electronics, 2018, 33(1): 332-342.
- [17] XIONG R, ZHANG Y, HE H, et al. A double-scale, particle-filtering, energy state prediction algorithm for lithium-ion batteries[J]. IEEE Transactions on Industrial

- Electronics, 2018, 65(2): 1526-1538.
- [18] CHU A, ALLAM A, ARENAS A, et al. Stochastic capacity loss and remaining useful life models for lithium-ion batteries in plug-in hybrid electric vehicles[J]. Journal of Power Sources, 2020, 478: 228991.
- [19] SCHWUNK S, ARMBRUSTER N, STRAUB S, et al. Particle filter for state of charge and state of health estimation for lithium-iron phosphate batteries[J]. Journal of Power Sources, 2013, 239: 705-710.
- [20] HU C, YOUNG B D, CHUNG J. A multiscale framework with extended Kalman filter for lithium-ion battery SOC and capacity estimation[J]. Applied Energy, 2012, 92: 694-704.
- [21] ZHENG Y, OUYANG M, LU L, et al. Understanding aging mechanisms in lithium-ion battery packs: From cell capacity loss to pack capacity evolution[J]. Journal of Power Sources, 2015, 278: 287-295.
- [22] HU, CHE Y, LIN X, X, et al. Battery health prediction using fusion-based feature selection and machine learning[J]. IEEE Transactions on Transportation Electrification, 2021, 7(2): 382-392.
- [23] 顾荣. 大数据处理技术与系统研究[D]. 南京: 南京大学, 2016.
- GU Rong. Research on techniques and systems for big data processing[D]. Nanjing: Nanjing University, 2016.
- [24] ULRICH L. Exclusive: GM Can Manage an EV's Batteries Wirelessly—and Remotely [EB/OL]. <https://spectrum.ieee.org/cars-that-think/energy/batteries-storage/ieee-spectrum-exclusive-gm-can-manage-an-evs-batteries-wirelessly-and-remotely>. 2020.
- [25] 余承其, 张照生, 刘鹏, 等. 大数据分析技术在新能源汽车行业的应用综述——基于新能源汽车运行大数据[J]. 机械工程学报, 2019, 55(20): 3-16.
- SHE Chengqi, ZHANG Zhaosheng, LIU Peng, et al. Overview of the application of big data analysis technology in new energy vehicle industry: Based on operating big data of new energy vehicle[J]. Journal of Mechanical Engineering, 2019, 55(20): 3-16.
- [26] KLASS V, BEHM M, LINDBERGH G, et al. Evaluating real-life performance of lithium-ion battery packs in electric vehicles[J]. Journal of The Electrochemical Society, 2012, 159(11): A1856-A1860.
- [27] YOU G, PARK S, OH D. Real-time state-of-health estimation for electric vehicle batteries: A data-driven approach[J]. Applied Energy, 2016, 176: 92-103.
- [28] FAN J, ZOU Y, ZHANG X. Quantifying electric vehicle battery's ohmic resistance increase caused by degradation from on-board data[C]// IFAC-PapersOnLine, 2019: 297-302.
- [29] 樊杰. 锂离子动力电池实车使用行为分析及老化状态研究[D]. 北京: 北京理工大学, 2019.
- FAN Jie. Usage pattern analysis and state of health research of lithium-ion power battery[D]. Beijing: Beijing Institute of Technology, 2019.
- [30] SAHA B, GOEBEL K. "Battery Data Set", NASA Ames Prognostics Data Repository[EB/OL]. <http://ti.arc.nasa.gov/project/prognostic-data-repository>, NASA Ames Research Center, Moffett Field, CA. 2007.
- [31] SAXENA S, HENDRICKS C, PECHT M. Cycle life testing and modeling of graphite/LiCoO₂ cells under different state of charge ranges[J]. Journal of Power Sources, 2016, 327: 394-400.
- [32] ZHENG F, XING Y, JIANG J, et al. Influence of different open circuit voltage tests on state of charge online estimation for lithium-ion batteries[J]. Applied Energy, 2016, 183: 513-525.
- [33] BIRKL C. "Oxford Battery Degradation Dataset 1, " in Long term battery ageing tests of 8 Kokam (SLPB533459H4) 740 mAh lithium-ion pouch cells[EB/OL]. University of Oxford. <https://ora.ox.ac.uk/objects/uuid:03ba4b01-cfed-46d3-9b1a-7d4a7bdf6fac>. 2017.
- [34] Sandia National Laboratories. Battery cell testing data archive [EB/OL]. <https://www.sandia.gov/energystoragesafety-ssl/research-development/research-data-repository/>. 2017.
- [35] 王震坡, 刘鹏, 张照生. 新能源汽车大数据分析与应用技术[M]. 北京: 机械工业出版社, 2018.
- WANG Zhenpo, LIU Peng, ZHANG Zhaosheng. Analysis and application technology of big data for EVs[M]. Beijing: China Machine Press, 2018.
- [36] 崔丁松. 基于大数据的纯电动汽车生态驾驶行为评估[D]. 北京: 北京理工大学, 2019.
- CUI Dingsong. Research on eco-driving behavior evaluation of battery electric vehicle based on big data[D]. Beijing: Beijing Institute of Technology, 2019.
- [37] 赵洋. 基于大数据的电动汽车动力电池系统故障诊断方法研究[D]. 北京: 北京理工大学, 2018.
- ZHAO Yang. Research on fault diagnosis methods of electric vehicle power battery system based on big data[D]. Beijing: Beijing Institute of Technology, 2018.
- [38] LIANG K, ZHANG Z, LIU P, et al. Data-driven ohmic

- resistance estimation of battery packs for electric vehicles[J]. *Energies*, 2019, 12(24): 4772.
- [39] SUN Z, LIU P, WANG Z. Real-time fault diagnosis method of battery system based on Shannon entropy[J]. *Energy Procedia*, 2017, 105: 2354-2359.
- [40] DUBARRY M, LIAW B Y, CHEN M, et al. Identifying battery aging mechanisms in large format Li ion cells[J]. *Journal of Power Sources*, 2011, 196(7): 3420-3425.
- [41] 马泽宇, 姜久春, 王占国, 等. 基于容量增量分析的石墨负极磷酸铁锂电池 SOC 估算方法研究[J]. *汽车工程*, 2014(12): 1439-1444.
- MA Zeyu, JIANG Jiuchun, WANG Zhanguo, et al. A research on SOC estimation for LiFePO₄ battery with graphite negative electrode based on incremental capacity analysis[J]. *Automotive Engineering*, 2014(12): 1439-1444.
- [42] XIONG R, LI L, TIAN J. Towards a smarter battery management system: A critical review on battery state of health monitoring methods[J]. *Journal of Power Sources*, 2018, 405: 18-29.
- [43] HAN X, OUYANG M, LU L, et al. A comparative study of commercial lithium ion battery cycle life in electric vehicle: Capacity loss estimation[J]. *Journal of Power Sources*, 2014, 268: 658-669.
- [44] HE J, WEI Z, BIAN X, et al. State-of-health estimation of lithium-ion batteries using incremental capacity analysis based on voltage-capacity model[J]. *IEEE Transactions on Transportation Electrification*, 2020, 6(2): 417-426.
- [45] LI Y, ABDEL-MONEM M, GOPALAKRISHNAN R, et al. A quick on-line state of health estimation method for Li-ion battery with incremental capacity curves processed by Gaussian filter[J]. *Journal of Power Sources*, 2018, 373: 40-53.
- [46] WENG C, CUI Y, SUN J, et al. On-board state of health monitoring of lithium-ion batteries using incremental capacity analysis with support vector regression[J]. *Journal of Power Sources*, 2013, 235: 36-44.
- [47] TANG X, ZOU C, YAO K, et al. A fast estimation algorithm for lithium-ion battery state of health[J]. *Journal of Power Sources*, 2018, 396: 453-458.
- [48] GOH T, PARK M, SEO M, et al. Capacity estimation algorithm with a second-order differential voltage curve for Li-ion batteries with NMC cathodes[J]. *Energy*, 2017, 135: 257-268.
- [49] WANG L, PAN C, LIU L, et al. On-board state of health estimation of LiFePO₄ battery pack through differential voltage analysis[J]. *Applied Energy*, 2016, 168: 465-472.
- [50] BLOOM I, JANSEN A N, ABRAHAM D P, et al. Differential voltage analyses of high-power, lithium-ion cells: 1. Technique and application[J]. *Journal of Power Sources*, 2005, 139(1-2): 295-303.
- [51] SCHIFFER Z J, CANNARELLA J, ARNOLD C B. Strain derivatives for practical charge rate characterization of lithium ion electrodes[J]. *Journal of The Electrochemical Society*, 2015, 163(3): A427-A433.
- [52] LI X, WANG Z, ZHANG L, et al. State-of-health estimation for Li-ion batteries by combing the incremental capacity analysis method with grey relational analysis[J]. *Journal of Power Sources*, 2019(410-411): 106-114.
- [53] WU B, YUFIT V, MERLA Y, et al. Differential thermal voltammetry for tracking of degradation in lithium-ion batteries[J]. *Journal of Power Sources*, 2015, 273: 495-501.
- [54] MERLA Y, WU B, YUFIT V, et al. Novel application of differential thermal voltammetry as an in-depth state-of-health diagnosis method for lithium-ion batteries[J]. *Journal of Power Sources*, 2016, 307: 308-319.
- [55] MERLA Y, WU B, YUFIT V, et al. Extending battery life: A low-cost practical diagnostic technique for lithium-ion batteries[J]. *Journal of Power Sources*, 2016, 331: 224-231.
- [56] CANNARELLA J, ARNOLD C B. State of health and charge measurements in lithium-ion batteries using mechanical stress[J]. *Journal of Power Sources*, 2014, 269: 7-14.
- [57] PEABODY C, ARNOLD C B. The role of mechanically induced separator creep in lithium-ion battery capacity fade[J]. *Journal of Power Sources*, 2011, 196(19): 8147-8153.
- [58] KHALEGHI S, KARIMI D, BEHESHTI S H, et al. Online health diagnosis of lithium-ion batteries based on nonlinear autoregressive neural network[J]. *Applied Energy*, 2021, 282: 116159.
- [59] LI Y, ZOU C, BERECIBAR M, et al. Random forest regression for online capacity estimation of lithium-ion batteries[J]. *Applied Energy*, 2018, 232: 197-210.
- [60] RICHARDSON R R, BIRKL C R, OSBORNE M A, et al. Gaussian process regression for in situ capacity estimation of lithium-ion batteries[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(1): 127-138.

- [61] GUO P, CHENG Z, YANG L. A data-driven remaining capacity estimation approach for lithium-ion batteries based on charging health feature extraction[J]. *Journal of Power Sources*, 2019, 412: 442-450.
- [62] CHEN Z, SUN M, SHU X, et al. Online state of health estimation for lithium-ion batteries based on support vector machine[J]. *Applied Sciences*, 2018, 8(6): 925.
- [63] 郭永芳, 黄凯, 李志刚. 基于短时搁置端电压压降的快速锂离子电池健康状态预测[J]. *电工技术学报*, 2019, 34(19): 3968-3978.
- GUO Yongfang, HUANG Kai, LI Zhigang. Fast state of health prediction of lithium-ion battery based on terminal voltage drop during rest for short time[J]. *Transactions of China Electrotechnical Society*, 2019, 34(19): 3968-3978.
- [64] BAGHDADI I, BRIAT O, GYAN P, et al. State of health assessment for lithium batteries based on voltage-time relaxation measure[J]. *Electrochimica Acta*, 2016, 194: 461-472.
- [65] FENG X, LI J, OUYANG M, et al. Using probability density function to evaluate the state of health of lithium-ion batteries[J]. *Journal of Power Sources*, 2013, 232: 209-218.
- [66] HU X, LI S E, JIA Z, et al. Enhanced sample entropy-based health management of Li-ion battery for electrified vehicles[J]. *Energy*, 2014, 64: 953-960.
- [67] LADPLI P, KOPSAFTOPOULOS F, CHANG F. Estimating state of charge and health of lithium-ion batteries with guided waves using built-in piezoelectric sensors/actuators[J]. *Journal of Power Sources*, 2018, 384: 342-354.
- [68] RICHARDSON R R, OSBORNE M A, HOWEY D A. Battery health prediction under generalized conditions using a Gaussian process transition model[J]. *Journal of Energy Storage*, 2019, 23: 320-328.
- [69] 洪吉超. 基于运行大数据的电动汽车动力电池安全控制管理研究[D]. 北京: 北京理工大学, 2020.
- HONG Jichao. Big-data-driven safety control strategies for battery systems of real-world electric vehicles[D]. Beijing: Beijing Institute of Technology, 2020.
- [70] 梁凯智. 基于数据驱动的动力电池剩余寿命预测方法研究[D]. 北京: 北京理工大学, 2020.
- LIANG Kaizhi. Research on prediction method of remaining useful life for power battery based on data driven[D]. Beijing: Beijing Institute of Technology, 2020.
- [71] FRISK E, KRYSSANDER M, LARSSON E. Data-driven lead-acid battery prognostics using random survival forests[C]//*Proceedings of the Annual Conference of The Prognostics and Health Management Society*, September 29-October 2, 2014, Fort Worth, Texas, USA. Scottsdale, Arizona: PMH Society, 2014: 92-101.
- [72] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- ZHOU Zhihua. Machine learning[M]. Beijing: Tsinghua University Press, 2016.
- [73] WANG Q, WANG Z, ZHANG L, et al. A novel consistency evaluation method for series-connected battery systems based on real-world operation data[J]. *IEEE Transactions on Transportation Electrification*, 2020, 7(2): 437-451.
- [74] ZHAO Y, LIU P, WANG Z, et al. Fault and defect diagnosis of battery for electric vehicles based on big data analysis methods[J]. *Applied Energy*, 2017, 207: 354-362.
- [75] VATANPARVAR K, FAEZI S, BURAGO I, et al. Extended range electric vehicle with driving behavior estimation in energy management[J]. *IEEE Transactions on Smart Grid*, 2018, 10(3): 2959-2968.
- [76] FIORI C, AHN K, RAKHA H A. Power-based electric vehicle energy consumption model: Model development and validation[J]. *Applied Energy*, 2016, 168: 257-268.
- [77] HAIDAR A M, MUTTAQI K M. Behavioral characterization of electric vehicle charging loads in a distribution power grid through modeling of battery chargers[J]. *IEEE Transactions on Industry Applications*, 2015, 52(1): 483-492.
- [78] CAI H, JIA X, CHIU A S F, et al. Siting public electric vehicle charging stations in Beijing using big-data informed travel patterns of the taxi fleet[J]. *Transportation Research Part D: Transport and Environment*, 2014, 33: 39-46.
- [79] MENG H, LI Y. A review on prognostics and health management (PHM) methods of lithium-ion batteries[J]. *Renewable and Sustainable Energy Reviews*, 2019, 116: 109405.
- [80] 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.
- [81] NUHIC A, TERZIMEHIC T, SOCZKA-GUTH T, et al. Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods[J]. *Journal of Power Sources*, 2013, 239: 680-688.
- [82] ZHAO Q, QIN X, ZHAO H, et al. A novel prediction method based on the support vector regression for the

- remaining useful life of lithium-ion batteries[J]. *Microelectronics Reliability*, 2018, 85: 99-108.
- [83] YANG D, WANG Y, PAN R, et al. State-of-health estimation for the lithium-ion battery based on support vector regression[J]. *Applied Energy*, 2018, 227: 273-283.
- [84] CHEN Y, XIONG J, XU W, et al. A novel online incremental and decremental learning algorithm based on variable support vector machine[J]. *Cluster Computing*, 2019, 22(3): 7435-7445.
- [85] WU J, ZHANG C, CHEN Z. An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks[J]. *Applied Energy*, 2016, 173: 134-140.
- [86] LI G, SHI J. On comparing three artificial neural networks for wind speed forecasting[J]. *Applied Energy*, 2010, 87(7): 2313-2320.
- [87] LIU K, SHANG Y, OUYANG Q, et al. A data-driven approach with uncertainty quantification for predicting future capacities and remaining useful life of lithium-ion battery[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(4): 3170-3180.
- [88] LI W, SENGUPTA N, DECHENT P, et al. Online capacity estimation of lithium-ion batteries with deep long short-term memory networks[J]. *Journal of Power Sources*, 2020, 482: 228863.
- [89] 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.
- [90] LI X, ZHANG L, WANG Z, et al. Remaining useful life prediction for lithium-ion batteries based on a hybrid model combining the long short-term memory and Elman neural networks[J]. *Journal of Energy Storage*, 2019, 21: 510-518.
- [91] ZHANG Y. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries[J]. *IEEE Transactions on Vehicular Technology*, 2018(67): 5695-5705.
- [92] LIU J, SAXENA A, GOEBEL K, et al. An adaptive recurrent neural network for remaining useful life prediction of lithium-ion batteries[R]. *National Aeronautics and Space Administration Moffett Field Ca Ames Research*, 2010.
- [93] LIU D, ZHOU J, LIAO H, et al. A health indicator extraction and optimization framework for lithium-ion battery degradation modeling and prognostics[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2015, 45(6): 915-928.
- [94] LI H, PAN D, CHEN C L P. Intelligent prognostics for battery health monitoring using the mean entropy and relevance vector machine[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2014, 44(7): 851-862.
- [95] LI X, YUAN C, LI X, et al. State of health estimation for Li-Ion battery using incremental capacity analysis and Gaussian process regression[J]. *Energy*, 2020, 190: 116467.
- [96] RICHARDSON R R, OSBORNE M A, HOWEY D A. Gaussian process regression for forecasting battery state of health[J]. *Journal of Power Sources*, 2017, 357: 209-219.
- [97] LIU D, PANG J, ZHOU J, et al. Prognostics for state of health estimation of lithium-ion batteries based on combination Gaussian process functional regression[J]. *Microelectronics Reliability*, 2013, 53(6): 832-839.
- [98] XIONG R, CAO J, YU Q. Reinforcement learning-based real-time power management for hybrid energy storage system in the plug-in hybrid electric vehicle[J]. *Applied Energy*, 2018, 211: 538-548.
- [99] ZENATI A, DESPREZ P, RAZIK H. Estimation of the SOC and the SOH of li-ion batteries, by combining impedance measurements with the fuzzy logic inference[C/CD]// *Conference of the IEEE Industrial Electronics Society. IEEE*, 2010.
- [100] ZHANG Y, XIONG R, HE H, et al. Lithium-ion battery remaining useful life prediction with Box-Cox transformation and Monte Carlo simulation[J]. *IEEE Transactions on Industrial Electronics*, 2018, 66(2): 1585-1597.
- [101] 张彩萍, 姜久春. 用基于遗传优化的扩展卡尔曼滤波算法辨识电池模型参数[J]. *吉林大学学报*, 2012, 42(3): 732-737.
- ZHANG Caiping, JIANG Jiuchun. Extended Kalman filter algorithm for parameters identification of dynamic battery model based on genetic algorithm optimization[J]. *Journal of Jilin University*, 2012, 42(3): 732-737.
- [102] 孙培坤. 电动汽车动力电池健康状态估计方法研究[D]. 北京: 北京理工大学, 2016.
- SUN Peikun. Research of state of health estimation method for electric vehicle lithium-ion power battery[D]. Beijing: Beijing Institute of Technology, 2016.
- [103] WANG Z, MA J, ZHANG L. State-of-health estimation

- for lithium-ion batteries based on the multi-island genetic algorithm and the gaussian process regression[J]. IEEE Access, 2017(5): 21286-21295.
- [104] 宋昕, 谷正气, 张清林, 等. 基于多岛遗传算法的湍流模型优化研究[J]. 湖南大学学报, 2011, 38(2): 23-29. SONG Xin, GU Zhengqi, ZHANG Qinglin, et al. Study on the turbulence model optimization based on multi-island generic algorithm[J]. Journal of Hunan University, 2011, 38(2): 23-29.
- [105] 王震坡, 孙培坤. 基于粒子群-高斯过程回归的锂离子电池充电特性与 SOH 关系探究[C]// 中国电动车辆学术年会论文集, 武汉: 中国汽车工程协会电动汽车分会, 2015: 170-174. WANG Zhenpo, SUN Peikun. Research on the relation between charging characteristics and SOH of lithium ion batteries based on particle swarm-gaussian process regression[C]// Proceedings of China Electric Vehicle Academic Conference, Wuhan: Electric Vehicle Branch of China Automotive Engineering Association, 2015, 170-174.
- [106] QIN T, ZENG S, GUO J. Robust prognostics for state of health estimation of lithium-ion batteries based on an improved PSO-SVR model[J]. Microelectronics Reliability, 2015, 55(9-10): 1280-1284.
- [107] GAO D, HUANG M. Prediction of remaining useful life of lithium-ion battery based on multi-kernel support vector machine with particle swarm optimization[J]. Journal of Power Electronics, 2017, 17(5): 1288-1297.
- [108] YANG R, XIONG R, HE H, et al. A novel method on estimating the degradation and state of charge of lithium-ion batteries used for electrical vehicles[J]. Applied Energy, 2017, 207: 336-345.
- [109] CHEN Z, MI C C, FU Y, et al. Online battery state of health estimation based on genetic algorithm for electric and hybrid vehicle applications[J]. Journal of Power Sources, 2013, 240: 184-192.
- [110] 边明远, 李克强. 以智能网联汽车为载体的汽车强国战略顶层设计[J]. 中国工程科学, 2018, 20(1): 52-58. BIAN Mingyuan, LI Keqiang. Strategic analysis on establishing an automobile power in china based on intelligent & connected vehicles[J]. Strategic Study of CAE, 2018, 20(1): 52-58.
-
- 作者简介: 王震坡, 男, 1976 年出生, 博士, 教授, 博士研究生导师。主要研究方向为动力电池成组理论与新能源汽车大数据分析。
E-mail: wangzhenpo@bit.edu.cn
- 王秋诗, 男, 1994 年出生, 博士研究生。主要研究方向为新能源汽车动力电池健康管理及新能源汽车大数据分析。
E-mail: wangqs_bit@163.com
- 刘鹏(通信作者), 男, 1983 年出生, 博士, 副教授, 硕士研究生导师。主要研究方向为新能源汽车大数据分析。
E-mail: bitliupeng@bit.edu.cn
- 张照生, 男, 1984 年出生, 博士, 副教授, 硕士研究生导师。主要研究方向为新能源汽车大数据分析。
E-mail: zhangzhaosheng@bit.edu.cn