

储能测试与评价



电动汽车用锂离子电池 SOC 估算方法

刘 娜, 王聪杰, 张 钊, 梁晓婧, 孙文浩, 田 君, 曹宝森, 田崔钧
(中国北方车辆研究所, 北京 100072)

摘 要: 锂离子电池荷电状态 (SOC) 估算是电动汽车电池管理系统 (BMS) 的核心技术。SOC 用于表征电池剩余可用容量, 受电池内部电化学非线性特性、全生命周期老化衰减、车载复杂工况扰动以及电池模组内部单体一致性差异等多重因素耦合作用, 无法依靠传感器直接测得, 只能通过电压、电流、温度等外部参数实现间接估算。估算精度与鲁棒性直接影响整车运行安全、续航预估可靠性, 也是制约 BMS 性能提升与电动汽车技术迭代的瓶颈。本文系统综述电动汽车锂离子电池 SOC 估算技术, 首先明确 SOC 在 BMS 中的核心定位与功能价值; 将现有估算方法划分为可测量经验估算法、模型驱动法、数据驱动法及模型-数据融合法四大类, 深入剖析各类方法的原理、优缺点及适用边界; 重点聚焦模型-数据融合这一主流发展方向, 对比分析串行补偿、特征提取、约束嵌入与并行融合四类核心策略的逻辑架构、技术优势及工程应用难点; 最后结合智能 BMS 升级及数字孪生、边缘计算等跨学科融合趋势, 提出 SOC 估算向终身学习、云-边-端垂直整合、物理-数据深度融合及多状态联合估计演进等方向。本文旨在系统梳理 SOC 估算技术的发展脉络, 剖析当前研究瓶颈与车载工程痛点, 整合各类方法的适配场景与优化路径, 为下一代 BMS 的研发、优化及工程化应用提供理论参考。

关键词: 锂离子电池; 荷电状态 (SOC); 电池管理系统 (BMS); 模型-数据融合; 状态估计

doi: 10.19799/j.cnki.2095-4239.2026.0378

中图分类号: TH 3

文献标志码: A

文章编号: 2095-4239 (2026) 10-4129-19

Research on SOC estimation methods for lithium-ion batteries in electric vehicles

LIU Na, WANG Congjie, ZHANG Kun, LIANG Xiaoqiang, SUN Wenhao, TIAN Jun,
CAO Baosen, TIAN Cuijun

(Testing and Evaluation Technology Department, China North Vehicle Research Institute, Beijing 100072, China)

Abstract: State-of-charge (SOC) estimation for lithium-ion batteries is the core technology of the battery management system (BMS) in electric vehicles. SOC indicates the remaining capacity of a battery and is affected by multiple coupled factors, including the internal electrochemical nonlinearity of the battery, aging degradation over the full life cycle, disturbances under complex on-vehicle operating conditions, and cell inconsistency within battery modules. SOC cannot be directly measured by sensors and can only be estimated indirectly through external parameters such as voltage, current, and temperature. Its estimation accuracy and robustness directly affect vehicle operational safety and the reliability of driving range prediction, and constitute a bottleneck restricting BMS performance

收稿日期: 2026-05-06; 修改稿日期: 2026-09-10。

基金项目: 中国科协青年人才托举工程 (2024QNRC001)。

第一作者: 刘娜 (1991—), 女, 博士, 高级工程师, 研究方向为动力及储能电池测试与评价, E-mail: liunaw1021@163.com; 通信作者: 田君, 研究员, 研究方向为动力及储能电池测试与评价, E-mail: juntian@noveri.com.cn。

引用本文: 刘娜, 王聪杰, 张钊, 等. 电动汽车用锂离子电池 SOC 估算方法[J]. 储能科学与技术, 2026, 15(10): 4129-4147.

Citation: LIU Na, WANG Congjie, ZHANG Kun, et al. Research on SOC estimation methods for lithium-ion batteries in electric vehicles[J]. Energy Storage Science and Technology, 2026, 15(10): 4129-4147.

improvement and the technological advancement of electric vehicles. This paper systematically reviews SOC estimation technologies for lithium-ion batteries in electric vehicles. First, the core role and functional significance of SOC in BMS are clarified. Second, existing estimation methods are classified into four categories: measurable-parameter-based empirical estimation methods, model-driven methods, data-driven methods, and model-data fusion methods; the principles, advantages, disadvantages, and application boundaries of each category are analyzed in depth. Focusing on model-data fusion as the mainstream development direction, this paper compares and analyzes the logical architecture, technical advantages, and engineering challenges of four core strategies: serial compensation, feature extraction, constraint embedding, and parallel fusion. Finally, in the context of the upgrading of intelligent BMS and interdisciplinary integration trends such as digital twins and edge computing, this paper proposes several future directions for SOC estimation, including lifelong learning, cloud-edge-end vertical integration, deep physics-data fusion, and multi-state joint estimation. This paper systematically reviews the evolution of SOC estimation technologies, analyzes current research bottlenecks and vehicle-oriented engineering challenges, summarizes the applicable scenarios and optimization paths for various methods, and provides theoretical references for the research, development, optimization, and engineering application of next-generation BMS.

Keywords: lithium-ion batteries; state of charge (SOC); battery management system (BMS); model-data fusion; state estimation

在全球“双碳”目标与化石能源短缺的双重驱动下，汽车领域电动化已成为实现能源结构转型与环境治理的核心路径之一^[1-2]。锂离子电池（LIBs）凭借能量密度高、循环寿命长、无记忆效应及成本持续下降的优势，已成为当前电动汽车（EVs）动力系统的主流选择^[3-4]。随着全球电动汽车保有量快速增长，预计2030年其总量将突破3亿辆，锂离子电池需求装机容量将达3000 GWh^[5-6]，而电池组作为电动汽车唯一动力来源，其安全、高效运行直接决定车辆续航可靠性与用户体验。

荷电状态（SOC）作为表征电池剩余电量的核心指标，相当于传统燃油汽车的油量表，不仅需向驾驶员实时反馈剩余续航里程，更需为电池管理系统（BMS）的均衡控制、安全保护、充电策略优化等核心功能提供关键决策依据，以避免电池过充、过放导致的寿命衰减或安全风险^[7-8]。然而，锂离子电池是典型的非线性电化学系统，其内部电化学反应涉及锂离子脱嵌、电荷转移、物质扩散等多物理场耦合，SOC无法通过传感器直接测量，仅能通过电压、电流、温度等外部可测信号间接估算^[9-10]。同时，电池在全生命周期内的老化衰减、复杂工况下的动态响应差异（如低温、高倍率充放电），以

及电池组内单体一致性差异等因素，进一步加剧了SOC估算的难度。SOC估算的精准性与鲁棒性难以协同提升，已成为制约电动汽车电池管理技术发展的关键因素^[11-13]。

尽管近年来学术界与工业界围绕SOC估算技术展开了大量研究，提出了多种估算方法，但各类方法均存在固有局限，尚未形成兼顾精度、鲁棒性、实时性与工程化可行性的最优方案。传统直接算法易受误差累积、测试条件限制，精度难以长期稳定。基于模型的方法依赖精准电池模型与参数辨识，对复杂工况适应性有限，且电化学模型计算复杂度高，难以满足车载实时估算需求；深度学习等数据驱动方法凭借强大的非线性拟合能力突破传统建模难题，灵活度高，但存在黑箱特性导致可解释性不足，且依赖海量试验数据支撑，实时性与泛化能力难以兼顾；而模型-数据融合方法虽然能实现两类方法的优势互补，展现出良好的应用潜力，但尚未形成统一的优化框架与工程化应用标准，极端工况下的鲁棒性仍需提升^[14-16]。此外，针对全生命周期内SOC估算精度的稳定性、电池老化与复杂工况耦合下的估算方法优化等关键工程问题，仍缺乏系统性的梳理与突破性研究，难以满足智能

BMS 发展需求。

鉴于此, 本文聚焦于电动汽车锂离子电池 SOC 估算问题开展系统性综述。文中优化 SOC 估算方法分类体系, 厘清电池机理模型与状态观测滤波算法的层级边界, 避免模型与求解算法概念混用; 针对模型-数据融合主流方向, 归纳串行补偿、特征提取、约束嵌入、并行融合四类实现策略, 从机理逻辑、计算开销、数据需求、工况适应性开展多维度对比, 明确不同路线的性能权衡与适用边界; 立足于车载工程实际, 跳出常温、小倍率理想实验条件, 重点剖析实车工况约束、电池老化耦合效应、模组 SOC 估算等现实痛点; 同时凝练领域亟待解决的科学与工程瓶颈, 结合不同硬件算力与应用场景给出差异化技术选型建议, 为 BMS 算法工程化落地提供参考。全文结构如下: 第 1 部分首先阐述电池管理系统的基本架构、关键功能模块, 重点说明 SOC 在 BMS 中的核心地位与作用, 明确 SOC 估算技术的应用定位与实际需求; 第 2 部分将现有 SOC 估算方法归纳为可测参量经验估算法、基于模型驱动的方法、基于数据驱动的方法以及模型与数据驱动相融合的方法四大类别, 详细阐述各类方法的原理、优势与局限性, 深入讨论当前 SOC 估算中存在的 key 问题与技术难点, 重点对比分析四类模型-数据融合策略的核心逻辑与应用效果; 第 3 部分立足智能 BMS 迭代升级的电池技术发展趋势, 结合数字孪生、边缘计算等跨学科技术的融合应用方向, 系统探讨 SOC 估算领域的未来研究趋势, 深入挖掘该领域实现技术突破的潜在

路径; 最后对全文内容进行总结, 凝练核心研究结论, 为后续 SOC 估算技术的深入研究与工程应用提供参考。

1 电池管理系统(BMS)

BMS 是一种通过监测电池组的状态与参数(如单体电压、电流、温度、荷电状态等)来管理可充电电池组的电子系统^[17]。基于所获取的状态信息, 该系统能够判断充电时机和使用截止节点, 避免危险运行工况, 从而保障电池及使用者的安全^[18]。其核心功能在于对电池进行有效控制与管理, 以确保锂离子电池的耐久性、功率性能与安全性, 具体包括信号测量、状态估算、一致性评估、均衡控制、安全充电、故障诊断及热管理等, 其总体框架如图 1 所示^[19-23]。根据 Dai 等^[24]的研究, 电池管理系统的发展可分为无管理、简单管理、先进管理与下一代管理四个阶段。目前该系统正处于先进管理阶段, 并正向下一代演进。随着电池数量增加和能量密度提升, 极端工况下状态估算方法的适应性不足使得电池安全问题日益突出, 因此发展以智能化为特征的下一代电池管理系统已迫在眉睫。

SOC 估算是 BMS 的基础组成部分, 对其他功能具有重要影响。SOC 可作为健康状态 (SOH) 计算、单体均衡控制及功率计算等功能的输入参数, 是 BMS 的关键功能。本质上, 精准的 SOC 估算能为研究人员和制造商提供关键依据, 可助力电动汽车的未来发展^[25]。




图 1 电池管理系统 (BMS) 总体图^[22-23]

Fig. 1 The overall diagram of battery management system (BMS)^[22-23]

2 SOC估算现有方法与挑战

SOC是衡量电池剩余可用容量的关键参数,通常以百分比表示,并非可直接测量的物理量,需通过电压、电流、温度等相关参数间接估计。其计算公式见式(1):

$$\text{SOC} = \frac{Q_c}{Q} \times 100\% \quad (1)$$

式中, Q_c 为计算时刻电池的剩余容量, Q 为电池的总容量^[26-27]。

其核心定义为特定条件(如温度、充放电倍率)下电池当前剩余容量与总容量的比值,但目前科研工作者对总容量的界定存在争议,常见选项包括额定容量、出厂容量、循环容量、当前实际容量及最大容量,理论分析中常用额定容量,部分研究也以最大容量为基准;从物理本质来看,它是电池正极中锂离子平均浓度与其最大浓度的比值^[25]。理论上SOC取值范围为0~100%,但实际应用中为避免过度充放导致电池性能退化,通常修正为 $\text{SOC}_{\min} > 0$ 且 $\text{SOC}_{\max} < 100\%$,其计算还需纳入库仑效率,同时会因制造商提供的额定容量与真实容量存在差异、电池生命周期内容量受老化及内部化学反应影响变化、传感器限制及机械因素干扰等,增加精准估计的难度^[28]。受上述复杂因素影响,高精度SOC估算仍是亟待解决的难题。

电池模组SOC是对串并联成组后模组整体剩余可用容量的表征,受模组内部单体容量差异、内阻不一致、老化进程分化、连接损耗等多重因素影响,模组SOC不能简单通过单体SOC取算术平均得到。当前模组SOC估算主要分为两类技术思路:一类为先完成各单体SOC估算,再基于单体状态做聚合校正得到模组SOC;另一类直接建立模组等效模型实现整体状态估计。受实车BMS传感器配置、单体离散老化等条件约束,高精度模组SOC估算仍是工程实践中亟待攻克的难点。现有SOC估算方法可分为可测参量经验估算法、模型驱动法、数据驱动法及基于模型与数据驱动的方法。

2.1 可测参数经验估算法

2.1.1 开路电压法

电池开路电压(OCV)是电池在开路状态下达到稳定时的电压,其数值接近电池电动势,可用于衡量电池电动势。研究表明,电池开路电压与荷电

状态呈单调递增关系^[29]。开路电压法是一种基于电池静置稳定后,开路电压与荷电状态之间存在相对固定函数关系进行SOC估计的方法。该方法通过实验获取OCV-SOC关系曲线并进行函数拟合,具有模型结构简单、在充放电末期估计精度高等优点。图2为锂离子电池OCV模型的可视化结果^[30],主要用于对比基于模型计算的开路电压与实测电压的一致性,以验证OCV-SOC模型的有效性^[31-32]。然而,该方法的最大局限在于,需要电池长时间静置才能测量稳定的开路电压,难以实现在线动态估计^[33]。因此在工程实践中,开路电压法通常不单独使用,而是与安时积分法相结合,用于修正安时积分法的累积误差,并将OCV-SOC拟合关系嵌入电池等效电路模型中。




图2 锂离子电池OCV-SOC曲线图^[30]

Fig. 2 The OCV-SOC curve diagram of lithium-ion battery^[30]

2.1.2 安时积分法

安时积分法(AHIM)又称库仑计量法,该方法简单直观,对控制器硬件与存储要求较低,是目前应用最广泛的SOC电荷累积估算方法。其核心原理是通过累积电池充放电过程中的电荷量,实现对电池荷电状态的估算。在实际估算SOC时,还需综合考虑电池温度、充放电效率等因素^[34-35]。安时积分法的计算如式(2)所示:

$$\text{SOC} = \frac{Q_0 + \int_0^t i_c \eta dt - \int_0^t i_d dt - s}{Q} \quad (2)$$

式中, Q 为电池的额定容量; Q_0 为电池的初始电量; η 为充电效率; s 为自放电电量; i_c 为充电电流; i_d 为放电电流。

安时积分法在 SOC 估算中存在明显缺陷^[36]: 其对电流传感器精度要求高, 测量结果易受环境干扰; 估算过程存在累积误差, 且高度依赖初始 SOC 的准确性; 同时, 电池充放电效率、温度、电流波动及容量衰减等因素, 均会进一步降低估算精度。为提升估算精度, 科研工作者通过引入容量修正系数^[37]或构建工程化容量修正模型^[38], 以减小累积误差。在工程应用中, 通常将安时积分法与开路电压法等相结合, 以提高 SOC 估计可靠性与稳定性^[39-40]。

2.1.3 内阻法

内阻法是利用电池内阻与 SOC 的单调关系来估算 SOC 的方法, 但其实际应用存在显著局限性^[41]。该方法将内阻分为交流阻抗和直流内阻, 其中直流内阻通过短时间内电压与电流的变化量来计算。然而, 锂离子电池的内阻随 SOC 变化不明显, 且测量易受温度、老化及电磁干扰影响, 导致估算精度低、设备成本高^[42]。因此, 内阻法仅在放电末期可实现较为有效的 SOC 估算, 难以单独应用于电动汽车等复杂工况场景, 通常需与安时积分法等算法融合, 作为辅助修正手段使用^[43-44]。

2.1.4 电化学阻抗法

电化学阻抗谱 (EIS) 法是通过施加小幅度交流电压, 在宽频率范围内测量电池阻抗谱来无损估算 SOC 的方法, 其核心在于利用电荷转移内阻等电池阻抗参数与 SOC 之间的单调关系构建估算模型^[45]。图 3 的奈奎斯特图及等效电路模型直观地揭示了该原理, 借助高频区的欧姆电阻、中频区的电荷转移电阻及低频区的扩散阻抗, 可清晰解析电池内部动态过程, 为 SOC 估算提供了直观依据^[46]。研究发现, 在特定温度下单一频率的阻抗相位与 SOC 呈现强线性相关, 这为简化测量方案提供了可行思路。但由于其测试设备成本高、对测量环境要求苛刻, 且阻抗受温度和电池老化程度影响显著, 因此该方法在温度变化大的实际场景中难以稳定应用, 不适用于电动汽车等复杂环境^[28,47]。

2.1.5 放电测试法

放电测试法是动力电池 SOC 估算中最为准确可靠的方法^[40]。其原理是通过放电测试获取剩余容量, 即在恒流连续放电至端电压达到放电截止电压过程中, SOC 可由放电电流对时间的积分得到^[48]。该方法适用性强, 可覆盖绝大多数电池体系, 常作




图 3 锂离子电池电化学阻抗谱(EIS)特性图^[46]

Fig. 3 Lithium-ion battery electrochemical impedance spectroscopy (EIS) characteristic diagram^[46]

为实验室标定 SOC 精度的基准方法, 同时也用于电池充放电特性研究与性能维护。但该方法存在明显局限, 完整测试耗时较长, 必须完成全程放电后方可确定各时刻 SOC, 无法在车辆运行过程中实现实时估算^[49]。此外, 测试需中断电池正常工作状态并切换至恒流放电模式, 因此不适用于在用车载场景, 仅适用于实验室动力电池离线维护及电池模型参数辨识。

2.2 模型驱动的 SOC 估算

模型驱动 SOC 估算分为两个关键环节: 第一环节为电池建模, 选取电化学模型或等效电路模型, 建立电池端电压、电流、温度与 SOC 等内部状态的数学描述; 第二环节为状态观测求解, 利用卡尔曼滤波、粒子滤波等观测算法, 结合实测电压电流对模型状态进行迭代修正, 最终输出 SOC。电池模型决定描述电池特性的物理完备程度, 状态观测算法决定状态收敛与抗噪声能力。基于模型的荷电状态估计方法大致可分为三类, 即电化学模型法 (EM)、等效电路模型法 (ECM) 和电化学阻抗模型法 (EIM)。

2.2.1 电化学模型法

电化学模型法是基于电池内部的电化学反应过程, 涵盖锂离子脱嵌、电荷转移、物质扩散等关键环节。该方法结合多孔电极理论、浓溶液理论以及法拉第第一定律、欧姆定律、菲克扩散定律、Butler-Volmer 方程等基础物理定律, 通过建立电化学动力与物质传输方程实现 SOC 估算^[50-51], 其模型示意图如图 4(a)所示。总体上, 电化学模型能够描述电池单体各相及各组分中物质的质量、能量与动量传输, 既可精准表征电池电流、电压等宏观特性, 也能反映电池内部浓度、电势、电流及温度的微观分布^[18,52]。该方法能够全面准确地描述电池内部锂离子扩散、电化学反应等过程及外部特性, 主要包括




图4 (a) 电化学模型示意图^[50]; (b) SP模型电势分布和电流分布示意图^[63]

Fig. 4 (a) Schematic diagram of the electrochemical model^[50]; (b) Schematic diagram of the potential distribution and current distribution of the SP model^[63]

一维模型（1D）^[53-54]、伪二维模型（P2D）^[55]及单粒子模型（SP）^[56-58]。

由 Doyle 提出的物理基电化学伪二维模型（P2D 模型）被广泛用于描述锂离子电池的电化学行为^[59-62]。该模型精度较高，能够模拟电池内部的副反应，进而实现电池老化状态的估计。然而，P2D 模型包含复杂的耦合非线性偏微分方程（PDEs），对计算资源和存储资源需求较高，难以应用于车载实时 SOC 估算场景，主要用于电池设计、性能仿真等离线研究。

SP 模型作为 P2D 模型的简化形式，假定电极内局部体积转移电流密度为常数 j_r ，且等于平均值 $\bar{j}_r$ ，电极内各活性颗粒具有一致的动力学行为，电

流在颗粒间均匀分布。基于该假设，SP 模型以单个颗粒代替整个电极、忽略液相浓度和电势对端电压的影响[其电势分布和电流分布示意图分别如图 4 (b)所示^[63]]，有效减少了待辨识参数并提升了计算效率，适用于低倍率恒流工况下的 SOC 估计。但该模型存在明显局限，当电流倍率增大时，电解液浓度变化加剧，模型误差会显著上升。为解决这一问题，科研工作者通过三参数抛物线法与帕德（Padé）近似法对固、液相锂离子扩散方程进行简化，构建了扩展单粒子模型（ESP）^[39,62-64]，该模型既能保证与 SP 模型相当的估算精度，又能有效提升模型对大电流工况的适应性，拓宽了模型的工程应用范围。

表1 P2D、SP、ESP 电化学模型综合性能对比				
Table 1 Comprehensive performance comparison of P2D, SP and ESP electrochemical models				
模型	计算复杂度	适用充放电倍率	典型 SOC 估算误差	主要局限
P2D 伪二维模型	较高	全倍率	1%~2%	计算开销大；参数辨识难度高，试验数据要求高
SP 单粒子模型	中等偏低	仅适用于低倍率（<1 C）； 倍率>1 C 时估算误差显著增大	低倍率下<5%	忽略电解液浓度演化效应，高倍率工况下估算误差显著增大
ESP 扩展单粒子模型	中等	可覆盖低至较高倍率区间，高倍率下精度优于 SP	1.5%~3%	计算开销较 SP 有所增加；放电末期非线性下误差上升

为满足不同放电倍率下的实时 SOC 估算需求，研究人员通过进一步简化 P2D 模型得到 SP2D 模型^[65-67]。文献[66]提出结合预测-校正策略与对齐方

法的简化多粒子模型，在保证 SP 模型精度的同时降低复杂度，能够精确估算电池内部的电势和体积转移电流密度分布。但 SP2D 模型存在参数繁多、

各参数对输出电压灵敏度差异较大的问题, 导致部分参数难以精准辨识。针对这一缺陷, 文献[67]以 SP2D 为基础, 采用非线性最小二乘法结合费雪信息矩阵分析参数可辨识性, 构建了 SP2D-Iden 模型, 提升了 SOC 估算精度, 进一步优化了模型的工程实用性。

在模型应用与优化方面, 电化学模型包含大量的偏微分方程组, 计算成本高。通常采用积分近似法、有限差分法等数值方法, 将偏微分方程组转化为常微分方程组, 也可通过多项式近似、状态空间建模等手段完成模型降阶, 以此降低计算复杂度。在模型落地过程中涉及两类不同的算法工具: 粒子群优化、遗传算法等启发式算法主要用于解决电化学模型的参数辨识难题; 扩展卡尔曼滤波、无迹卡尔曼滤波等状态观测算法, 则以电化学模型构建的状态空间为基础, 结合电池实测电压、电流迭代求解锂离子浓度与 SOC。电化学模型虽能满足 BMS 对 SOC 估计精度要求, 为电池结构优化设计提供理论支撑, 但其工程应用仍面临多重因素制约。全阶电化学模型参数复杂, 经过降阶得到的简化模型在多变工况下存在精度退化问题, 同时部分关键模型参数难以精准辨识, 对工程开发人员的专业素养要求较高, 上述因素共同造成电化学模型直接部署于车载电池管理系统仍存在较大现实挑战。

上文提到的 P2D、SP、ESP 以及 SP2D 系列

模型的仿真验证大多基于常温、全新电芯条件完成。面向电动汽车车载实际工况, 电池将承受宽温域、动态变倍率充放电、传感器噪声、车辆振动扰动等复杂条件。同时电池老化引发活性物质损耗、SEI 膜持续生长, 带来容量衰减与内阻增长, 会持续改变模型内部参数, 直接造成 SOC 估算精度劣化。老化与 SOC 估算存在双向耦合效应, SOC 估算偏差会进一步干扰 SOH 辨识结果, SOH 表征的可用容量发生漂移, 又反向造成 SOC 计算基准偏移, 进一步放大估算误差。

2.2.2 等效电路模型法

等效电路模型通过电阻、电容、恒压源等传统电路元件构建网络, 以描述动力蓄电池的外部特性^[68]。其核心工作原理体现在两方面: 一是利用电压源表征电池的热力学平衡电动势 (即开路电压 OCV), 二是通过电阻电容 (RC) 网络模拟电池的极化特性、欧姆损耗等各类工作状态, 整体适用性较强。此外, 该模型可进一步推导状态方程, 为后续 SOC 估算、性能分析及实际应用提供便利。目前, 等效电路模型已广泛应用于新能源汽车建模仿真及基于模型的电池管理系统研究, 常见类型包括电阻-内阻 (Rint) 模型、戴维南 (Thevenin) 模型、新一代汽车合作计划 (PNGV) 模型、非线性等效 (GNL) 模型与双极化 (DP) 模型^[69-70], 其电路结构如图 5 所示。




图 5 等效电路模型图: (a) Rint 模型; (b) Thevenin 模型; (c) PNGV 模型; (d) GNL 模型; (e) DP 模型

Fig. 5 Diagrams of equivalent circuit models: (a) Rint model; (b) Thevenin model; (c) PNGV model; (d) GNL model; (e) DP model

2.2.2.1 电阻-内阻(Rint)模型

Rint 模型是结构最简单的电池等效电路, 仅包含一个理想电压源 (OCV) 和一个固定内阻 (R_0)^[71-72]。该模型的优势在于结构简单、计算简便, 适用于动态参数少、极化效应可忽略的理想工

况^[73]。然而, 该模型本质上是一个静态模型, 既无法描述动力学过程中的极化特性, 也未考虑环境因素引发的参数变化, 同时还忽略了充放电过程中由内部电化学反应导致的欧姆内阻与开路电压的动态演变^[74]。这些缺陷致使其在大倍率充放电、宽温域

工作及老化状态下仿真误差较大,进而在多数高精度应用场景中适用性不足。总体而言,该模型的适用边界极为有限,仅适用于OCV-SOC曲线线性度高、内阻近乎恒定且极化效应可忽略的理想电池^[59]。

2.2.2.2 戴维南(Thevenin)模型

与Rint模型相比,Thevenin模型通过增加一个RC串联电路来模拟电池的极化特性,能够有效捕捉锂电池充放电过程中的动态响应,更贴合实际工程应用场景。其中,欧姆电阻 R_o 代表充放电瞬间的电压变化(即欧姆损耗),而RC串联电路则反映充放电过程中及结束后电压的渐变过程(即极化效应),从而更贴合实际应用场景。

为提升锂电池模型精度,科研工作者从模型结构创新与外部因素补偿两个维度提出了多种改进方案。在模型结构层面,Zhao等^[76]通过引入可随负载电流自适应调节的双极化电阻(DPR),显著增强了模型对不同负载工况的适应性与鲁棒性;Qi等^[76]则通过引入极化反应和开路电压滞后效应,强化了模型的物理基础,使其能更准确地描述锂电池的非线性动态行为。在应对外部因素方面,温度是导致模型参数漂移、影响估算精度的关键因素。Wu等^[77]针对这一问题,建立了在0~40℃范围内辨识参数的温度补偿模型,有效提升了SOC在不同温度下的估算精度。这些研究从不同技术路径共同推进了电池状态估计精度的提升,拓展了Thevenin模型的应用范围。

2.2.2.3 新一代汽车合作计划(PNGV)模型

考虑到不同倍率下的负载电流效应(即负载电流随时间累积所产生的电压变化),新一代车辆合作计划(PNGV)模型在Thevenin模型的基础上增加了一个电容 C ^[78-79]。在电池的整个充放电循环过程中,电容 C 会进行充放电,进而影响负载电流和电池SOC的变化。然而,对于Thevenin模型而言,电池的SOC是固定不变的。因此,Thevenin模型仅能描述电池在特定SOC值下的瞬时静态响应,无法反映电池的动态变化过程。因此,PNGV模型在描述锂离子电池等效电路方面具有更高的准确性,更适用于复杂动态工况下的SOC估算。

基于PNGV模型的优化与创新,其已成为众多科研团队的研究焦点,不同团队从不同技术痛点切入,逐步推动PNGV模型在精度、适应性及场景覆

盖度上实现突破,形成了各具特色且层层递进的技术成果。西安理工大学团队率先针对传统PNGV模型的核心缺陷展开改进,创新性地提出将PNGV模型的所有参数与SOC进行动态关联,并结合粒子滤波(PF)算法构建全新的SOC估算方法^[80]。这一改进直击传统模型忽略参数时变特性、滤波算法适应性差的关键问题,通过参数与SOC的动态绑定,让模型能实时跟随电池状态变化调整参数,再配合粒子滤波算法的优势,有效提升了终端电压预测精度与SOC估算精度,为PNGV模型的参数动态化优化奠定了重要基础。此后,南阳理工大学团队聚焦特定电池类型的应用需求,针对 LiFePO_4 刀片电池的特性进行PNGV模型的专项优化^[81]。该团队首次将SOC依赖型内阻融入PNGV模型,成功解决了传统模型忽略内阻时变特性的缺陷。这一成果不仅为电动汽车高功率电池的SOC估算提供了适配性强、实用性高的技术方案,更填补了刀片电池专用SOC估算模型的研究空白,让PNGV模型在特定电池类型的应用中迈出了关键一步。与此同时,印度哈里亚纳邦中央大学团队则从模型的多工况适配性与性能提升角度出发,对PNGV模型进行了进一步创新^[82]。该团队将自适应算法与体电容参数融入PNGV模型,构建出m-APNGV模型,成功突破了传统等效电路模型的静态参数局限。针对 LiFePO_4 电池的特性,m-APNGV模型实现了充电、放电、动态负载工况下的全场景精准模拟,且在性能上全面优于经典的Thevenin模型。这一成果为EVs电池管理系统提供了兼顾估算精度、实时性与多工况适配性的优质技术方案,进一步拓展了PNGV模型在复杂实际应用场景中的适用范围。上述团队围绕PNGV模型的改进形成了互补共进的技术脉络,持续推动着电池SOC估算技术向更高精度、更强适配性、更全场景覆盖的方向发展,为新能源汽车电池管理领域的技术进步提供了重要支撑。

2.2.2.4 非线性等效(GNL)模型

GNL模型是由清华大学汽车安全与节能国家重点实验室于2005年提出,是在PNGV模型基础上提出的改进模型^[83]。该模型不仅考虑了欧姆极化、电化学极化和浓差极化的影响,还融入了PNGV模型中的电容 C ,以涵盖与负载电流相关的OCV变化,同时其结构更贴近锂离子电池的内部特性。因

此, GNL 模型不仅在倍率响应特性方面具有良好的仿真性能, 还具有更高的仿真精度。目前, GNL 模型主要用于模拟锂离子电池的充放电特性, 进而实现对 SOC 和功率状态的估计。研究表明, 基于 GNL 模型的磷酸铁锂电池组自适应无迹卡尔曼滤波 (AUKF) 算法, 能够有效减小老化电池 SOC 的估计误差, 提升估计结果的准确性^[84]。GNL 模型因额外引入了自放电效应, 显著提升了计算复杂度, 其工程适用性有限, 多用于高精度离线仿真研究。

2.2.2.5 双极化(DP)模型

DP 模型是一种在经典戴维南等效电路基础上串联两个 RC 环节构建而成的锂电池等效电路模型, 也称为新型双极化电阻模型, 其核心优势在于优异的动态性能与高精度的 SOC 估算能力, 已成为 BMS 中关键技术工具^[85-86]。该模型的极化电阻能够随工作电流实时调整: 当电流稳定时, 极化电阻收敛于恒流工况下的稳态值; 当电流剧烈波动时, 极化电阻快速响应并收敛于瞬态工况下的瞬态值。这一动态特性使其更真实地模拟电池极化行为, 从而有效提升 SOC 估计的精度与可靠性^[87]。相比其他等效电路模型, DP 模型在模拟锂电池动态行为时不仅精度更高, 计算复杂度也相对均衡, 因此在锂离子电池 SOC 估算领域应用广泛。同时, 该模型将开路电压表征为 SOC 的函数, 使其非常适用于充电策略优化与充放电瞬态响应分析, 被视为 BMS 中最为灵活的方法之一。当前关于 DP 模型的研究主要聚焦于两方面: 一是进一步提升模型在极端工况下的精度与适应性; 二是在保证模型性能的同时, 通过模型降阶、参数优化等方式降低计算成本, 提升实时性。此外, 模型在电池老化、温度波动等实际复杂工况下的适应性与鲁棒性也成为未来研究的关键方向。随着机器学习技术的发展, 将数据驱动方法与基于物理的 DP 模型相融合的混合方法, 有望在电池管理、状态估算及新材料设计中发挥更重要的作用。

2.3 数据驱动的 SOC 估算

数据驱动的 SOC 估算技术通过直接测量电池电流、电压及温度等外部参数, 无需依赖复杂的电池内部模型或附加滤波器, 即可实现 SOC 的精准估算。该方法有效规避了传统模型方法中复杂的建模与参数辨识难题, 凭借其无模型依赖、灵活性

高、泛化能力强以及优异的非线性映射与自学习能力而受到广泛关注, 适用于各类电池体系。目前常用技术包括人工神经网络 (ANNs)、支持向量机 (SVM)、支持向量回归 (SVR) 和模糊逻辑 (FL) 等^[88-89]。由于此类方法不预设模型结构来模拟电池内部反应, 其建模过程高度依赖于充足的训练数据, 通过深入分析输入与输出变量间的内在关联, 挖掘电池外部特征参数中隐含的状态信息与动态演变规律, 进而实现 SOC 的精准估计。

2.3.1 人工神经网络(ANNs)

人工神经网络 (ANNs) 作为应用广泛的机器学习框架, 通过模拟生物神经网络的结构与功能, 采用监督学习方式, 无需依赖预设规则即可直接从数据中学习, 能够有效捕捉高度非线性系统的动态特性。鉴于锂离子电池具有复杂的非线性特性, ANNs 尤其适用于其故障诊断任务。在结构上, ANNs 可分为传统神经网络[如反向传播神经网络 (BPNN)、小波神经网络 (WNN)、径向基函数神经网络 (RBFNN) 和极限学习机 (ELM) 等, 通常仅含单隐藏层]和现代深度神经网络[如循环神经网络 (RNN)、卷积神经网络 (CNN)]^[90]。在 BMS 实际应用中, 常采用长短期记忆网络 (LSTM)、基于长短期记忆的循环神经网络 (RNN-LSTM) 等混合架构; 尽管 ANNs 存在众多变体, 但目前实际用于锂离子电池故障检测的主要为基础 ANN、LSTM、RNN 及其混合模型^[91]。ANNs 故障诊断通过从已知数据构建非线性黑箱模型, 再利用未见过的测试数据验证性能, 在充分离线训练后能有效区分电池的正常与异常状态。

2.3.2 支持向量机(SVM)

SVM 作为一种基于统计学习理论的机器学习方法, 其核心机制是通过在高维空间中构造最优超平面, 在分类问题中寻求使不同类别数据间隔最大化的决策边界^[92]。该方法在锂离子电池应用中展现出独特优势: 相较于神经网络, SVM 具有更强的泛化能力、更低的小样本依赖和更高的计算效率, 且无需建立电池等效模型即可实现状态估计与故障诊断^[93-94]。研究表明, 采用 SVM 进行 SOC 估算的误差可控制在 5% 以内^[95]。Yu 等^[96]采用最小二乘支持向量机 (LS-SVM) 将 SOC 在线估计的最大误差进一步降至 2%。Li 团队^[97]则通过粒子群算法 (PSO) 优化 SVM 参数, 结合交叉验证构建了高效

的非线性回归框架,进一步提升了估算精度与稳定性。尽管SVM需要求解复杂的二次规划问题,但其在电池领域的应用持续拓展,除基础SVM和支持向量回归(SVR)外,还衍生出核空间向量机(KSVM)等变体,目前已成为锂离子电池状态估计与故障诊断的重要工具。

2.3.3 支持向量回归(SVR)

SVR的基本思想基于最小化结构经验风险和模型复杂度。与神经网络方法相比,该方法具有更强的实用性,更易逼近SOC的真实值^[27]。在SVR应用中,核函数的选择至关重要,合适的核函数能够显著提升模型的泛化能力。通常选择高斯径向基函数作为核函数,以获得收敛速度快、参数少的简单非线性映射。Álvarez Antón等^[99]采用基于径向基函数核的SVR算法,在动态应力测试(DST)工况下实现了均方根误差(RMSE)低于0.71%的SOC精准预测。Li等^[97]采用的PSO-SVR模型,在正常工况下平均估计误差较经典SVM算法的误差优化明显,且具备更快的训练速度、更高的精度和更强的泛化能力。即便在电池故障状态下,结果仍处于可接受范围内,对工程应用具有参考意义。Hu等^[99]针对BMS提出了基于RBF核的SVR估计方案,创新性采用双步搜索技术优化训练并搜寻最优参数,在多种电动汽车行驶工况下均展现出优于神经网络模型的估计精度。Tian等^[100]针对电池数据多样性的问题,提出多模式集成支持向量回归(ME-SVR)方法,通过聚类划分数据子集并建立多个SVR模型进行加权集成,实验表明该算法能显著提升SOC估计的精度、稳定性与泛化能力。

2.3.4 模糊逻辑(FL)

FL方法为非线性复杂系统建模提供了有效工具,其核心优势在于能够将非线性特性与不确定性因素纳入SOC估计过程,通过融合电压、电流、温度等多源传感器信息,实现对SOC的精准估算^[101]。

在具体应用中,Salkind等^[102]提出一种实用的电池系统SOC估计方法,基于FL模型对通过阻抗谱法或库仑计数法获取的数据进行分析,具备较强的场景适用性。Zheng等^[103]则通过引入模糊逻辑控制器对滑模观测器进行改进,构建新型模糊逻辑滑模观测器用于SOC估计。测试结果表明,该算法不仅在SOC估计精度和收敛速度上表现优异,相

较于传统滑模观测器和扩展卡尔曼滤波方法,在抵抗电流与电压噪声干扰、抑制参数扰动等方面也展现出更强的鲁棒性。

上述数据驱动模型估算SOC方法的对比见表2。虽然数据驱动模型具备诸多优势,但仍存在明显不足:一是建模过程需要大量电池实验数据作为支撑,数据采集成本较高;二是当数据样本量较少时,模型估算精度相对一般,通用性较差;三是部分算法执行耗时较长,难以保证应用的实时性,这对电动汽车BMS的实时性要求而言是较大挑战,也成为其工程化落地的重要制约因素。除模型结构优化外,输入特征筛选也是提升数据驱动SOC估算效果的重要环节。有研究采用最大信息系数开展特征相关性分析,筛选电流、电压、能量等强相关输入特征,再结合优化算法改进最小二乘支持向量机,并搭配自适应卡尔曼滤波构建闭环估算框架。该方法在变温度混合工况与信号噪声干扰条件下实现了高鲁棒性的SOC估算,但其训练过程仍依赖大规模数据集^[104]。除传统电压、电流、温度等电气类特征之外,部分研究尝试引入电池力学响应信号扩充特征维度,针对磷酸铁锂电池OCV-SOC长电压平台导致估算精度恶化的痛点,将电芯膨胀力与电流、温度信号融合,构建CNN-BiLSTM混合网络挖掘多维时序特征,有效改善电压平台区间的SOC估算效果,但该方案需要额外配置力学传感器,会增加BMS硬件成本与系统复杂度^[105]。

2.4 基于物理模型与数据驱动的SOC估算方法

为克服单一模型方法的固有局限,物理模型受简化假设影响易产生理论误差,而数据驱动模型因黑箱特性存在可解释性差、泛化能力不足等问题,融合物理模型与数据驱动模型已成为实现高精度、高鲁棒性锂离子电池SOC估算的主流研究方向。该研究方法的核心在于协同与互补,利用多物理模型(涵盖电化学、热、机械等多尺度机理)所提供的系统先验知识、状态演化框架及物理规律约束,为状态估计奠定可解释的坚实基础。同时,借助机器学习和深度学习等数据驱动技术强大的非线性拟合、特征挖掘与自适应能力,来补偿机理模型未涵盖的复杂动态、老化效应及工况不确定性,最终实现物理可解释性与数据高精度的有机统一。

目前,基于物理模型与数据驱动的融合方法已在SOC估算领域展现出显著优势。相关研究中,

表2 几种数据驱动的 SOC 估算方法对比

Table 2 Comparison of several data-driven SOC estimation methods

方法	原理特点	优点	缺点	适用场景与备注
ANN	模拟神经网络，通过监督学习从数据中学习非线性动态特性；包括传统神经网络和深度神经网络	无须预设模型规则，直接从数据中学习，能够捕捉高度非线性系统的动态特性，适用于复杂非线性系统如锂离子电池	需要大量训练数据，模型为黑箱，解释性较差，深度网络结构复杂，训练时间长	适用于故障诊断、状态估计，常用 LSTM、RNN 等混合架构进行时序特征提取
SVM	基于统计学习理论，通过构造最优超平面实现数据分类与回归；可采用核函数处理非线性问题	泛化能力强，对小样本数据适应性较好，计算效率较高，无需建立电池等效模型	需要求解二次规划问题，计算复杂度随数据量增加，核函数与参数选择对性能影响大	适用于 SOC 估计、故障诊断，常用 LS-SVM、PSO-SVM 等改进方法提升精度
SVR	基于结构风险最小化，通过核函数映射实现非线性回归；常用高斯径向基函数作为核函数	泛化能力好，易于逼近真实值，参数较少，收敛速度较快，对噪声具有一定鲁棒性	核函数选择敏感，大数据集下训练速度可能下降	适用于动态工况下的 SOC 预测，常通过参数优化提升性能
FL	基于模糊推理，将非线性与不确定性纳入模型，通过多源信息融合实现 SOC 估计	能够处理不确定性与非线性，无须精确数学模型，结合其他方法可提升鲁棒性	规则依赖专家知识，设计复杂，规则过多时推理效率降低	适用于多传感器信息融合的 SOC 估计，常与阻抗谱、滑模观测器等方法结合使用

Charkhgard 和 Farrokhi^[106]将径向基函数神经网络（RBFNN）与扩展卡尔曼滤波（EKF）结合，通过 RBFNN 离线训练自主采集数据集及 EKF 自适应估计荷电状态，最终获得小于 3% 的均方根误差（RMSE）。Huynh 和 Won^[107]提出基于反向传播神经网络（BPNN）的 SOC 估计方法，结合无迹卡尔曼滤波（UKF）降低噪声干扰，该方法在不同环境温度和行驶循环工况下表现稳定，RMSE 控制在 5% 以内。Chen 等^[108]开发了基于前馈神经网络（FFNN）的增强型电池模型，结合 EKF 实现 SOC 评估，模型可快速跟踪真实 SOC，估计误差低于 2%。下文将基于四种最具代表性的融合策略架构，对相关研究进行系统性分类与深入分析。

2.4.1 物理模型初估协同数据驱动模型误差修正

该策略采用串行级联架构，工作流程清晰直观。首先由机理清晰、计算高效的物理模型（多为 ECM）结合自适应滤波算法（如 EKF、UKF）进行 SOC 的初步估计；随后，针对初步估计结果因模型简化、参数时变或环境扰动而产生的系统性残差，引入数据驱动模型（如神经网络、相关向量机）作为智能补偿器，对残差在线学习与动态修正。这种先机理-后数据的模式，本质上是将数据驱动模型定位为物理模型在高维非线性误差空间中的补充与校准器。

该策略的优势在于结构模块化，逻辑清晰且易于工程化落地实现。Mao 等^[109]基于该路线提出具体方案：即在正常工况下，采用二阶 RC 模型结合全局遗忘因子递推最小二乘法（FFRLS）与 UKF 完成参数辨识与 SOC 初步估计；为克服 ECM 在低温环境下的性能瓶颈，引入相关向量机（RVM）进行

误差补偿，并通过贝叶斯概率融合算法整合两类模型输出，实现高精度 SOC 估计。Wang 等^[110]构建了机理建模-数据补偏的 SOC 估计框架，采用改进自适应扩展卡尔曼滤波（AEKF）与动态 FFRLS 算法，实现多温度、多工况下的基础 SOC 估计；针对 AEKF 因忽略高阶项导致的系统误差，设计了滑动窗口多对一结构的改进 LSTM，依托其优异的时间序列特征提取能力进行误差补偿，显著提升了复杂工况下的估计稳定性。Murawwat 等^[90]的研究进一步验证了该策略的有效性，以二阶 RC 模型表征电池动态特性，结合 UKF 算法完成初始 SOC 估计，并引入深度前馈神经网络（DFNN）对 UKF 输出的残差进行动态追踪与修正，实现 SOC 估计精度的实时优化，为动态工况下的状态监测提供了可靠方案。

2.4.2 物理模型特征提取协同数据驱动模型状态估计

与串行补偿不同，该策略强调前端融合。其核心逻辑是：利用物理模型的机理分析能力，从原始测量数据（电流、电压、温度）中提取或生成具有明确物理意义且与 SOC 强相关的高级特征，作为数据驱动模型的输入，而非直接使用原始数据。这些特征可包括在线辨识的模型参数（如欧姆内阻、极化时间常数）、反映内部状态的中间变量（如开路电压 OCV 的估计值）或基于物理方程推导出的健康指标。

基于这一思路，Tang 等^[111]设计了一种基于神经网络（NN）模型与 ECM 融合的 SOC 估计方法。该方法通过 ECM 在线辨识欧姆内阻、极化电阻/电容等参数，将这些参数与电流、电压等共同作为

NN输入,使NN能够学习基于物理特征的精准SOC映射关系。Feng等^[112]提出ECM与前馈神经网络、UKF相结合的混合模型,利用电化学-热模型提取反映电池内部状态的特征,结合前馈NN和UKF,在-10~40℃温度范围及10C放电倍率下取得良好性能。Feng等^[112]通过贝叶斯原理将ECM与RVM深度融合。该方法利用ECM构建状态空间结构,并由RVM基于ECM的输出进行回归估计,再借助UKF算法,最终实现了宽温度范围内的高精度SOC估计。Dong等^[113]将ECM作为外生输入与自回归外生模型(ARXM)融合以增强其预测能力,该混合模型结合序贯蒙特卡洛滤波(SMCF),在不同工况下实现±3%以内的SOC估计误差。

2.4.3 物理模型约束解释协同数据驱动模型状态估计

该策略以数据驱动模型为状态估计核心,同时引入物理模型作为约束机制与解释性校验器,从而有效抑制数据驱动模型易过拟合、预测结果可能违背物理规律的问题。该思路是提升SOC估计可解释性与泛化能力的关键,并在物理信息神经网络(PINN)范式中得到了成功实践。Guo等^[114]开发的SA-NN-FOO模型与Wang等^[115]构建的PIRNN模型,均将分数阶电池模型的物理规律嵌入训练过程作为约束,迫使神经网络输出符合电池内在机理。这种方法不仅保障了估计结果的物理合理性,也显著增强了算法的可靠性与鲁棒性。

2.4.4 物理-数据模型并行预测与融合机制

该策略采用并行协同架构,使物理模型与数据驱动模型独立、并行地进行状态预测,进而通过加权平均、贝叶斯推理、滤波算法或多尺度融合等高级融合机制将两者输出进行最优整合。该架构旨在最大程度保留两类模型的独立见解,并通过融合平滑单一模型的偶然偏差,实现协同增效,尤其适用于多状态联合估计、预测-校正闭环系统等复杂任务。Liu等^[116]提出多尺度联合状态估计方案,将数据驱动的自回归模型(AR)与机理型ECM相结合,构建AR-MM模型以整合两类模型特征,用于表征电池组整体特性;同时设计Rint-DM模型,利用内阻差异(ΔR_0)反映单体与电池组间性能偏差,并采用多尺度 H_∞ 滤波算法在不同时间尺度下联合估计SOC与容量,有效提升了状态估计的精度与可靠性。Zhang等^[117]构建SOH与SOC联合估计的

闭环框架:采用门控循环单元(GRU)网络完成SOH一步预测,并将其作为观测方程输入;以安时积分法为状态方程,结合PF实现SOC估计。为抑制误差累积,该框架在多次充放电循环后设置检查点,利用增量容量峰值特征修正SOH预测结果,形成预测-修正的闭环控制机制。

2.4.5 SOH-SOC 联合估计

SOC与SOH之间存在强耦合关系,SOC的求解高度依赖电池当前实际可用容量,而该参量正是SOH的核心表征指标;反过来,SOH辨识又需要准确的SOC时序序列作为输入。电池老化带来的容量衰减、内阻增长会同时改变两类状态的演化规律,进而形成双向耦合误差。同时两类状态的演化时间尺度存在明显差异:SOC呈秒级快速波动,SOH则表现为缓慢退化,这也使得联合估计框架设计需要在估算精度、计算开销与实时性之间做出多重权衡。

当前SOC-SOH联合估计可从估计架构与建模范式两个维度分类,两类维度可相互组合。从估计架构上可分为串行解耦估计与并行联合估计;在建模范式上包含纯机理、纯数据驱动以及模型-数据融合方案。①串行解耦估计:先完成SOC估算,再依托SOC输出序列辨识可用容量与内阻,进一步求解SOH。该方案计算逻辑简单,工程实现难度低,但SOC的估算误差会直接传递并累积到SOH辨识结果。②并行联合状态估计:将SOC、可用容量、内阻等一并作为系统状态变量,借助滤波算法同步迭代输出SOC与SOH,能够抑制误差传递问题;但状态维度增加会带来算力开销的显著上升。③模型-数据融合属于建模范式,可嵌入上述两种估计架构。依托物理模型构建状态估计框架,利用数据驱动算法拟合老化诱发的模型参数漂移,在保留物理可解释性的同时补偿机理模型的偏差,是实现电池全生命周期下两类状态协同更新的重要发展方向。

现有联合估计算法在实验室标定工况下可以取得较好效果,但在车载复杂动态工况、宽温域、老化不一致电池模组条件下,算法鲁棒性仍然是亟待解决的难题。与此相关,在SOH与剩余使用寿命预测领域,部分研究将混合专家时序网络与深度证据回归相结合,可通过单次前向推理实现预测输出,并区分数据噪声带来的偶然不确定性与模型能

力局限带来的认知不确定性，为 SOC-SOH 联合估计过程中的预测风险与可信度评估提供了新的技术思路^[118]。在混合驱动联合估计方面，也有研究构建简化电化学模型与 LSTM 结合的框架，通过参数灵敏度分析筛选模型敏感参数并开展自适应在线更新，采用多时间尺度交互更新策略实现全生命周期下 SOC-SOH 协同估算，在一定程度上缓解了两类状态之间的双向耦合干扰^[119]。面向实车电池包场景，有研究基于实车运行数据集，综合容量、欧姆

内阻、单体电压与包内温度不一致性多项老化指标，采用熵权法结合模糊矩阵实现 SOH 多维度综合评估，同时构建优化梯度提升树模型开展剩余寿命预测，为兼顾单体差异性的电池包层级健康状态评价提供了可行思路^[120]。

2.5 模型-数据融合策略对比与总结

上述四种混合策略均以物理机理与数据驱动深度融合为核心思路展开，但在融合逻辑、性能表现与适用场景上存在显著差异，具体对比如表 3 所示。

表 3 混合策略对比表
Table 3 Comparison of hybrid strategies

对比维度	串行补偿	特征提取	约束嵌入	并行融合
核心逻辑	物理模型初估，数据驱动误差修正	物理模型提取特征，驱动数据模型输入	物理规律作为约束嵌入数据模型	双模型并行预测，智能融合决策
关键优势	结构简单，易于实现	提升输入质量，增强可解释性	确保物理合理性，泛化能力强	鲁棒性高，抗扰动能力强
主要挑战	补偿器设计依赖经验	有效特征的提取与构造需依托电池机理与工程经验	模型训练复杂，收敛难度大	计算复杂度高、融合规则设计难度大
典型技术	RVM 与 UKF LSTM 与 AEKF	ECM 参数与 NN 电化学特征与 NN	PINN 物理约束神经网络	多尺度滤波 粒子滤波与 GRU
数据需求	中等	中等	低	高
计算复杂度	低-中	中	高	最高
适用场景	特定工况误差补偿	特征明确的中等复杂度场景	高可靠性要求，数据稀缺场景	高鲁棒性要求的复杂系统

四种融合策略体现了从轻量级应用到深度范式创新的技术演进。串行补偿与特征提取属于应用导向的轻量化融合，采用模块化松散耦合架构，分别通过误差修正和特征强化两条路径解决具体工程痛点，易于落地且针对性强。物理约束嵌入与并行融合则指向更深层的范式创新：前者将物理机理内化为模型原生约束，从源头规避数据驱动模型的黑箱问题，保障结果可信度；后者通过系统级架构重构实现多维信息协同，获得鲁棒性更强的估计性能。

总体而言，各策略在精度、复杂度、可解释性与数据依赖性之间存在不可避免的固有权衡。若追求更高物理一致性与泛化能力，往往需承担更高计算成本与实现难度，而结构简洁、易工程化的方案，其极端工况自适应能力常受局限。因此，融合策略的选型本质上是面向具体应用场景，在估计性能、计算效率与运行可靠性之间进行多目标优化权衡，这一技术谱系的演进逻辑，也清晰映射出 SOC 估算领域从“模型简单叠加”向“物理机理与数据智能深度融合”的发展趋势。

综上，各类融合策略在估算精度、计算复杂度、模型可解释性及数据需求之间存在固有的平衡

关系。物理一致性强、泛化性能好的方案通常计算成本高、实现难度大；而结构简单、易于工程落地的方法，在复杂与极端工况下的自适应能力相对有限。因此，在实际应用中选择合适的融合策略，本质上是针对具体场景，合理平衡估计性能、计算效率和可靠性。上述技术路线演进表明，SOC 估算正从简单的模型叠加，向物理机理与数据智能的深度融合演进。

3 研究趋势

现有综述的研究展望多偏重宏观概念描述，本文结合 SOC 估算领域当前亟待突破的科学与工程瓶颈，提出以下六个具体的研究方向：

（1）机理模型简化与精度的平衡问题。面向车载有限算力，如何在保留电化学模型核心物理完备性的前提下实现有效降阶；解决简化模型在低温、大倍率及老化电池工况下的精度退化难题。

（2）模型-数据融合架构的轻量化设计。当前物理信息神经网络等深度融合算法仿真精度高，但计算开销大。已有研究开始探索面向车规级嵌入式处理器的轻量化状态估算模型，在保持高估算精度

的同时将参数量压缩至 1.1M 级别,初步验证了复杂算法在资源受限 BMS 硬件上部署的可行性^[121]。但如何设计轻量化融合架构,兼顾物理约束、估算精度与车载嵌入式算力约束,仍是亟待解决的现实问题。

(3) 老化-工况耦合条件下的 SOC 自适应更新。电池全生命周期内持续发生容量衰减与内阻漂移,如何摆脱对大量离线标定的依赖,实现在线自适应更新;解决新老电池混用、衰减不一致条件下单体至模组层级的 SOC 协同估算问题。

(4) 面向车载非理想采样的鲁棒性算法。实车传感器普遍存在噪声干扰、信号跳变及短时数据丢失等问题,如何提升 SOC 估算算法在非理想采样条件下的抗干扰能力与估算稳定性。

(5) SOC-SOH-SOF 多状态联合估计。构建统一的多状态估计框架,抑制状态间误差的相互传递与耦合放大;面向模组与电池包层级,解决单体不一致条件下的模组 SOC 精准估算难题。

(6) 云边协同的 SOC 估算架构。边缘端 BMS 完成实时 SOC 基础估算,云端利用海量实车运行数据完成模型迭代与参数优化,并将更新后的模型下发至边缘端,实现电池全生命周期的持续学习与进化^[122]。数字孪生、迁移学习、物理信息神经网络等跨学科技术为上述问题提供了新的解决工具,但相关研究不应停留在仿真验证层面,亟需推进实车测试,推动 SOC 估算算法从实验室走向 BMS 工程落地。

4 结 论

本文梳理了电动汽车锂离子电池 SOC 估算的四类主流方法,着重对比分析模型-数据融合四类典型架构的优势与现实取舍,同时结合车载实际工况,对模组 SOC 估算、老化与 SOC 的耦合关系、SOC-SOH 联合估计等工程问题开展讨论,得到如下结论:

(1) 不同 SOC 估算方法各有优劣,不存在普适的最优方案。可测参量经验估算法实现简单,但累积误差很难彻底抑制;模型驱动法物理机理清晰,但实际效果很大程度上取决于电池建模质量和参数辨识水平;纯数据驱动法对非线性问题的拟合效果突出,但普遍面临泛化能力不足、可解释性差的问题。采用模型-数据融合思路,能够弥补单一

技术路线的固有短板。其中串行补偿、特征提取两类架构更容易在现有 BMS 基础上落地改造;物理约束嵌入和并行融合虽然综合表现更好,但计算开销偏大,现阶段更多用于仿真研究及算力充裕的控制器平台。

(2) 现阶段 SOC 估算仍面临不少亟待解决的科学与工程难题:高阶电化学模型降阶处理后,估算精度和车载算力之间很难兼顾;电池老化与复杂工况共同作用下,模型参数如何实现自适应更新仍是难点;受单体不一致性影响,模组层级 SOC 的准确表征与估算一直是工程难点;开展 SOC-SOH 多状态联合估计时,误差互相传递耦合,难以有效隔离;深度学习类算法的轻量化部署,以适应车规级嵌入式硬件,同样存在现实技术障碍。

(3) 技术选型应结合具体应用条件综合权衡。面向成本受限的普通车载 BMS,等效电路模型搭配卡尔曼滤波仍是比较务实的选择,辅以 OCV 定期校正,也可引入轻量级数据驱动模块做误差补偿。对于算力充足的高性能 BMS,可尝试物理约束嵌入或并行融合方案,实现 SOC 与 SOH 协同估计。在实验室机理研究阶段,P2D 等阶电化学模型更为合适,可作为基准,用于评判车载算法能够达到的精度上限。

总体来看,SOC 估算不能只看重理想实验条件下的仿真指标,还应充分考虑实车复杂工况、电池全生命周期老化、模组单体不一致等现实约束。推动电池机理研究、数据智能算法与车载工程实践相结合,对下一代智能 BMS 的发展具有重要的现实意义。

参 考 文 献

- [1] GAO Z W, LAN T Y, YIN H S, et al. Development and commercial application of lithium-ion batteries in electric vehicles: A review[J]. Processes, 2025, 13(3): 756. DOI:10.3390/pr13030756.
- [2] 林宗虎. 气液两相流和沸腾传热[M]. 西安: 西安交通大学出版社, 2003.
LIN Z H. Gas liquid two phase flow and boiling heat transfer[M]. Xi'an: Xi'an Jiaotong University Press, 2003.
- [3] YANG W Q, LIN Y T, DU J L, et al. Integrating electrochemical and thermal models for improved lithium-ion battery energy storage system heat dissipation[J]. Chinese Journal of Chemical Engineering, 2025, 85: 393-407. DOI:10.1016/j.cjche.2025.02.033.
- [4] KHAN F M N U, RASUL M G, SAYEM A S M, et al. Maximizing energy density of lithium-ion batteries for electric vehicles: A critical review[J]. Energy Reports, 2023, 9: 11-21. DOI:10.1016/j.

- egyr.2023.08.069.
- [5] LIU G X, WAN W, NIE Q, et al. Controllable long-term lithium replenishment for enhancing energy density and cycle life of lithium-ion batteries[J]. *Energy & Environmental Science*, 2024, 17(3): 1163-1174. DOI:10.1039/d3ee03740a.
- [6] FAN T, LIANG W C, GUO W, et al. Life cycle assessment of electric vehicles' lithium-ion batteries reused for energy storage [J]. *Journal of Energy Storage*, 2023, 71: 108126. DOI:10.1016/j.est.2023.108126.
- [7] MIAO Y P, LIU L L, ZHANG Y P, et al. An overview of global power lithium-ion batteries and associated critical metal recycling [J]. *Journal of Hazardous Materials*, 2022, 425: 127900. DOI: 10.1016/j.jhazmat.2021.127900.
- [8] POSSO RIVERA F, ZALAMEA J, ESPINOZA J L, et al. Sustainable use of spilled turbinable energy in Ecuador: Three different energy storage systems[J]. *Renewable and Sustainable Energy Reviews*, 2022, 156: 112005. DOI: 10.1016/j.rser.2021.112005.
- [9] CHAOU I, GOLBON N, HMOUZ I, et al. Lyapunov-based adaptive state of charge and state of health estimation for lithium-ion batteries[J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(3): 1610-1618. DOI:10.1109/TIE.2014.2341576.
- [10] LU L G, HAN X B, LI J Q, et al. A review on the key issues for lithium-ion battery management in electric vehicles[J]. *Journal of Power Sources*, 2013, 226: 272-288. DOI: 10.1016/j.jpowsour.2012.10.060.
- [11] CHEN Z, ZHAO H Q, ZHANG Y J, et al. State of health estimation for lithium-ion batteries based on temperature prediction and gated recurrent unit neural network[J]. *Journal of Power Sources*, 2022, 521: 230892. DOI: 10.1016/j.jpowsour.2021.230892.
- [12] TANG X P, GAO F R, ZOU C F, et al. Load-responsive model switching estimation for state of charge of lithium-ion batteries[J]. *Applied Energy*, 2019, 238: 423-434. DOI:10.1016/j.apenergy.2019.01.057.
- [13] LIN S L. Deep learning-based state of charge estimation for electric vehicle batteries: Overcoming technological bottlenecks [J]. *Heliyon*, 2024, 10(16): e35780. DOI:10.1016/j.heliyon.2024.e35780.
- [14] ZHOU L, LAI X, LI B, et al. State estimation models of lithium-ion batteries for battery management system: Status, challenges, and future trends[J]. *Batteries*, 2023, 9(2): 131. DOI: 10.3390/batteries9020131.
- [15] MADANI S S, SHABEER Y, NAIR A S, et al. Advances in battery modeling and management systems: A comprehensive review of techniques, challenges, and future perspectives[J]. *Batteries*, 2025, 11(11): 426. DOI:10.3390/batteries11110426.
- [16] JIN L, LI S, HU B. RNN models for dynamic matrix inversion: A control-theoretical perspective[J]. *IEEE Transactions on Industrial Informatics*, 2018, 14(1): 189-199. DOI:10.1109/TII.2017.2717079.
- [17] ZUBI G, DUFO-LÓPEZ R, CARVALHO M, et al. The lithium-ion battery: State of the art and future perspectives[J]. *Renewable and Sustainable Energy Reviews*, 2018, 89: 292-308. DOI: 10.1016/j.rser.2018.03.002.
- [18] HOW D N T, HANNAN M A, HOSSAIN LIPU M S, et al. State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review[J]. *IEEE Access*, 2019, 7: 136116-136136. DOI:10.1109/ACCESS.2019.2942213.
- [19] XU G N, DU X W, LI Z J, et al. Reliability design of battery management system for power battery[J]. *Microelectronics Reliability*, 2018, 88: 1286-1292. DOI:10.1016/j.microrel.2018.06.115.
- [20] CHENG K W E, DIVAKAR B P, WU H J, et al. Battery-management system (BMS) and SOC development for electrical vehicles[J]. *IEEE Transactions on Vehicular Technology*, 2011, 60(1): 76-88. DOI:10.1109/TVT.2010.2089647.
- [21] ZHENG Y J, CUI Y F, HAN X B, et al. A capacity prediction framework for lithium-ion batteries using fusion prediction of empirical model and data-driven method[J]. *Energy*, 2021, 237: 121556. DOI:10.1016/j.energy.2021.121556.
- [22] CAI T, VALECHA P, TRAN V, et al. Detection of Li-ion battery failure and venting with carbon dioxide sensors[J]. *eTransportation*, 2021, 7: 100100. DOI:10.1016/j.etrans.2020.100100.
- [23] WILDFEUEER L, LIENKAMP M. Quantifiability of inherent cell-to-cell variations of commercial lithium-ion batteries[J]. *eTransportation*, 2021, 9: 100129. DOI:10.1016/j.etrans.2021.100129.
- [24] KRISHNA T N V, KUMAR S V S V P D, SRINIVASA RAO S, et al. Powering the future: Advanced battery management systems (BMS) for electric vehicles[J]. *Energies*, 2024, 17(14): 3360. DOI: 10.3390/en17143360.
- [25] NYAMATHULLA S, DHANAMJAYULU C. A review of battery energy storage systems and advanced battery management system for different applications: Challenges and recommendations [J]. *Journal of Energy Storage*, 2024, 86: 111179. DOI:10.1016/j.est.2024.111179.
- [26] DAI H F, JIANG B, HU X S, et al. Advanced battery management strategies for a sustainable energy future: Multilayer design concepts and research trends[J]. *Renewable and Sustainable Energy Reviews*, 2021, 138: 110480. DOI: 10.1016/j.rser.2020.110480.
- [27] PLETT G L. Battery management systems, Volume I: Battery modeling[M]. Norwood: Artech House, 2015.
- [28] LIU Y F, HE Y J, BIAN H D, et al. A review of lithium-ion battery state of charge estimation based on deep learning: Directions for improvement and future trends[J]. *Journal of Energy Storage*, 2022, 52: 104664. DOI:10.1016/j.est.2022.104664.
- [29] ZHANG M Y, FAN X B. Review on the state of charge estimation methods for electric vehicle battery[J]. *World Electric Vehicle Journal*, 2020, 11(1): 23. DOI:10.3390/wevj11010023.
- [30] SELVARAJ V, VAIRAVASUNDARAM I. A comprehensive review of state of charge estimation in lithium-ion batteries used in electric vehicles[J]. *Journal of Energy Storage*, 2023, 72: 108777. DOI:10.1016/j.est.2023.108777.
- [31] TRUCHOT C, DUBARRY M, LIAW B Y. State-of-charge estimation and uncertainty for lithium-ion battery strings[J].

- Applied Energy, 2014, 119: 218-227. DOI: 10.1016/j.apenergy.2013.12.046.
- [32] PEI L, LU R G, ZHU C B. Relaxation model of the open-circuit voltage for state-of-charge estimation in lithium-ion batteries[J]. IET Electrical Systems in Transportation, 2013, 3(4): 112-117. DOI:10.1049/iet-est.2013.0020.
- [33] FARMANN A, SAUER D U. A study on the dependency of the open-circuit voltage on temperature and actual aging state of lithium-ion batteries[J]. Journal of Power Sources, 2017, 347: 1-13. DOI:10.1016/j.jpowsour.2017.01.098.
- [34] PILLAI P, SUNDARESAN S, KUMAR P, et al. Open-circuit voltage models for battery management systems: A review[J]. Energies, 2022, 15(18): 6803. DOI:10.3390/en15186803.
- [35] ZHANG B, LU C H, LIU J H. Combination algorithm for state of charge estimation[C]//2013 International Conference on Communication Systems and Network Technologies. April 6-8, 2013, Gwalior, India. IEEE, 2013: 865-867. DOI: 10.1109/CSNT.2013.186.
- [36] 杨文荣, 朱赛飞, 陈阳, 等. 基于改进安时积分法估计锂离子电池组 SOC[J]. 电源技术, 2018, 42(1):183-184.
- YANG W R, ZHU S F, CHEN Y, et al. SOC estimation of lithium-ion battery based on improved ampere-hour integral method[J]. Chinese Journal of Power Sources, 2018, 42(1): 183-184.
- [37] NG K S, MOO C S, CHEN Y P, et al. Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries[J]. Applied Energy, 2009, 86(9): 1506-1511. DOI:10.1016/j.apenergy.2008.11.021.
- [38] 刘建伟, 吴刚, 石春. 基于可用容量估算和电量增量曲线的安时积分荷电状态估算方法[J]. 仪表技术, 2021(3): 33-37.
- LIU J W, WU G, SHI C. Amp-hour integral state-of-charge estimation method based on available capacity estimation and electric quantity increment curve[J]. Instrumentation Technology, 2021(3): 33-37.
- [39] 罗勇, 祁朋伟, 黄欢, 等. 基于容量修正的安时积分 SOC 估算方法研究[J]. 汽车工程, 2020, 42(5): 681-687.
- LUO Y, QI P W, HUANG H, et al. Research on ampere-hour integral SOC estimation method based on capacity correction[J]. Automotive Engineering, 2020, 42(5): 681-687.
- [40] 谢路耀, 华思聪, 陈怡, 等. 基于容量修正的安时积分法研究[J]. 浙江工业大学学报, 2021, 49(4): 403-408.
- XIE L Y, HUA S C, CHEN Y, et al. Research on ampere hour integral method based on capacity correction[J]. Journal of Zhejiang University of Technology, 2021, 49(4): 403-408.
- [41] ZHOU W L, ZHENG Y P, PAN Z J, et al. Review on the battery model and SOC estimation method[J]. Processes, 2021, 9(9): 1685. DOI:10.3390/pr9091685.
- [42] 王宇航, 王顺利, 潘小琴, 等. 基于扩展卡尔曼的锂离子电池 SOC 估算研究[J]. 自动化与仪表, 2018, 33(8): 76-79, 99.
- WANG Y H, WANG S L, PAN X Q, et al. SOC estimation research of lithium-ion battery based on the extended Kalman[J]. Automation & Instrumentation, 2018, 33(8): 76-79, 99.
- [43] GUO D X, YANG G, FENG X N, et al. Physics-based fractional-order model with simplified solid phase diffusion of lithium-ion battery[J]. Journal of Energy Storage, 2020, 30: 101404. DOI: 10.1016/j.est.2020.101404.
- [44] LIU C H, HU M H, JIN G Q, et al. State of power estimation of lithium-ion battery based on fractional-order equivalent circuit model[J]. Journal of Energy Storage, 2021, 41: 102954. DOI: 10.1016/j.est.2021.102954.
- [45] 司伟, 冯长江, 黄天辰. 基于内阻法修正的蓄电池卡尔曼滤波 SOC 估算[J]. 计算机测量与控制, 2018, 26(12): 185-189.
- SI W, FENG C J, HUANG T C. SOC estimation of battery calman filter based on internal resistance correction[J]. Computer Measurement & Control, 2018, 26(12): 185-189.
- [46] 张方亮, 黄泽波, 李占锋. 不同放电倍率下锂电池 SOC 估算分析研究[J]. 机械设计与制造, 2018(6): 262-265.
- ZHANG F L, HUANG Z B, LI Z F. The analysis of lithium battery SOC estimation under different discharge rate[J]. Machinery Design & Manufacture, 2018(6): 262-265.
- [47] HUANG K, GUO Y F, LI Z G. Overview of state-of-charge estimation for power lithium-ion batteries[J]. Power Technology, 2018, 42(9): 1398-1401.
- [48] WANG L, ZHAO X W, DENG Z W, et al. Application of electrochemical impedance spectroscopy in battery management system: State of charge estimation for aging batteries[J]. Journal of Energy Storage, 2023, 57: 106275. DOI: 10.1016/j.est.2022.106275.
- [49] JAFARI M, GAUCHIA A, ZHANG K L, et al. Simulation and analysis of the effect of real-world driving styles in an EV battery performance and aging[J]. IEEE Transactions on Transportation Electrification, 2015, 1(4): 391-401. DOI:10.1109/tte.2015.2483591.
- [50] CHEN Y, HUO W W, LIN M Y, et al. Simulation of electrochemical behavior in Lithium ion battery during discharge process[J]. PLoS One, 2018, 13(1): e0189757. DOI:10.1371/journal.pone.0189757.
- [51] 赵珈卉, 田立亭, 程林. 锂离子电池状态估计与剩余寿命预测方法综述[J]. 发电技术, 2023, 44(1): 1-17.
- ZHAO J H, TIAN L T, CHENG L. Review on state estimation and remaining useful life prediction methods for lithium-ion battery[J]. Power Generation Technology, 2023, 44(1): 1-17.
- [52] BARIK S, SARAVANAN B. Recent developments and challenges in state-of-charge estimation techniques for electric vehicle batteries: A review[J]. Journal of Energy Storage, 2024, 100: 113623. DOI:10.1016/j.est.2024.113623.
- [53] DUAN X D, HU D Y, CHEN W H, et al. Electrochemical modeling of fast charging in batteries[J]. Advanced Energy Materials, 2024, 14(26): 2400710. DOI:10.1002/aenm.202400710.
- [54] DINI P, COLICELLI A, SAPONARA S. Review on modeling and SOC/SOH estimation of batteries for automotive applications[J]. Batteries, 2024, 10(1): 34. DOI:10.3390/batteries10010034.
- [55] SMITH K A, RAHN C D, WANG C Y. Model-based electrochemical estimation of lithium-ion batteries[C]//2008 IEEE International Conference on Control Applications. September 3-5, 2008. San Antonio, TX, USA. IEEE, 2008: 714-719. DOI:10.1109/cca.2008.4629589.

- [56] SMITH K A, RAHN C D, WANG C Y. Control oriented 1D electrochemical model of lithium ion battery[J]. *Energy Conversion and Management*, 2007, 48(9): 2565-2578. DOI: 10.1016/j.enconman.2007.03.015.
- [57] WANG J R, MENG J H, PENG Q, et al. Lithium-ion battery state-of-charge estimation using electrochemical model with sensitive parameters adjustment[J]. *Batteries*, 2023, 9(3): 180. DOI: 10.3390/batteries9030180.
- [58] FANG H Z, WANG Y B, SAHINOGLU Z, et al. Adaptive estimation of state of charge for lithium-ion batteries[C]//2013 American Control Conference. June 17-19, 2013. Washington, DC. IEEE, 2013: 3485-3491. DOI:10.1109/acc.2013.6580370.
- [59] WANG X X, YE P L, LIU S R, et al. Research progress of battery life prediction methods based on physical model[J]. *Energies*, 2023, 16(9): 3858. DOI:10.3390/en16093858.
- [60] XIONG R, CAO J Y, YU Q Q, et al. Critical review on the battery state of charge estimation methods for electric vehicles[J]. *IEEE Access*, 2018, 6: 1832-1843. DOI:10.1109/access.2017.2780258.
- [61] DOYLE M, NEWMAN J, GOZDZ A S, et al. Comparison of modeling predictions with experimental data from plastic lithium ion cells[J]. *Journal of the Electrochemical Society*, 1996, 143(6): 1890-1903. DOI:10.1149/1.1836921.
- [62] DOYLE M, FULLER T F, NEWMAN J. Modeling of galvanostatic charge and discharge of the lithium/polymer/insertion cell[J]. *Journal of the Electrochemical Society*, 1993, 140(6): 1526-1533. DOI:10.1149/1.2221597.
- [63] HAN X B, OUYANG M G, LU L G, et al. Simplification of physics-based electrochemical model for lithium ion battery on electric vehicle. Part II: Pseudo-two-dimensional model simplification and state of charge estimation[J]. *Journal of Power Sources*, 2015, 278: 814-825. DOI:10.1016/j.jpowsour.2014.08.089.
- [64] KANG X, SHI W, CHEN H. Parameter identification based on simplified electrochemical model of lithium ion battery[J]. *Energy Storage Science and Technology*, 2020, 9(3): 969-977.
- [65] HE W, HAN T, SONG H Q, et al. An extended single-particle model of lithium-ion batteries based on simplified solid-liquid diffusion process[J]. *iScience*, 2024, 27(11): 110764. DOI:10.1016/j.isci.2024.110764.
- [66] REN L C, ZHU G R, KANG J Q, et al. An algorithm for state of charge estimation based on a single-particle model[J]. *Journal of Energy Storage*, 2021, 39: 102644. DOI:10.1016/j.est.2021.102644.
- [67] WU J H, AI W L. Simplified pseudo two-dimensional model for stress evolution of lithium-ion battery electrodes under practical loadings[J]. *Journal of the Electrochemical Society*, 2026, 173(3): 030504. DOI:10.1149/1945-7111/ae385f.
- [68] NEJAD S, GLADWIN D T, STONE D A. A systematic review of lumped-parameter equivalent circuit models for real-time estimation of lithium-ion battery states[J]. *Journal of Power Sources*, 2016, 316: 183-196. DOI:10.1016/j.jpowsour.2016.03.042.
- [69] 邓昊, 杨林, 邓忠伟, 等. 基于电化学机理模型的锂离子电池参数辨识及 SOC 估计[J]. *上海理工大学学报*, 2018, 40(6): 557-565.
- DENG H, YANG L, DENG Z W, et al. Lithium-ion battery parameter identification and SOC estimation based on electrochemical models[J]. *Journal of University of Shanghai for Science and Technology*, 2018, 40(6): 557-565.
- [70] WANG Q, GAO T, LI X C. SOC estimation of lithium-ion battery based on equivalent circuit model with variable parameters[J]. *Energies*, 2022, 15(16): 5829. DOI:10.3390/en15165829.
- [71] JUNG S, TULLU A. Characteristics evaluation of 14 battery equivalent circuit models[J]. *IEEE Access*, 2023, 11: 117200-117209. DOI:10.1109/access.2023.3325395.
- [72] WANG C, YANG M J, WANG X, et al. A review of battery SOC estimation based on equivalent circuit models[J]. *Journal of Energy Storage*, 2025, 110: 115346. DOI:10.1016/j.est.2025.115346.
- [73] TEKIN M, KARAMANGIL M İ. Comparative analysis of equivalent circuit battery models for electric vehicle battery management systems[J]. *Journal of Energy Storage*, 2024, 86: 111327. DOI: 10.1016/j.est.2024.111327.
- [74] RAMSEY D, GERMAN R, BOUSCAYROL A, et al. Comparison of equivalent circuit battery models for energetic studies on electric vehicles[C]//2020 IEEE Vehicle Power and Propulsion Conference (VPPC). November 18-December 16, 2020. Gijon, Spain. IEEE, 2020: 1-5. DOI:10.1109/vppc49601.2020.9330891.
- [75] ZHAO X W, CAI Y S, YANG L, et al. State of charge estimation based on a new dual-polarization-resistance model for electric vehicles[J]. *Energy*, 2017, 135: 40-52. DOI: 10.1016/j.energy.2017.06.094.
- [76] QI C S, WANG S L, CAO W, et al. Improved joint prediction strategy for state of charge and peak power of lithium-ion batteries by considering hysteresis characteristics-current measurement deviation correction[J]. *Journal of Energy Storage*, 2024, 84: 110726. DOI:10.1016/j.est.2024.110726.
- [77] WU X G, LI X F, DU J Y. State of charge estimation of lithium-ion batteries over wide temperature range using unscented Kalman filter[J]. *IEEE Access*, 2018, 6: 41993-42003. DOI: 10.1109/access.2018.2860050.
- [78] TAO Z, ZHAO Z Y, WANG C D, et al. State of charge estimation of lithium batteries: Review for equivalent circuit model methods [J]. *Measurement*, 2024, 236: 115148. DOI: 10.1016/j.measurement.2024.115148.
- [79] LAI X, GAO W K, ZHENG Y J, et al. A comparative study of global optimization methods for parameter identification of different equivalent circuit models for Li-ion batteries[J]. *Electrochimica Acta*, 2019, 295: 1057-1066. DOI: 10.1016/j.electacta.2018.11.134.
- [80] GENG Y F, PANG H, LIU X F. State-of-charge estimation for lithium-ion battery based on PNGV model and particle filter algorithm[J]. *Journal of Power Electronics*, 2022, 22(7): 1154-1164. DOI:10.1007/s43236-022-00422-0.
- [81] TAO Z, ZHAO Z Y, FAN F, et al. High precision SoC estimation of LiFePO₄ blade batteries using improved OCV-based PNGV model [C]//IECON 2023- 49th Annual Conference of the IEEE Industrial Electronics Society. October 16-19, 2023. Singapore, Singapore. IEEE, 2023: 01-06. DOI:10.1109/iecon51785.2023.10312229.

- [82] YADAV R, MANAS M, DUBEY R K. An improved modified adaptive PNGV model for electric vehicle battery performance and charge stability[C]//2025 10th International Conference on Signal Processing and Communication (ICSC). February 20-22, 2025. Noida, India. IEEE, 2025: 253-257. DOI: 10.1109/icsc64553.2025.10969071.
- [83] 林成涛, 仇斌, 陈全世. 电流输入电动汽车电池等效电路模型的比较[J]. 机械工程学报, 2005, 41(12): 76-81.
- LIN C T, QIU B, CHEN Q S. Comparison of current input equivalent circuit models of electrical vehicle battery[J]. Chinese Journal of Mechanical Engineering, 2005, 41(12): 76-81.
- [84] YAN X W, GUO Y W, CUI Y, et al. Electric vehicle battery SOC estimation based on GNL model adaptive Kalman filter[J]. Journal of Physics: Conference Series, 2018, 1087(5): 052027. DOI:10.1088/1742-6596/1087/5/052027.
- [85] XIE S Y, ZHANG X H, BAI W Y, et al. State-of-charge estimation of lithium-ion battery based on an improved dual-polarization model[J]. Energy Technology, 2023, 11(4): 2201364. DOI: 10.1002/ente.202201364.
- [86] MARGAL A, EL DAOUDI S, EL ABDALLAOUI A, et al. State of charge estimation of a Li-ion battery with a DP model based on open-circuit voltage[C]//2026 2nd International Conference on Global Aeronautical Engineering and Satellite Technology (GAST). April 22-24, 2026, Marrakech, Morocco. IEEE, 2026: 1-6. DOI:10.1109/GAST67799.2026.11523351.
- [87] SUN X, ZUO L, ZHANG M K, et al. Equivalent circuit models for lithium-ion batteries: A comprehensive review[J]. Electronics, 2026, 15(9): 1968. DOI:10.3390/electronics15091968.
- [88] 付诗意, 吕桃林, 闵凡奇, 等. 电动汽车用锂离子电池SOC估算方法综述[J]. 储能科学与技术, 2021, 10(3): 1127-1136.
- FU S Y, LYU T L, MIN F Q, et al. Review of estimation methods on SOC of lithium-ion batteries in electric vehicles[J]. Energy Storage Science and Technology, 2021, 10(3): 1127-1136.
- [89] WU Y H, BAI D X, ZHANG K, et al. Advancements in the estimation of the state of charge of lithium-ion battery: A comprehensive review of traditional and deep learning approaches[J]. Journal of Materials Informatics, 2025, 5(2): DOI: 10.20517/jmi.2024.84.
- [90] RIMSHA, MURAWWAT S, GULZAR M M, et al. State of charge estimation and error analysis of lithium-ion batteries for electric vehicles using Kalman filter and deep neural network[J]. Journal of Energy Storage, 2023, 72: 108039. DOI: 10.1016/j.est.2023.108039.
- [91] SAMANTA A, CHOWDHURI S, WILLIAMSON S S. Machine learning-based data-driven fault detection/diagnosis of lithium-ion battery: A critical review[J]. Electronics, 2021, 10(11): 1309. DOI: 10.3390/electronics10111309.
- [92] CHATTERJEE S, KUMAR GATLA R, SINHA P, et al. Fault detection of a Li-ion battery using SVM based machine learning and unscented Kalman filter[J]. Materials Today: Proceedings, 2023, 74: 703-707. DOI:10.1016/j.matpr.2022.10.279.
- [93] XIE Z Y, DU S C, LV J, et al. A hybrid prognostics deep learning model for remaining useful life prediction[J]. Electronics, 2021, 10(1): 39. DOI:10.3390/electronics10010039.
- [94] KIM B, IM S, YOO G. Performance evaluation of CNN-based end-point detection using *in-situ* plasma etching data[J]. Electronics, 2021, 10(1): 49. DOI:10.3390/electronics10010049.
- [95] HOU J J, LI T, ZHOU F, et al. A review of critical state joint estimation methods of lithium-ion batteries in electric vehicles[J]. World Electric Vehicle Journal, 2022, 13(9): 159. DOI: 10.3390/wevj13090159.
- [96] YU Y, JI S, WEI K. Estimating method for power battery state of charge based on LS-SVM[J]. Chinese Journal of Power Sources, 2012, 36(3): 61-63.
- [97] LI R, XU S H, LI S B, et al. State of charge prediction algorithm of lithium-ion battery based on PSO-SVR cross validation[J]. IEEE Access, 2020, 8: 10234-10242. DOI: 10.1109/ACCESS.2020.2964852.
- [98] ÁLVAREZ ANTÓN J C, GARCÍA NIETO P J, BLANCO VIEJO C, et al. Support vector machines used to estimate the battery state of charge[J]. IEEE Transactions on Power Electronics, 2013, 28(12): 5919-5926. DOI:10.1109/TPEL.2013.2243918.
- [99] HU J N, HU J J, LIN H B, et al. State-of-charge estimation for battery management system using optimized support vector machine for regression[J]. Journal of Power Sources, 2014, 269: 682-693. DOI:10.1016/j.jpowsour.2014.07.016.
- [100] TIAN H X, LI A, LI X Y. SOC estimation of lithium-ion batteries for electric vehicles based on multimode ensemble SVR[J]. Journal of Power Electronics, 2021, 21(9): 1365-1373. DOI: 10.1007/s43236-021-00279-9.
- [101] KUMAR R R, BHARATIRAJA C, UDHAYAKUMAR K, et al. Advances in batteries, battery modeling, battery management system, battery thermal management, SOC, SOH, and charge/discharge characteristics in EV applications[J]. IEEE Access, 2023, 11: 105761-105809. DOI:10.1109/ACCESS.2023.3318121.
- [102] SALKIND A J, FENNIE C, SINGH P, et al. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology[J]. Journal of Power Sources, 1999, 80(1/2): 293-300. DOI:10.1016/S0378-7753(99)00079-8.
- [103] ZHENG W H, XIA B Z, WANG W, et al. State of charge estimation for power lithium-ion battery using a fuzzy logic sliding mode observer[J]. Energies, 2019, 12(13): 2491. DOI: 10.3390/en12132491.
- [104] XIA B Z, YE M, WANG Q, et al. Robustness estimation for state-of-charge of a lithium-ion battery based on feature fusion[J]. Energy Reports, 2024, 12: 4016-4025. DOI: 10.1016/j.egy.2024.09.072.
- [105] 马昊远, 吴焱, 王通, 等. 基于力-电-温度信号和CNN-BiLSTM模型的磷酸铁锂电池SOC估计[J]. 储能科学与技术, 2025, 14(7): 2865-2874.
- MA H Y, WU Y, WANG T, et al. State of charge estimation of lithium iron phosphate batteries based on force-electric-temperature signals and a CNN-BiLSTM model[J]. Energy Storage Science and Technology, 2025, 14(7): 2865-2874.

- [106] CHARKHGARD M, FARROKHI M. State-of-charge estimation for lithium-ion batteries using neural networks and EKF[J]. IEEE Transactions on Industrial Electronics, 2010, 57(12): 4178-4187. DOI:10.1109/TIE.2010.2043035.
- [107] HUYNH H T, WON Y. Regularized online sequential learning algorithm for single-hidden layer feedforward neural networks[J]. Pattern Recognition Letters, 2011, 32(14): 1930-1935. DOI: 10.1016/j.patrec.2011.07.016.
- [108] CHEN C, XIONG R, YANG R X, et al. State-of-charge estimation of lithium-ion battery using an improved neural network model and extended Kalman filter[J]. Journal of Cleaner Production, 2019, 234: 1153-1164. DOI: 10.1016/j.jclepro. 2019. 06.273.
- [109] MAO L, HU Q, ZHAO J B, et al. State-of-charge of lithium-ion battery based on equivalent circuit model - Relevance vector machine fusion model considering varying ambient temperatures [J]. Measurement, 2023, 221: 113487. DOI: 10.1016/j.measurement.2023.113487.
- [110] WANG C S, LI R P, CAO Y, et al. A hybrid model for state of charge estimation of lithium-ion batteries utilizing improved adaptive extended Kalman filter and long short-term memory neural network[J]. Journal of Power Sources, 2024, 620: 235272. DOI:10.1016/j.jpowsour.2024.235272.
- [111] TANG A H, HUANG Y K, LIU S M, et al. A novel lithium-ion battery state of charge estimation method based on the fusion of neural network and equivalent circuit models[J]. Applied Energy, 2023, 348: 121578. DOI:10.1016/j.apenergy.2023.121578.
- [112] FENG F, TENG S L, LIU K L, et al. Co-estimation of lithium-ion battery state of charge and state of temperature based on a hybrid electrochemical-thermal-neural-network model[J]. Journal of Power Sources, 2020, 455: 227935. DOI: 10.1016/j.jpowsour. 2020.227935.
- [113] DONG G Z, CHEN Z H, WEI J W. Sequential Monte Carlo filter for state-of-charge estimation of lithium-ion batteries based on auto regressive exogenous model[J]. IEEE Transactions on Industrial Electronics, 2019, 66(11): 8533-8544. DOI: 10.1109/TIE.2018.2890499.
- [114] GUO R H, XU Y M, HU C G, et al. Self-adaptive neural network-based fractional-order nonlinear observer design for state of charge estimation of lithium-ion batteries[J]. IEEE/ASME Transactions on Mechatronics, 2024, 29(3): 1761-1772. DOI: 10.1109/TMECH.2023.3321719.
- [115] WANG Y N, HAN X B, GUO D X, et al. Physics-informed recurrent neural networks with fractional-order constraints for the state estimation of lithium-ion batteries[J]. Batteries, 2022, 8(10): 148. DOI:10.3390/batteries8100148.
- [116] LIU F, YU D, SU W X, et al. Multi-state joint estimation of series battery pack based on multi-model fusion[J]. Electrochimica Acta, 2023, 443: 141964. DOI:10.1016/j.electacta.2023.141964.
- [117] ZHANG Y, GU P W, DUAN B, et al. A hybrid data-driven method optimized by physical rules for online state collaborative estimation of lithium-ion batteries[J]. Energy, 2024, 301: 131710. DOI:10.1016/j.energy.2024.131710.
- [118] ZHAO Z B, FENG M Q, YU Q Y, et al. Towards trustworthy lithium-ion battery remaining useful life prediction with uncertainty quantification[J]. Journal of Energy Storage, 2026, 167: 122408. DOI:10.1016/j.est.2026.122408.
- [119] YANG D L, QI N L, HUO M Y, et al. SOC-SOH co-estimation across the battery life cycle using a simplified electrochemical model with adaptive parameter updating and LSTM[J]. International Journal of Electrochemical Science, 2026, 21(4): 101300. DOI:10.1016/j.ijoes.2026.101300.
- [120] YANG H X, LIANG F W, LI K R, et al. State of health estimation and remaining useful life prediction of Li-ion battery oriented to real-world electric vehicles: A comprehensive evaluation methodology[J]. Engineering Applications of Artificial Intelligence, 2026, 181: 115311. DOI:10.1016/j.engappai.2026.115311.
- [121] HAJLAOUI R, SHALABY M, ALFILH R H C, et al. An improved MobileNet based on a modified poor and rich optimization algorithm for lithium-ion battery state-of-health estimation[J]. Scientific Reports, 2026, 16: 7689. DOI: 10.1038/s41598-026-38275-3.
- [122] HELALEY A, KHAN M K, SAJID Z. Integrating chemical engineering principles into battery management systems for enhanced safety and reliability in energy storage[J]. Battery Energy, 2026, 5(1): e70067. DOI:10.1002/bte2.70067.