



移动扫码阅读

邵哲, 仲恒, 梅延润, 等. 锂离子电池健康状态估计的特征提取: 方法与应用 [J]. 能源环境保护, 2026, 40(1): 54-67.

SHAO Zhe, ZHONG Heng, MEI Yanrun, et al. Feature Extraction for Lithium-Ion Battery State of Health Estimation: Methods and Applications[J]. Energy Environmental Protection, 2026, 40(1): 54-67.

锂离子电池健康状态估计的特征提取: 方法与应用

邵哲^{1,2,3}, 仲恒^{1,2,3}, 梅延润^{1,2,3}, 秦文杰^{1,2,3}, 陈然^{1,2,3},
侯慧杰^{1,2,3}, 胡敬平^{1,2,3,*}, 杨家宽^{1,2,3}

(1. 华中科技大学环境科学与工程学院, 湖北武汉 430074; 2. 长江流域多介质污染协同控制湖北省重点实验室, 湖北武汉 430074; 3. 固废处理处置与资源化技术湖北省工程实验室, 湖北武汉 430074)

摘要: 为了确保锂离子电池系统的安全性、可靠性和持久性, 准确估计电池的健康状态(State of Health, SOH)至关重要。SOH 作为一个内部状态量, 难以通过传感器直接测量, 往往需要通过间接方式进行估计。SOH 估计的准确性在很大程度上依赖于健康特征的提取质量, 当前 SOH 估计研究面临电池内部复杂的电化学反应机制难以直接观测, 且单一特征往往无法全面捕捉电池老化过程的挑战。首先阐明了 SOH 与电池容量衰减、内阻增长的宏观联系, 并追溯其活性物质损失(LAM)和活性锂损失(LLI)等微观电化学反应机制, 确立了理想健康特征应具备明确物理意义的评价基准。在此基础上, 总结了当前主流的特征提取技术, 主要包括基于电压电流曲线、微分曲线、脉冲功率特性、电化学阻抗和多物理场的特征提取, 并对这 5 种特征提取技术进行了归纳与评述。此外, 系统梳理了 NASA、CALCE、Oxford 等多个国际公认的锂电池公开数据集, 为相关算法的开发与验证提供了基准。最后, 针对单一特征难以在复杂多变的工况下实现鲁棒性、高精度 SOH 估计的现状, 提出未来发展趋势的三个关键方向: (1) 建立标准化的评估协议, 实现客观的算法比较; (2) 融合多物理场特征(电、热、机械等), 创建更全面、更稳健的健康指标; (3) 将物理模型与数据驱动方法相结合(如物理信息神经网络), 提高模型可解释性、数据效率和泛化能力。

关键词: 锂离子电池; 梯次利用; 健康状态; 健康特征; 特征提取

中图分类号: X703

文献标识码: A

文章编号: 2097-4183(2026)01-0054-14

Feature Extraction for Lithium-Ion Battery State of Health Estimation: Methods and Applications

SHAO Zhe^{1,2,3}, ZHONG Heng^{1,2,3}, MEI Yanrun^{1,2,3}, QIN Wenjie^{1,2,3}, CHEN Ran^{1,2,3},
HOU Huijie^{1,2,3}, HU Jingping^{1,2,3,*}, YANG Jiakuan^{1,2,3}

(1. School of Environmental Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 2. Hubei Key Laboratory of Multi-media Pollution Cooperative Control in Yangtze Basin, Wuhan 430074, China; 3. Hubei Provincial Engineering Laboratory for Disposal and Recycling Technology of Solid Waste, Wuhan 430074, China)

收稿日期: 2025-08-31

修回日期: 2025-10-14

接受日期: 2025-10-20

DOI: 10.20078/j.eep.20251101

基金项目: 国家重点研发计划资助项目(2023YFC3902802); 国家自然科学基金面上资助项目(52170134); 华中科技大学交叉研究支持计划(2023JCYJ005); 湖北省科技计划项目(2024BAA012); 武汉市动力电池低碳循环产业创新联合实验室(2025020802040290)

第一作者: 邵哲(2000—), 女, 安徽太和人, 博士研究生, 主要研究方向为锂电池健康状态估计。E-mail: shaozhe@hust.edu.cn

*通讯作者: 胡敬平(1980—), 男, 河南长垣人, 教授, 主要研究方向为环境电化学与功能材料。E-mail: hujp@hust.edu.cn

Abstract: To ensure the safety, reliability and longevity of battery systems, accurate estimation of the State of Health (SOH) of lithium-ion batteries is essential. As an internal state variable, SOH is difficult to measure directly with sensors and is therefore often estimated through indirect methods. The accuracy of SOH estimation largely depends on the quality of the extracted health features that are correlated with battery aging. This review systematically analyzes and evaluates mainstream feature extraction methodologies for lithium-ion battery SOH estimation. It clarifies the link between macroscopic aging phenomena (capacity fade and impedance rise) and microscopic electrochemical degradation mechanisms, such as loss of active material (LAM) and loss of lithium inventory (LLI). A comprehensive survey is conducted on five primary feature categories: (1) Voltage-current curve features, derived from standard charging protocols (e.g., Constant Current-Constant Voltage, CC-CV), including temporal indicators and capacity metrics within specific voltage windows. (2) Differential curve features, such as Incremental Capacity Analysis (ICA) and Differential Voltage Analysis (DVA), identifying electrochemical phase transitions whose peak attributes (height, position, area) serve as health indicators. (3) Pulse power characterization features, obtained from Hybrid Pulse Power Characterization (HPPC) tests, reflecting DC internal resistance (DCR) and variations in the open-circuit voltage (OCV) versus state of charge (SOC) curve. (4) Electrochemical impedance spectroscopy (EIS) features, extracted from raw impedance data, including parameters fitted using equivalent circuit models (ECM) and deconvolution results from distribution of relaxation times (DRT) analysis. (5) Multi-physics field features, which utilize non-electrical signals from thermal, ultrasonic, and mechanical sensors, providing additional diagnostic dimensions. Publicly available datasets (e.g., NASA, CALCE, Oxford) are also reviewed as benchmarks. The analysis finds that voltage-current curve features are computationally efficient but typically require full charging cycles. While ICA/DVA offer deep mechanistic insight by linking peak changes to LAM and LLI, their susceptibility to noise and current rate complicates online implementation. HPPC-derived features effectively track impedance growth but require accurate OCV correction. EIS provides the most comprehensive diagnostic information, with ECM offering physically meaningful parameters and DRT excelling at decoupling overlapping processes, though measurements are time-intensive. Multi-physics features capture structural and thermal degradation, offering complementary perspectives. A key finding is that no single feature can reliably provide robust and high-precision SOH estimation under complex and variable real-world conditions. Given the limitations of single features, future research is expected to focus on: (1) establishing standardized public benchmarks and evaluation protocols to enable objective comparison and accelerate technological progress; (2) fusing multi-physics features (electrical, thermal, mechanical) to develop more comprehensive and robust health indicators; and (3) integrating physical models with data-driven methods, such as physics-informed neural networks (PINNs), to enhance model interpretability, data efficiency, and generalization.

Keywords: Lithium-ion battery; Cascade utilization; State of health; Health features; Feature extraction

0 引 言

锂离子电池(Lithium-Ion Battery, LIB)因其能量密度高、循环寿命长和自放电率低等优点,已成为电动汽车(Electric Vehicle, EV)、电网储能系统

(Energy Storage System, ESS)及便携式电子设备的首选储能方案^[1]。然而,随着使用时长增加和充放电循环,锂离子电池会经历复杂的电化学老化过程,导致其性能衰减^[2]。为了确保电池系统的安全性、可靠性和持久性,准确估计电池的健康状态

(SOH)至关重要,这不仅能优化充放电策略、预防热失控等灾难性故障,还是实现退役动力电池梯次利用和构建循环经济的关键推动力。通过估计退役动力电池的 SOH,可以评估其是否适用于储能等二次生命周期应用,从而最大限度地利用资源并减少浪费^[3]。

SOH 作为一个内部状态量,难以通过传感器直接测量。准确估计 SOH 的关键不只在使用的模型方法,更深层次地依赖于从电池的各种运行数据中提取出与电池老化程度强相关的健康特征(Health Features, HFs)^[4]。这些特征是连接可观测数据与不可观测的内部衰减状态之间的桥梁。任何 SOH 估计模型的性能,尤其是依赖历史数据的数据驱动模型,其准确性和鲁棒性在很大程度上取决于所提取健康特征的质量。当前 SOH 估计面临的主要挑战在于难以直接观测电池内部复杂的电化学衰退机制,且单一特征往往无法全面捕捉电池老化过程。本文系统综述了多种特征参数,如充放电曲线、微分曲线、电化学阻抗等在 SOH 估计中的应用方法与效果,并特别关注不同特征参数的局限性,讨论如何提高估计精度和鲁棒性。同时,介绍了一些可用的公开锂电池数据集。最后,指出了当前研究中存在的挑战,并对未来发展趋势提出了展望,为锂电池健康状态估计及进一步梯次利用的研究提供参考。

1 锂电池健康状态与衰减机制

锂电池性能的衰减主要体现在 2 个方面:容量衰退和阻抗增长。容量衰退意味着电池存储电量的能力下降,影响电池的使用时长;阻抗增长会导致电池在充放电时产生更大的电压降(或电压升),更多的电量以热量的形式耗散。因此,健康状态 SOH 的定义通常为在一定条件下电池从满电状态以一定倍率放电到截止电压所放出的容量与电池额定容量的百分比,是反映电池老化程度的重要指标。SOH 的计算公式见式(1)^[5]:

$$SOH = \frac{C_0}{C_N} \quad (1)$$

式中: C_0 为电池当前容量(A·h), C_N 为电池额定容量(A·h)。另一种计算方式使用内阻的定义,见式(2)^[6]:

$$SOH = \frac{R_{EoL} - R_{present}}{R_{EoL} - R_{new}} \quad (2)$$

式中: R_{EoL} 为电池达到寿命终点时的内阻(Ω),

$R_{present}$ 为电池当前内阻(Ω), R_{new} 为新电池的内阻(Ω)。

在宏观的衰减现象背后是一系列复杂的、相互关联的物理和化学变化,即微观层面的衰减机制。电池内部的退化机制极为复杂,可以概括为正负极中的活性物质损失(Loss of Active Material, LAM)以及活性锂损失(Loss of Lithium Inventory, LLI)等,如图 1 所示。LLI 是指电池中可用于充放电循环的锂离子数量的不可逆减少,是容量衰减最主要的因素之一。锂离子是电池的“电荷载体”,其损失直接导致电池能够储存和释放的电荷总量下降。除了被固体电解质膜(Solid Electrolyte Interphase, SEI)生长所消耗外,造成 LLI 的另一个重要原因是析锂以及与电解液发生其他副反应^[7]。LAM 是指电极材料本身发生物理或化学变化,使其失去储存和释放锂离子的能力。导致 LAM 的主要原因包括活性材料颗粒开裂、正极材料结构在循环过程中发生相变、机械应力或黏结剂失效导致的活性材料涂层从集流体上剥离等^[8-9]。这些微观层面的变化共同导致了宏观上可观测到的容量衰减和阻抗增长。因此,理想的健康特征应与这些特定的物理化学退化过程建立明确的关联,从而为 SOH 估计提供具有物理意义的输入^[10]。

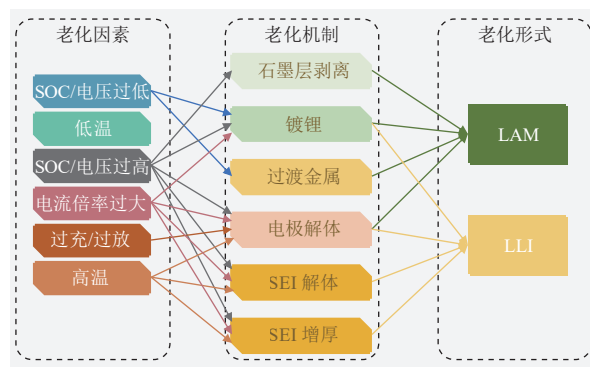


图 1 锂离子电池衰减机制示意图^[11]

Fig. 1 Schematic diagram of the aging mechanism of lithium-ion batteries^[11]

2 特征提取方法

SOH 作为一个反映电池内部电化学系统综合状态的宏观指标,难以通过传感器直接测量。它必须通过分析电池在运行过程中外部可测的物理量,如电压、电流、温度和时间等数据,进行间接推断和估计^[12]。根据特征的物理量和提取方式,将特征提取方法分为以下几类。

2.1 基于电压电流曲线的特征

电压是一种电池内部反应机制的外部表现形式, 电池的电压电流曲线物理含义丰富, 从电池的充放电曲线中直接提取特征, 是最直接、计算成本最低的特征提取方法之一。恒流恒压充电 (Constant Current-Constant Voltage, CC-CV) 模式是锂电池最常用的充电模式, 这一标准化过程为提取健康特征提供了理想的通用窗口^[13]。这些特征主要基于时间、容量、电压曲线几何形状以及相关的统计量。

2.1.1 时间相关特征

CC-CV 充电过程包含丰富的电池老化信息。在 CC 阶段, 电池先以恒定电流充电, 其端电压逐渐升高至截止电压; 随后进入 CV 阶段, 此过程端电压恒定, 充电电流会逐渐减小直至截止电流。随着电池的老化, 其内阻增加, 导致电池在不同充电阶段达到截止电压和截止电流的时间发生变化。恒流充电时间 (Constant Current Charging Time, CCCT) 指 CC 阶段的持续时间, 随着电池老化, 其内阻增大, 导致端电压更快达到充电截止电压, 从而使得 CCCT 显著缩短; 等电压增量时间 (Time Interval for Equal Voltage Increase, TEVI) 则是指在 CC 充电阶段, 电池电压从一个固定的低电压值上升到另一个固定的高电压值所需要的时间, 达到相同电压增量所需的时间会随着容量衰减和阻抗的增长而减少; 与 TEVI 相对应的是等电流衰减时间 (Time Interval for Equal Current Decrease, TECD), 即在 CV 充电阶段充电电流从一个固定的高电流值衰减到另一个固定的低电流值所需要的时间。电池老化会导致 CV 阶段的持续时间变长, 因此 TECD 会随着 SOH 的降低而增加^[14]。LIN 等^[15]的研究证明了 CCCT 与电池容量衰减之间存在强相关性, 且避免了微分运算带来的噪声敏感性问题, 是一个简单而有效的健康特征, 如图 2 所示。CAI 等^[16]则分别提取了 CCCT 和 CV 模式下电流从 1.5 A 下降至 0.8 A 的 TECD 作为特征, 通过皮尔逊相关系数 (Pearson Correlation Coefficient, PCC) 和灰色关联分析 (Grey Relational Analysis, GRA) 进行相关性分析, 证明了这 2 个特征与 SOH 具有相对较高的相关性。

2.1.2 容量相关特征

通过对充电电流进行时间积分, 可以得到与容量相关的特征。这些特征通常与 SOH 有更直接的物理联系。




图 2 不同衰减阶段的充电电压曲线及 CCCT 特征^[15]

Fig. 2 Charging voltage curves and CCCT features at different aging stages^[15]

固定电压区间的充电容量指在 CC 充电阶段, 当电池电压从起始电压上升到截止电压时充入的电荷量。随着电池老化, 在相同的电压窗口内能够充入的容量减少, 这直接反映了电池的容量衰减。在此基础上, 可以将 CC 充电电压范围划分为多个小的、固定的电压步长, 然后计算在每个步长内充入的容量增量, 形成一个容量增量序列 $\Delta V\text{-}\Delta Q$ 。DENG 等^[17]指出随着电池老化, $\Delta V\text{-}\Delta Q$ 的统计特性如平均值和标准差, 会发生系统性变化。即使只使用其中部分随机的充电数据, 通过分析其 ΔQ 序列的统计特征, 也能够实现对 SOH 的准确估计, 这为 SOH 在线应用提供了极大的便利^[18]。

2.1.3 几何与统计特征

除了时间和容量, 电压、电流曲线本身的几何形状和统计分布也蕴含着电池老化信息。

几何特征包括电压曲线上特定段的斜率、曲率、拐点位置, 以及曲线下方的面积等。例如, CC 阶段电压曲线的斜率会随着内阻的增加而变化。WU 等^[19]的研究提取了充电和放电过程中电压曲线随时间变化的面积作为健康特征, 并使用不同的数据驱动方法在不同的数据集上验证了该健康特征, 证实了其在表征 SOH 变化方面的有效性。对于一段充放电过程中的电压、电流或温度时间曲线, 可以计算其统计特征, 如标准差、偏度、峰度等表征其 SOH。WANG 等^[20]分别从 CC 和 CV 阶段的电压电流曲线中, 提取了平均值、标准差、峰度、偏度、曲线熵等共 16 个统计量作为物理信息神经网络的输入参数, 拟合电池的退化动力学函数并预测 SOH。此外, 一些信号处理领域的指标, 如波峰因数 (Crest Factor)、波形因数 (Shape

Factor)和脉冲因数(Impulse Factor),也被用于量化曲线形状的变化,并与SOH建立关联^[21]。

基于充放电曲线特征的研究主要局限性在于许多特征(如完整的CCCT)依赖于完整的充电周期,但这在实际的使用场景中难以实现。因此,更多的研究转向从不完整、随机的部分充放电数据中提取可靠的健康特征。例如,XIAN等^[22]研究发现,尽管CC阶段包含了丰富的信息,但其起始状态(即充电开始时的荷电状态(SOC))在实际应用中是高度随机的,这给基于CC阶段的特征提取带来了不确定性。相比之下,多数用户习惯将电池充至100% SOC, CV阶段数据因而被完整记录,这使基于CV阶段电流衰减曲线的特征(如TECD、电流衰减率等)在实际应用中具有天然优势。

2.2 基于微分曲线的特征

标准的恒流充放电曲线通常包含一些平坦区域,称为电压平台。这些平台对应于电极材料在脱锂/嵌锂过程中的相变过程。然而,随着电池老化,这些平台的变化可能非常微弱。通过对充放电数据进行微分变换,将隐藏在平滑曲线下的电化学信息以更清晰、更具物理意义的形式展现。增量容量分析(Incremental Capacity Analysis, ICA)和差分电压分析(Differential Voltage Analysis, DVA)是2种最常用的微分技术,得到的IC/DV曲线上的特征峰能够直接与电极材料的相变过程和电池内部的特定老化机制相关联,从而为SOH估计提供了清晰的机理洞察^[23]。

2.2.1 增量容量曲线

在充放电电压曲线上,通常会出现一些电压平坦的区域,这些区域对应于电极活性材料在嵌锂/脱锂过程中的两相共存区,即发生了电化学相变。ICA通过计算充放电曲线中电量对电压的导数,以电压 V 为X轴,增量容量 dQ/dV 为Y轴得到IC曲线^[24]。在IC曲线上,这些平坦的电压平台会被转化为清晰可辨的峰,曲线上的每个峰都对应一个特定的电化学反应过程^[25]。IC曲线的计算公式见式(3):

$$\Delta c = \frac{dQ}{dV} = \frac{I \cdot dt}{dV} \quad (3)$$

式中: Δc 为增量容量(A·h/V), Q 为充/放电容量(A·h), V 为电池端电压(V), I 为电流(A), t 为时间(h)。

随着电池的老化,IC曲线的形态会发生系统性的变化,这为健康状态的量化提供了丰富的特

征。从IC曲线中提取的健康特征主要围绕其特征峰的属性展开,包括峰高(Peak Height,即 dQ/dV 的最大值)、峰位(Peak Position,峰值所对应的电压值)以及峰面积(Peak Area,代表了与该相变过程相关的容量)。例如,当电极中的活性物质因颗粒破碎或发生不可逆相变而损失时,能够参与特定电化学反应的物质总量减少,导致IC曲线上对应峰的高度和面积减小^[26]。然而LLI不会减少活性物质的总量,但会改变正负极之间的荷电状态平衡,导致电极的可用容量窗口发生“滑动”或“偏移”。在IC曲线上,这种偏移表现为特征峰位置的移动^[27],如图3(b)所示^[28]。

2.2.2 差分电压曲线

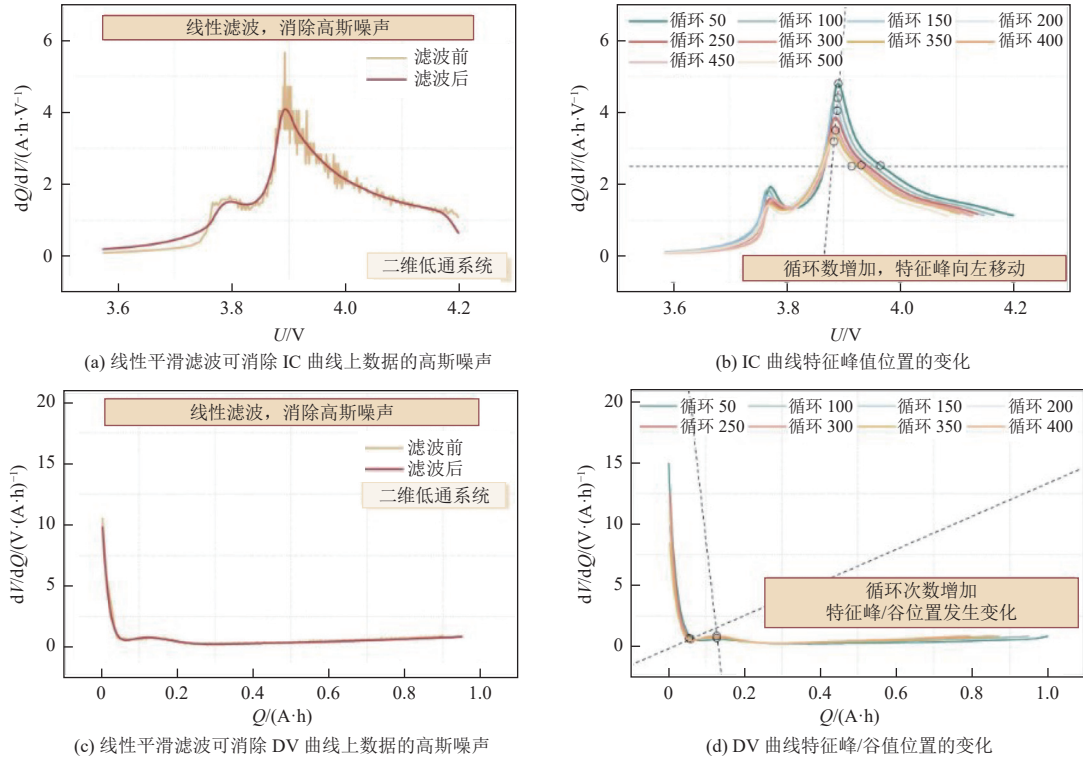
DVA是与ICA互补的另一种重要技术,其定义为电压对容量的导数,并绘制 $dV/dQ-Q$ 曲线,即DV曲线。DV曲线上的峰值(或谷值)与IC曲线的峰值在物理意义上有所不同,DV曲线中的峰表征的是从一个平衡态向另一个平衡态过渡的转折点^[29]。IC曲线中的峰与DV曲线中的谷相对应,其具体计算公式见式(4):

$$\Delta u = \frac{dV}{dQ} = \frac{dV}{I \cdot dt} \quad (4)$$

式中: Δu 为差分电压(V/(A·h))。

DV曲线上的峰和谷同样可以被提取用作健康指标,如图3(c)所示。BERECIBAR等^[30]构建DV曲线中峰的位置与SOH之间的关系用于估计SOH。WANG等^[31-32]指出DV曲线中的第二个拐点会随着电池的衰减向左移动,2个拐点之间的位置间隔也可用于估计SOH。同时,对于容量未达到第二个拐点的电池单体,构建一个函数表征当前的DV曲线和原始DV曲线之间的差异,该函数也与电池容量之间存在高度相关性,并且在离线校准后也可用于SOH估计。

尽管ICA/DVA在理论上极为强大,但在实际应用中,尤其是在线SOH估计中,仍面临着巨大的挑战。首先,微分处理会放大测量数据中的噪声,导致计算出的IC/DV曲线存在校对毛刺,难以准确识别特征峰。因此,通常需要缓慢、恒定的电流以及完整的充放电数据才能获得高质量的曲线,或对原始数据进行复杂的滤波处理,如使用Savitzky-Golay滤波器,但这又可能导致失真,影响特征的准确性^[33]。此外,IC/DV曲线的形态对充放电倍率高度敏感,随着倍率的增加,电化学极化效应增强,会导致特征峰向一定方向偏移,且峰


图 3 不同充电周期下的 IC/DV 曲线构建^[28]Fig. 3 IC/DV curve construction for various charging cycles^[28]

形会发生形变甚至重叠, 掩盖有用的衰减信息^[27]。目前, 新兴的虚拟增量容量 (Virtual Incremental Capacity, VIC) 和虚拟微分电压 (Virtual Differential Voltage, VDV) 利用机器学习^[34], 从任意、非恒流充电模式下收集的部分数据中, 重建该电池在理想的、低倍率恒流条件下的 IC/DV 曲线, 即使在真实的、非理想的应用场景中, 也能够利用 ICA/DVA 强大的诊断能力, 推动了微分技术在 SOH 估计中应用的发展。

2.3 基于混合脉冲功率特性的特征

电池性能衰减还会引起功率性能的下降, 这通常与电池内部阻抗的增长直接相关。混合脉

冲功率特性 (Hybrid Pulse Power Characterization, HPPC) 测试由美国先进电池联合会 (USABC) 和 FreedomCAR 等组织制定, 用于评估电池功率性能和内阻等, 表征电池在不同 SOC 下的功率能力^[35]。一个 HPPC 测试单元包括 (1) 放电脉冲: 在电池处于稳定状态时, 施加一个持续时间较短的大电流放电脉冲; (2) 静置: 脉冲结束后, 让电池静置一段时间使其电压部分恢复; (3) 充电脉冲: 施加一个持续时间较短的充电脉冲。得到测试的电压与电流响应曲线如图 4 所示^[36]。该测试单元会在电池的整个工作 SOC 范围内, 以固定的 SOC 间隔 (如每 10% SOC) 重复进行, 从而绘制出电池在不同 SOC

图 4 HPPC 测试的电压与电流响应曲线^[36]Fig. 4 Voltage and current response curves of the HPPC test^[36]

下的功率和电阻特性曲线。该方法可以通过建立放电、静置和充电期间的响应电压与电流的关系,获得不同 SOC 下充放电内阻^[37]。

2.3.1 直流内阻特征

直流内阻(DC Internal Resistance, DCR)是 HPPC 测试中提取的核心健康特征,通过计算在电流脉冲期间电压的变化量与电流变化量的比值得到,即遵循欧姆定律的 $\Delta V/\Delta I$ 。直流内阻会随着电池的衰减而增加,因此可以作为健康特征用于估计 SOH。YANG 等^[38]利用 HPPC 测试结果对一阶电阻电容(Resistor-Capacitor, RC)等效电路进行参数辨识,得到等效电阻和电容的值,作为神经网络的输入对 SOH 进行估计。然而简单的 DCR 计算方法通常忽略了在脉冲期间由于 SOC 变化而引起的开路电压(Open-Circuit Voltage, OCV)的微小变化。然而这种变化不可忽略,若不加以校正,会导致对内阻的估计值过高。因此, PILLAI 等^[39]通过模型来补偿 OCV 的动态变化,从而得到更准确的内阻值。

2.3.2 OCV-SOC 特征

在 HPPC 测试中,通常可以得到开路电压 OCV 与荷电状态 SOC 的关系曲线,如图 5 所示^[40]。OCV-SOC 曲线反映了电极材料在不同锂浓度下的电势随着电池衰减,OCV-SOC 曲线会发生可测量的平移和形状变化^[41]。BARCELLONA 等^[42]的研究采用多项式拟合 OCV-SOC 曲线,并将拟合参数作为健康特征估计,探究这些参数在电池生命周期中的变化,建立拟合与 SOH 之间的映射关系。GAO 等^[43]则使用 OCV-SOC 曲线作为连接电化学模型和等效电路模型的纽带,将 OCV-SOC 的关系应用至基于等效电路的 SOC 估算器,利用平衡电位量化容量衰减来实现 SOH 的估计,




图5 磷酸铁锂电池的 OCV-SOC 曲线^[40]

Fig. 5 OCV-SOC curve for a LiFePO₄ battery^[40]

并通过模拟和实验结果验证了所提出的估算方案的鲁棒性和有效性。LI 等^[44]通过分析 OCV-SOC 曲线的变化,利用库仑计数法和扩展卡尔曼滤波算法构建 SOH 观测器,该观测器能够自适应地更新 OCV-SOC 曲线,可用容量补偿 SOH 衰退,并将这些更新后的信息集成到 SOC 估计中,最终实现对老化电池 SOH 的准确估计。

2.4 基于电化学阻抗的特征

电化学阻抗谱(Electrochemical Impedance Spectroscopy, EIS)是一种电化学表征技术,通过向电化学系统施加微小交流信号并测量系统响应,深入分析锂电池的内部电化学过程。图 6 为典型的锂离子电池电化学阻抗谱奈奎斯特图。通过分析不同频率区间的阻抗特征,EIS 可以表征容量衰减、内阻变化、电极/电解质界面劣化等关键指标,有助于揭示电池内部复杂的电荷传输、界面反应和材料衰减机制,为电池性能优化和健康状态预测提供重要的科学依据^[45]。




图6 典型的锂离子电池电化学阻抗谱奈奎斯特图^[46]

Fig. 6 Typical Nyquist plot of the electrochemical impedance spectroscopy data for a lithium-ion battery^[46]

2.4.1 基于原始 EIS 数据的特征

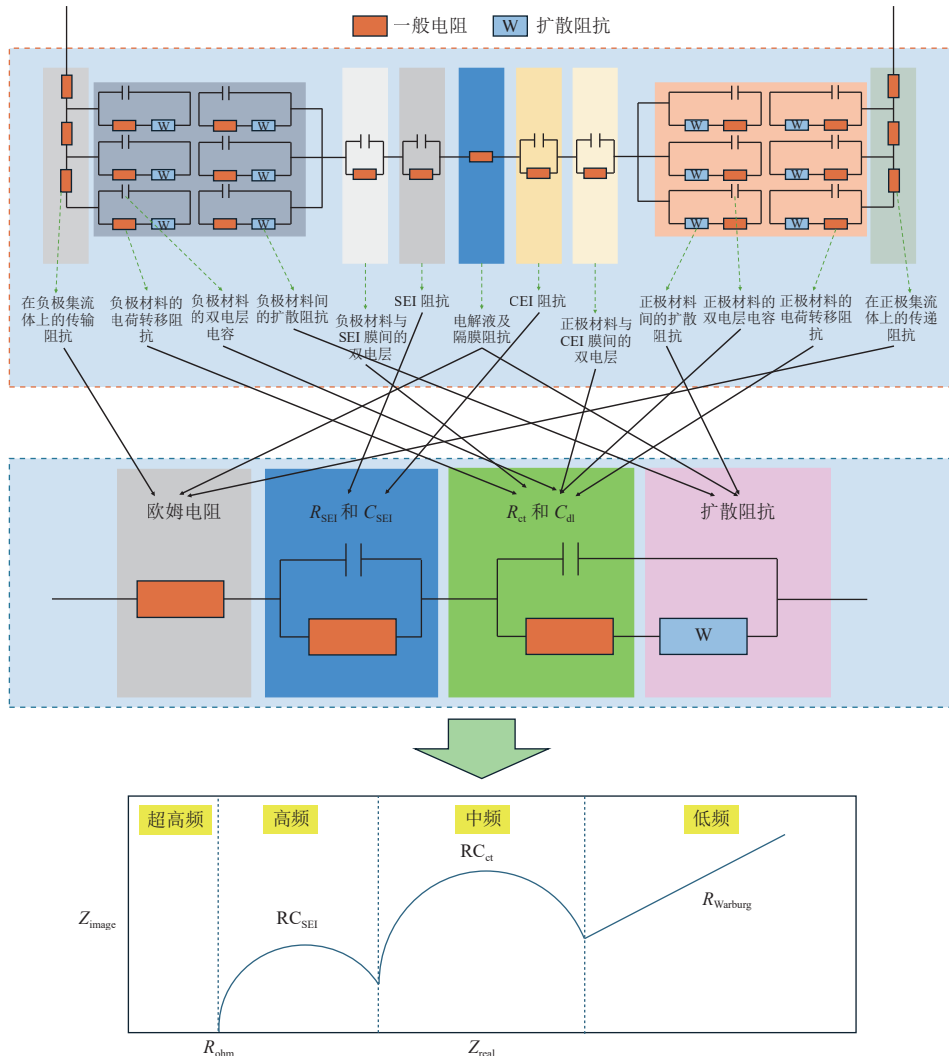
在获取 EIS 数据后,最直接的方法是使用所有频率点的阻抗数据作为健康特征。ZHANG 等^[47]直接将锂电池在 60 个频率点下测得的共 120 维阻抗值(实部和虚部)数据构建成特征向量,作为数据驱动模型的输入对 SOH 进行估计。然而有研究指出,对于数据驱动模型并非输入的维度越高预测的效果越好;非强相关性的参数在预测过程中可能起负相关作用,例如冗余的特征可能影响参数最优化过程^[48],且获取完整频率范

国内的阻抗数据需要更多的时间。ZHANG 等^[47]则在完整阻抗数据的基础上, 使用自动相关性 (Automatic Relevance Determination, ARD) 找到与 SOH 关联性最强的频率作为特征, 也取得了较为优异的估计性能。BAO 等^[49]从 EIS 的不同频段中分别提取了健康特征, 将这些特征作为人工神经网络模型的输入, 得到了较高的估计精度。此外, XIA 等^[50]使用 SHAP (SHapley Additive exPlanations) 框架分析了 EIS 谱中多个频点对 SOH 预测的重要性。研究表明, 仅需采集这一小部分优化后的 EIS 数据即可准确预测 SOH, 测量时间被缩短至 100 s 以内, 显著减少了测量时间和数据需求。这

些研究简化了 SOH 估计过程, 使基于有限频谱测量的快速评估成为可能, 并为基于 EIS 的 SOH 估计的实际应用提供了新思路。

2.4.2 基于等效电路模型的特征

将 EIS 数据与等效电路模型 (Equivalent-Circuit Model, ECM) 相结合, 是提取具有明确物理意义的健康特征的经典方法。通过将 EIS 谱图拟合到一个由电阻、电容等元件组成的电路模型中, 可以将复杂的阻抗响应分解为几个独立的物理过程, 如图 7 所示。常用的等效电路模型有 Rint、Thevenin、PNGV、RC 模型等^[51]。



注: SEI——固体电解质界面膜; CEI——正极电解质界面膜; R_{SEI} ——界面膜电阻; C_{SEI} ——界面膜电容; R_{ct} ——电荷转移电阻; C_{dl} ——双电层电容; R_{ohm} ——欧姆电阻; RC_{ct} ——电荷转移容阻; RC_{SEI} ——界面膜容阻; $R_{Warburg}$ ——韦伯扩散阻抗; Z_{image} ——阻抗虚部; Z_{real} ——阻抗实部。

图 7 基于 ECM 的 EIS 特征提取

Fig. 7 Feature extraction of EIS based on ECM

STROE 等^[52]研究了 2.5 A·h 的 LiFePO₄ 电池在不同循环次数下阻抗的变化规律, 并采用等效

电路模型对 EIS 进行拟合, 分析了等效电阻和等效电容随循环次数变化的规律, 建立了等效电

阻与循环次数的关系,实现对SOH的预测。GALEOTTI等^[53]则研究了不同循环阶段EIS的变化规律,同样使用等效电路模型对EIS进行拟合,研究各等效参数随健康状态的变化规律,以电池欧姆电阻与可用容量之间的关系通过证据理论(Theory of Evidence, TOE)来估计电池的健康状态。基于ECM的特征提供了具有清晰物理意义的参数,能够直接与SEI膜生长、电荷转移动力学等微观衰减机制相关联,为深入理解电池的衰减机制提供了依据。然而这种方法的有效性完全依赖于所选ECM的正确性,错误的模型结构或不稳定的拟合算法都可能导致提取的参数失去物理意义^[54]。相比之下,直接使用原始EIS数据可避免复杂的模型拟合问题,特征提取过程更为直接和鲁棒,但其代价是物理意义的损失^[55]。

2.4.3 基于弛豫时间分布的特征

弛豫时间分布(Distribution of Relaxation Times, DRT)通过数学变换(如傅里叶变换)将频域的阻抗谱转换为时域的弛豫时间分布谱图。在DRT谱图中,不同的电化学过程会以独立峰的形式出现,从而实现了重叠过程的有效解耦。不同的电化学过程由暂态进入稳态的时间不同,故而可以通过提取不同的弛豫时间来辨识和分析不同的电化学过程,用于实现对EIS谱图的解析^[56]。

DRT曲线包含了峰/谷特征和弛豫时间(τ)变化的全面信息^[57],因此最直接的方法是基于DRT曲线中的容量衰减来分析峰/谷特征的变化趋势。ZHANG等^[58]对从DRT图和EIS数据中提取的参数与SOH的相关性进行了分析,并从相关性分析中选择与SOH呈线性关系或分段线性关系的参数,实现了高度准确的SOH估算。SU等^[59]分析了DRT曲线分布函数中的峰值和谷值信息随容量衰减的变化规律,并提取了与SOH高度相关的多个特征作为健康特征。对提取的健康特征进行加权主成分分析处理,以获得间接健康特征。XU等^[60]则将DRT和时域数据(如IC曲线和内阻)相结合来提取稳定的健康特征。

2.5 多物理场方法

锂离子电池本质是一个复杂的电-热-力耦合系统,其衰减过程不仅体现在电学性能上,也伴随着热动力学和机械结构的变化。利用多物理场传感器可以捕捉这些非电学信号,为SOH估计提供全新的信息维度。

从信息论的角度,锂离子电池的衰减可以被

视为一个从有序走向无序的熵增过程。随着电池老化,其动态响应信号的熵值会呈现出单调变化的趋势,可以作为一种新颖的健康特征^[61]。利用样本熵(Sample Entropy)或模糊熵(Fuzzy Entropy)等算法,可以衡量电池电压或温度等时间序列信号的复杂性或不规则性。

锂电池在运行中会产热,且其热特性与健康状态密切相关。JIANG等^[62]将温度变化率与电压变化率之比(dT/dV)定义为微分热电压分析(Differential Thermal Voltammetry, DTV),DTV能够捕捉电化学相变过程中的熵热效应,DTV曲线的峰、谷特征可作为健康指标,与IC峰相对应,提供了与ICA互补的热学视角。利用红外热像仪可以获得电池表面温度的二维分布图。健康的电池在均匀工作时温度分布相对一致,而老化或存在内部缺陷的电池则可能出现局部热点。基于此,KAFADAROVA等^[63]提出了使用温度分布的统计特征,如平均温度、最高/最低温度差、温度方差等,作为反映电池内部不均匀性的健康特征。

超声波传感是一种利用声波探测电池内部物理结构变化的非侵入式技术。WU等^[64]指出电池老化过程中发生的物理变化,如电极材料的杨氏模量变化、电解液密度的改变、内部产气形成气泡、电极分层或出现裂纹等,都会改变声波的传播路径和衰减特性,从而导致飞行时间(Time-of-Flight, ToF)和信号振幅发生可测量的变化,并基于此特性开发了一种用于监测商业软包锂电池的超声波传感技术,利用超声波传感数据进行数据融合分析,构建了新的电池健康指标。此外,通过在电池表面或内部集成应变片或压力传感器,可以直接测量在电池衰减过程中析锂、产气导致的电极体积的膨胀和收缩。从这些传感器信号中提取的特征也可以作为评估电池健康状态的物理量度^[65]。

3 公开数据集

高质量的锂电池数据是健康状态估计中获得高估计精度和泛化性能的重要前提。目前,有多个重要的公开锂电池数据集可供研究人员使用,它们涵盖了不同的使用条件和电池类型,为电池研究提供了宝贵资源。

3.1 NASA Data

由美国国家航空航天局(National Aeronautics and Space Administration, NASA)发布的锂电池老

化数据集^[66],是最早且最广泛使用的公开数据集之一。数据集中包含多组共 34 个标称容量为 2 A·h 的 18650 型锂电池,在不同温度条件下循环至初始容量的 70% 或 80% 的完整生命周期退化数据。该数据集采用恒流-恒压充电和恒流放电(根据不同电池组采用不同截止电压, 2.7、2.5 或 2.2 V)的标准化测试协议,涵盖充放电过程中的电压、电流、温度、容量等关键参数以及电化学阻抗谱测量结果(频率范围 0.1~5.0 kHz),采用.mat 格式存储。目前该数据集已为 SOH 估算、电池剩余使用寿命预测以及基于机器学习的电池管理系统算法验证提供了可靠的实验基础^[67-68]。

3.2 CACLE Data

CALCE 锂电池数据集^[69]是由马里兰大学可靠性工程中心(Center for Advanced Life Cycle Engineering, CALCE)构建的综合性电池老化数据集。数据集涵盖多种电池形式(圆柱形、软包和方形)和化学体系(LCO、LFP、NMC)锂离子电池单体在 4 种不同温度(-40、-5、25、50 °C)和 3 种荷电状态(0、50%、100% SOC)下的测试数据,测试类型涵盖完整和部分循环、存储、动态驾驶工况、开路电压测量和阻抗测量等。常用的 CS2 系列包含 15 个标称容量为 1.1 A·h 的方形钴酸锂电池单体,所有电池均采用 CCCV 充电方式(0.5 C 充电至 4.2 V,截止电流 0.05 A),并根据实验类型采用不同的放电协议,包括恒流放电(0.5 C、1 C)、变倍率放电以及不同截止电压的部分充放电循环。数据内容包含电压、电流、容量、能量、内阻等参数,并定期进行阻抗测试和容量标定。除 CS2_8 和 CS2_21 外,数据采集均采用 Arbin 电池测试仪,以 Excel 形式存储,而 CS2_8 和 CS2_21 使用 CADEX 电池测试仪进行数据采集,以.txt 形式存储^[70-71]。

3.3 Oxford Data

Oxford 锂电池数据集(Oxford Battery Degradation Dataset 1)^[72]是由牛津大学 Howey 研究团队构建的电池老化监测数据库,包含 8 个小型锂离子软包电池单体(Kokam SLPB533459H4),标称容量为 740 mA·h,在 40 °C 恒温环境中循环至电池生命终止。该数据集于 2015 年开始记录,采用 Bio-Logic MPG-205 八通道电池测试设备进行数据采集。实验协议采用恒流-恒压充电模式,放电则基于城市 Artemis 驾驶工况进行;表征测试

在每 100 个驱动循环后执行,包括 1 C 循环(电流值 740 mA)和伪开路电压循环(电流值 40 mA)。数据内容涵盖表征循环过程中的时间、电压、电荷量和温度等关键参数,以 MATLAB 二进制格式存储,分为示例驱动循环文件和完整特征表征数据文件 2 部分。该数据集因其是在实际驾驶工况下采集的电池退化特征数据,在电池研究领域具有重要价值,为电池健康状态诊断、剩余寿命预测和退化机理研究提供了标准化的实验基础,特别适用于电动汽车应用场景下的电池管理系统算法验证。

3.4 XJTU Data

XJTU 锂电池数据集^[20]是由西安交通大学构建的锂电池全生命周期监测数据库,共包含 55 个标称容量为 2 A·h 的 18650 圆柱形电池单体($\text{LiNi}_{0.5}\text{Co}_{0.2}\text{Mn}_{0.3}\text{O}_2$),分为 6 个批次,采用 6 种不同的充放电策略进行实验。实验采用 ACTS-5V10A-GGS-D 充放电平台,数据采样频率为 1 Hz,记录了电池从开始使用到容量衰减至初始值的 80% 以下的完整数据。每个批次的充放电协议均不同。数据内容涵盖电压、电流、容量、温度等多维传感器数据,为电池健康状态估算、剩余寿命预测和退化机理建模研究提供了标准化的基准测试平台,特别适用于验证机理模型和数据驱动融合模型方法的有效性。

3.5 HUST Data

由华中科技大学开发的磷酸铁锂电池数据库^[73]共包含 77 个 18650 圆柱形锂离子电池单体,正极材料为磷酸铁锂,负极材料为石墨,标称容量为 1.1 A·h。在 30 °C 恒温条件下进行实验,77 个电池单体使用相同的快充协议,但采用 77 种不同的多阶段放电协议。该数据集专注于受控变量下的多电池退化性能分析,特别适用于研究周期性波动和非稳态演化特性。数据采集采用高精度电池测试设备,记录了完整的充放电循环过程中的电压、电流、容量和温度等参数。该数据集为电池在复杂工况下的性能预测、多样化放电策略对电池寿命影响的研究以及基于机器学习的电池健康管理算法开发提供了丰富的实验支撑。

4 总结与展望

4.1 总 结

锂离子电池健康状态估计的准确性高度依赖于高质量健康特征的提取。本文系统梳理了锂离

子电池健康状态估计中的特征提取方法及其应用现状,深入分析了不同特征参数的物理机理、提取方法和应用效果。通过对基于电压电流曲线、微分曲线、混合脉冲功率特性和电化学阻抗谱等 4 类主要特征提取方法的全面综述,揭示了各类特征在反映电池老化机制方面的独特优势和固有局限性。此外,还介绍了 NASA、CALCE 和 Oxford 等重要的公开数据集,为电池健康状态估计研究提供了标准化的实验基础和算法验证平台。这些数据集涵盖了不同电池类型、工作条件和老化模式,为 SOH 算法开发和性能比较提供了重要支撑。

4.2 展 望

尽管现有研究已取得显著进展,锂离子电池健康特征工程仍有广阔发展空间,未来的研究应集中在以下几个方向。

(1) 标准化测试与评估: 目前,不同研究中使用的电池类型、测试工况和评估指标各不相同,这给不同特征和算法的横向比较带来了困难。因此,建立公开的、标准化的电池老化数据集和统一的评估协议,对于推动该领域的健康发展至关重要。这需要学术界和产业界联合,共同定义能够反映真实复杂工况的测试规范,保证所提取的特征和提出的新算法具有实际应用价值。

(2) 多特征深度融合: 单一的电化学特征往往难以全面反映电池复杂的老化过程。将来自不同领域(如电、热、力、声)的特征进行深度融合,是提高 SOH 估计精度和鲁棒性的必然趋势。例如,电学特征(电压、电流)直接反映宏观电化学反应动力学,热学特征(表面温度分布)可以揭示内部阻抗不均匀性和局部老化热点,而声学或力学特征则能捕捉到电极材料微观结构损伤、产气或析锂等物理退化信息。通过先进的融合算法(如多模态深度学习),将这些互补信息有效结合,可以构建出更全面、更可靠的混合健康指标,克服单一特征的局限性,从而在面对多重、耦合的锂离子电池老化机制时实现更精确的健康状态估计。

(3) 数据驱动与物理模型耦合: 将数据驱动方法与物理模型相结合是另一个前景广阔的方向。纯数据驱动模型往往缺乏物理可解释性,且在训练数据覆盖不到的工况下泛化能力有限。通过将电池的物理或电化学模型(如伪二维模型、等效电路模型等)作为约束或先验知识融入神经网络等数据驱动模型的训练过程中,构建物理信息神经网络(Physics-informed Neural Networks, PINN)。

这种方法使得模型的预测结果不仅能精准拟合观测数据,还能遵守基本的物理定律,不仅能显著提高模型在小样本数据下的学习效率和泛化能力,更能增强模型的可解释性与可靠性,使其在电池管理系统的应用中更值得信赖。

参考文献 (References):

- [1] ETACHERI V, MAROM R, ELAZARI R, et al. Challenges in the development of advanced Li-ion batteries: A review[J]. *Energy & Environmental Science*, 2011, 4(9): 3243.
- [2] 王其钰, 王朔, 张杰男, 等. 锂离子电池失效分析概述[J]. *储能科学与技术*, 2017, 6(5): 1008-1025.
WANG Qiyu, WANG Shuo, ZHANG Jienan, et al. Overview of the failure analysis of lithium ion batteries[J]. *Energy Storage Science and Technology*, 2017, 6(5): 1008-1025.
- [3] ZHAO Guangjin, WU Wenlong, QIU Wubin, et al. Secondary use of PHEV and EV lithium-ion batteries in stationary applications as energy storage system[J]. *Advanced Materials Research*, 2012, 528: 202-205.
- [4] TANG Kang, LUO Bingbing, CHEN Dian, et al. The state of health estimation of lithium-ion batteries: A review of health indicators, estimation methods, development trends and challenges[J]. *World Electric Vehicle Journal*, 2025, 16(8): 429.
- [5] LIN Mingqiang, WU Denggao, MENG Jinhao, et al. A multi-feature-based multi-model fusion method for state of health estimation of lithium-ion batteries[J]. *Journal of Power Sources*, 2022, 518: 230774.
- [6] VIDAL C, MALYSZ P, KOLLMEYER P, et al. Machine learning applied to electrified vehicle battery state of charge and state of health estimation: State-of-the-art[J]. *IEEE Access*, 2020, 8: 52796-52814.
- [7] 邓林旺, 冯天宇, 舒时伟, 等. 锂离子电池无损析锂检测研究进展[J]. *储能科学与技术*, 2023, 12(1): 263-277.
DENG Linwang, FENG Tianyu, SHU Shiwei, et al. Nondestructive lithium plating online detection for lithium-ion batteries: A review[J]. *Energy Storage Science and Technology*, 2023, 12(1): 263-277.
- [8] VETTER J, NOVÁK P, WAGNER M R, et al. Ageing mechanisms in lithium-ion batteries[J]. *Journal of Power Sources*, 2005, 147(1-2): 269-281.
- [9] IURILLI P, BRIVIO C, WOOD V. On the use of electrochemical impedance spectroscopy to characterize and model the aging phenomena of lithium-ion batteries: A critical review[J]. *Journal of Power Sources*, 2021, 505: 229860.
- [10] LIU Datong, ZHOU Jianbao, LIAO Haitao, 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.
- [11] 陈丹. 基于数据-模型联合驱动的储能系统锂离子电池剩余寿命预测 [D]. 成都: 四川大学, 2023: 19.
- CHEN Dan. Empirical-data hybrid driven approaches for remaining useful life prediction of lithium-ion batteries in energy storage system[D]. Chengdu: Sichuan University, 2023: 19.
- [12] LI Mei, XU Wenting, ZHANG Shiwen, et al. State of health estimation and battery management: A review of health indicators, models and machine learning[J]. *Materials*, 2025, 18(1): 145.
- [13] LIU Gengfeng, ZHANG Xiangwen, LIU Zhiming. State of health estimation of power batteries based on multi-feature fusion models using stacking algorithm[J]. *Energy*, 2022, 259: 124851.
- [14] FANG Pengya, ZHANG Han, ZHANG Anhao, et al. SOH estimation based on multisource feature extraction and SSALSTM algorithm[J]. *ACS Omega*, 2025, 10(29): 31880–31895.
- [15] LIN Chuanping, XU Jun, SHI Mingjie, et al. Constant current charging time based fast state-of-health estimation for lithium-ion batteries[J]. *Energy*, 2022, 247: 123556.
- [16] CAI Li, LIN Jingdong. A charging-feature-based estimation model for state of health of lithium-ion batteries[J]. *Expert Systems with Applications*, 2024, 238: 122034.
- [17] DENG Zhongwei, HU Xiaosong, XIE Yi, et al. Battery health evaluation using a short random segment of constant current charging[J]. *iScience*, 2022, 25(5): 104260.
- [18] DENG Zhongwei, HU Xiaosong, LI Penghua, et al. Data-driven battery state of health estimation based on random partial charging data[J]. *IEEE Transactions on Power Electronics*, 2022, 37(5): 5021–5031.
- [19] WU Jiang, LIU Zelong, ZHANG Yan, et al. Data-driven state of health estimation for lithium-ion battery based on voltage variation curves[J]. *Journal of Energy Storage*, 2023, 73: 109191.
- [20] WANG Fujin, ZHAI Zhi, ZHAO Zhibin, et al. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis[J]. *Nature Communications*, 2024, 15: 4332.
- [21] SÜPÜRTÜLÜ M, HATİPOĞLU A, YILMAZ E. An analytical benchmark of feature selection techniques for industrial fault classification leveraging time-domain features[J]. *Applied Sciences*, 2025, 15(3): 1457.
- [22] XIAN Yanhua, LI Mingyang, HUANG Jiayin. A lithium-ion batteries SOH estimation method based on extracting new features during the constant voltage charging stage and improving BPNN[J]. *PLoS One*, 2025, 20(5): e0324868.
- [23] WENG Caihao, CUI Yujia, SUN Jing, 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.
- [24] LI Yaqi, GUO Jia, PEDERSEN K, et al. Recent health diagnosis methods for lithium-ion batteries[J]. *Batteries*, 2022, 8(7): 72.
- [25] THOMPSON A H. Electrochemical potential spectroscopy: A new electrochemical measurement[J]. *Journal of the Electrochemical Society*, 1979, 126(4): 608–616.
- [26] ZHENG Linfeng, ZHU Jianguo, LU D D, et al. Incremental capacity analysis and differential voltage analysis based state of charge and capacity estimation for lithium-ion batteries[J]. *Energy*, 2018, 150: 759–769.
- [27] FLY A, CHEN R. Rate dependency of incremental capacity analysis (dQ/dV) as a diagnostic tool for lithium-ion batteries[J]. *Journal of Energy Storage*, 2020, 29: 101329.
- [28] XIE Yanxin, WANG Shunli, ZHANG Gexiang, et al. A review of data-driven whole-life state of health prediction for lithium-ion batteries: Data preprocessing, aging characteristics, algorithms, and future challenges[J]. *Journal of Energy Chemistry*, 2024, 97: 630–649.
- [29] BLOOM I, JANSEN A N, ABRAHAM D P, et al. Differential voltage analyses of high-power, lithium-ion cells[J]. *Journal of Power Sources*, 2005, 139(1–2): 295–303.
- [30] BEREICIBAR M, GARMENDIA M, GANDIAGA I, et al. State of health estimation algorithm of LiFePO_4 battery packs based on differential voltage curves for battery management system application[J]. *Energy*, 2016, 103: 784–796.
- [31] WANG Limei, PAN Chaofeng, LIU Liang, et al. On-board state of health estimation of LiFePO_4 battery pack through differential voltage analysis[J]. *Applied Energy*, 2016, 168: 465–472.
- [32] WANG Limei, ZHAO Xiuliang, LIU Liang, et al. State of health estimation of battery modules via differential voltage analysis with local data symmetry method[J]. *Electrochimica Acta*, 2017, 256: 81–89.
- [33] ZHAO Qian, JIANG Haobin, CHEN Biao, et al. Research on the SOH prediction based on the feature points of incremental capacity curve[J]. *Journal of the Electrochemical Society*, 2021, 168(11): 110554.
- [34] ZHOU Qinan, VUYLSTEKE G, ANDERSON R D, et al. Battery state of health estimation and incremental capacity analysis for charging with general current profiles using neural networks[DB/OL]. (2025-06-11)[2025-10-10]. <http://arxiv.org/abs/2502.19586>.
- [35] 谢乐琼, 王莉, 胡坚耀, 等. 动力电池重要测试方法: 混合脉冲功率特性测试 [J]. *电池工业*, 2018, 22(5): 257–264.
- XIE Leqiong, WANG Li, HU Jianyao, et al. An impor-

- tant test of power battery: Hybrid pulse power characterization test[J]. Chinese Battery Industry, 2018, 22(5): 257–264.
- [36] BIAŁOŃ T, NIESTRÓJ R, SKARKA W, et al. HPPC test methodology using LFP battery cell identification tests as an example[J]. *Energies*, 2023, 16(17): 6239.
- [37] LEE S, KIM J, CHO B H. Maximum pulse current estimation for high accuracy power capability prediction of a Li-ion battery[J]. *Microelectronics Reliability*, 2015, 55(3–4): 572–581.
- [38] YANG Duo, WANG Yujie, PAN Rui, et al. A neural network based state-of-health estimation of lithium-ion battery in electric vehicles[J]. *Energy Procedia*, 2017, 105: 2059–2064.
- [39] PILLAI P, DESAI S, PATTIPATI K R, et al. An improved approach to estimate the internal resistance of a battery during the HPPC test[DB/OL]. (2025-05-25)[2025-10-10]. <http://arxiv.org/abs/2505.06410>.
- [40] 汪宇航, 黄海宏, 王海欣. 基于脉冲电压频域特征和内阻的退役电池快速初步分选策略[J]. 仪器仪表学报, 2024, 45(3): 214–226.
- WANG Yuhang, HUANG Haihong, WANG Haixin. Fast preliminary sorting strategy for retired batteries based on pulse voltage frequency domain features and internal resistance[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 214–226.
- [41] AZIZIGHALESARI S, POPOVIC J, VENUGOPAL P, et al. A review of lithium-ion batteries diagnostics and prognostics challenges[C]//IECON 2021–47th Annual Conference of the IEEE Industrial Electronics Society. Toronto: IEEE, 2021.
- [42] BARCELLONA S, CODECASA L, COLNAGO S, et al. Calendar aging effect on the open circuit voltage of lithium-ion battery[J]. *Energies*, 2023, 16(13): 4869.
- [43] GAO Yizhao, ZHANG Xi, YANG Jun, et al. Estimation of state-of-charge and state-of-health for lithium-ion degraded battery considering side reactions[J]. *Journal of the Electrochemical Society*, 2018, 165(16): A4018–A4026.
- [44] LI Zhuo, NI Haibin, ZHU Wenbing, et al. Adaptive SOC-OCV mapping-based joint estimation of SOC and SOH in aging lithium-ion batteries using extended Kalman filtering[J/OL]. Journal of Power Electronics: 1–13[2025-05-22]. <https://doi.org/10.1007/s43236-025-01064-8>.
- [45] LIU Yadong, LIU Qi, LI Zhefei, et al. Failure study of commercial LiFePO₄ Cells in over-discharge conditions using electrochemical impedance spectroscopy[J]. *Journal of the Electrochemical Society*, 2014, 161(4): A620–A632.
- [46] WANG Xueyuan, WEI Xuezhe, ZHU Jiangong, et al. A review of modeling, acquisition, and application of lithium-ion battery impedance for onboard battery management[J]. *eTransportation*, 2021, 7: 100093.
- [47] ZHANG Yunwei, TANG Qiaochu, ZHANG Yao, et al. Identifying degradation patterns of lithium ion batteries from impedance spectroscopy using machine learning[J]. *Nature Communications*, 2020, 11: 1706.
- [48] JIANG Bo, ZHU Jiangong, WANG Xueyuan, et al. A comparative study of different features extracted from electrochemical impedance spectroscopy in state of health estimation for lithium-ion batteries[J]. *Applied Energy*, 2022, 322: 119502.
- [49] BAO Minghan, LIU Dexun, WU Yuyao, et al. Interpretable machine learning prediction for Li-ion battery's state of health based on electrochemical impedance spectroscopy and temporal features[J]. *Electrochimica Acta*, 2024, 494: 144449.
- [50] XIA Bizhong, QIN Zhanpeng, FU Hongye. Rapid estimation of battery state of health using partial electrochemical impedance spectra and interpretable machine learning[J]. *Journal of Power Sources*, 2024, 603: 234413.
- [51] 岳永胜, 孙冬, 许爽, 等. 锂离子电池等效电路模型的研究进展[J]. 电池, 2023, 53(6): 682–686.
- YUE Yongsheng, SUN Dong, XU Shuang, et al. Research progress in equivalent circuit model for Li-ion battery[J]. Battery Bimonthly, 2023, 53(6): 682–686.
- [52] STROE D I, SWIERCZYNSKI M, STAN A I, et al. Diagnosis of lithium-ion batteries state-of-health based on electrochemical impedance spectroscopy technique[C]//2014 IEEE Energy Conversion Congress and Exposition (ECCE). Pittsburgh: IEEE, 2014: 4576–4582.
- [53] GALEOTTI M, CINÀ L, GIAMMANCO C, et al. Performance analysis and SOH (state of health) evaluation of lithium polymer batteries through electrochemical impedance spectroscopy[J]. *Energy*, 2015, 89: 678–686.
- [54] KACETL T, KACETL J, TASHAKOR N, et al. A simplified model for the battery ageing potential under highly rippled load for battery management and active degradation control[DB/OL]. (2022-11-19)[2025-10-10]. <http://arxiv.org/abs/2209.08836>.
- [55] RASTEGARPANAH A, HATHAWAY J, STOLKIN R. Rapid model-free state of health estimation for end-of-first-life electric vehicle batteries using impedance spectroscopy[J]. *Energies*, 2021, 14(9): 2597.
- [56] ZHENG Yuejiu, SHI Zhihe, GUO Dongxu, et al. A simplification of the time-domain equivalent circuit model for lithium-ion batteries based on low-frequency electrochemical impedance spectra[J]. *Journal of Power Sources*, 2021, 489: 229505.
- [57] XU Yidong, ZHANG Hengyun, LIU Ruitong, et al. Analysis of electro-chemical impedance and state of health based on permanent expansion for prismatic batteries[J]. *Journal of*

- Power Sources, 2024, 605: 234515.
- [58] ZHANG Qi, WANG Dafang, SCHATZ E, et al. Degradation mechanism analysis and state-of-health estimation for lithium-ion batteries based on distribution of relaxation times[J]. *Journal of Energy Storage*, 2022, 55: 105386.
- [59] SU Zhipeng, LAI Jidong, SU Jianhui, et al. Modeling and health feature extraction method for lithium-ion batteries state of health estimation by distribution of relaxation times[J]. *Journal of Energy Storage*, 2024, 90: 111770.
- [60] XU Tingting, PENG Zhen, LIU Dunge, et al. A hybrid drive method for capacity prediction of lithium-ion batteries[J]. *IEEE Transactions on Transportation Electrification*, 2021, 8(1): 1000–1012.
- [61] SUI Xin, HE Shan, MENG Jinhao, et al. Fuzzy entropy-based state of health estimation for Li-ion batteries[J]. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 2021, 9(4): 5125–5137.
- [62] JIANG Pengchang, ZHANG Tianyi, HUANG Guangjie, et al. An end-cloud collaboration approach for state-of-health estimation of lithium-ion batteries based on Bi-LSTM with collaboration of multi-feature and attention mechanism[J]. *International Journal of Green Energy*, 2024, 21(10): 2205–2217.
- [63] KAFADAROVA N, SOTIROV S, HERBST F, et al. A system for determining the surface temperature of cylindrical lithium-ion batteries using a thermal imaging camera[J]. *Batteries*, 2023, 9(10): 519.
- [64] WU Yi, WANG Youren, YUNG W K C, et al. Ultrasonic health monitoring of lithium-ion batteries[J]. *Electronics*, 2019, 8(7): 751.
- [65] MOHAMMADI MORADIAN J, ALI A, YAN Xuehua, et al. Sensors innovations for smart lithium-based batteries: Advancements, opportunities, and potential challenges[J]. *Nano-Micro Letters*, 2025, 17(1): 279.
- [66] SAHA B, GOEBEL K. Battery data set[EB/OL]. (2007-10-18) [2025-10-12]. <https://www.nasa.gov/intelligent-systems-division/>.
- [67] ZHANG Ying, ZHANG Ming, LIU Chao, et al. Reliability enhancement of state of health assessment model of lithium-ion battery considering the uncertainty with quantile distribution of deep features[J]. *Reliability Engineering & System Safety*, 2024, 245: 110002.
- [68] HOU Zhoujie, PAN Jiahui, LI Yuanqing. MFASleepNet: Multi-view fusion attention-based deep neural network for automatic sleep staging[C]//2024 International Joint Conference on Neural Networks (IJCNN). IEEE, 2024: 1–8.
- [69] UNIVERSITY OF MARYLAND, CALCE. CS2 battery dataset[DB/OL]. (2011) [2025-10-12]. <https://calce.umd.edu/data#CS2>.
- [70] FENG Juqiang, CAI Feng, LI Huachen, et al. A data-driven prediction model for the remaining useful life prediction of lithium-ion batteries[J]. *Process Safety and Environmental Protection*, 2023, 180: 601–615.
- [71] LI Lei, LI Yuanjiang, MAO Runze, et al. Remaining useful life prediction for lithium-ion batteries with a hybrid model based on TCN-GRU-DNN and dual attention mechanism[J]. *IEEE Transactions on Transportation Electrification*, 2023, 9(3): 4726–4740.
- [72] HOWEY D, BIRKL C. Oxford battery degradation dataset 1[DB/OL]. (2017-01-01) [2025-10-12]. <https://ora.ox.ac.uk/objects/uuid:03ba4b01-cfed-46d3-9b1a-7d4a7bdf6fac>.
- [73] MA Guijun, XU Songpei, JIANG Benben, et al. Real-time personalized health status prediction of lithium-ion batteries using deep transfer learning[J]. *Energy & Environmental Science*, 2022, 15(10): 4083–4094.