XXXX

基于数据驱动的锂电池健康状态估计方法研究现状与进展

江善和*，荣浩威，潘宜宏
（安庆师范大学 电子工程与智能制造学院，安徽 安庆 246011）

摘 要：随着锂离子电池在新能源汽车与大规模储能系统中的广泛应用，其健康状态（SOH）的精准、可靠估计已成为系统安全运行与经济优化的关键技术。数据驱动的SOH估计方法，因无需深入复杂电化学机理建模且具备强大非线性拟合能力，已成为近年来SOH估计的研究主流。本文旨在聚焦数据驱动领域的SOH估计方法及其发展现状，系统梳理并深度评述该领域的研究进展。首先，理清锂离子电池的老化机理、影响因素和健康状态估计概念。其次，从机器学习、深度学习及融合模型等方面综述了数据驱动SOH估计方法的研究及其应用，深入分析各类方法在精度、鲁棒性、计算效率和可解释性方面的优势与局限。在此基础上，分析了当前SOH估计研究在机理与数据融合、跨域泛化与终身学习算法、轻量化与协同学习架构、电池组健康状态协同估计等方面存在的共性问题与挑战。最后，给出了SOH估计领域所面临的前沿研究方向及发展趋势。

关键词：锂离子电池；健康状态估计；数据驱动；机器学习；深度学习；融合模型
doi：10.19799/j.cnki.2095-4239.2026.0353
中图分类号：TM 912　　文献标志码：A　　文章编号：2095-4239（XXXX）XX-1-19

Research Status and Progress of Data-Driven Methods for Lithium-Ion Battery State of Health Estimation

JIANG Shanhe*, RONG Haowei, PAN Yihong
(School of Electronic Engineering and Intelligent Manufacturing, Anqing Normal University, Anqing 246011, Anhui, China)

Abstract: With the widespread adoption of lithium-ion batteries in new energy vehicles and large-scale energy storage systems, accurate and reliable estimation of State of Health (SOH) has become a critical technology for ensuring operational safety and economic optimization. Data-driven SOH estimation methods, which eliminate the need for complex electrochemical mechanism modeling while offering strong nonlinear fitting capabilities, have emerged as the dominant research trend in recent years. This paper aims to systematically review and critically assess the current developments in data-driven SOH estimation methods. First, it clarifies the aging mechanisms of lithium-ion batteries, influential factors, and the conceptual framework of SOH estimation. Second, the research and applications of data-driven SOH estimation methods from the perspectives of machine learning, deep learning, and fusion models are reviewed. The advantages and limitations of various methods in terms of accuracy, robustness, computational efficiency and explainability are analyzed in depth.

收稿日期：2026-04-24；修改稿日期：2026-07-01。
基金项目：国家自然科学基金项目（51607004），安徽省自然科学基金项目（2008085MF197）。
第一作者及通信联系人：江善和（1975—），男，博士，教授，基于数据驱动的锂离子电池状态监测，E-mail：jshxlxlw@163.com。
引用本文：江善和, 荣浩威, 潘宜宏. 基于数据驱动的锂电池健康状态估计方法研究现状与进展[J]. 储能科学与技术, XXXX, XX(XX): 1-19.
Citation：JIANG Shanhe, RONG Haowei, PAN Yihong. Research Status and Progress of Data-Driven Methods for Lithium-Ion Battery State of Health Estimation[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-19.

Based on this, the common problems and challenges in current SOH estimation research in terms of the integration of theory and data, cross-domain generalization and lifelong learning algorithms, lightweight and collaborative learning architectures, and collaborative estimation of battery group health status are analyzed. Finally, the frontier research directions and development trends in the SOH estimation field are presented.

Keywords: Lithium-ion battery; State of health estimation; Data-driven method; Machine learning; Deep learning; Blending model

0 引 言

随着全球能源致力于实现零碳排放，绿色能源已为交通电气化和智能电网奠定了坚实的技术基础[1-2]。锂离子电池凭借其卓越的能量密度和低自放电特性，已成为从小型电子设备到大型电动交通工具的核心动力源[3-7]。但是，锂离子电池长期运行中因电极结构破坏与副反应导致容量损失及内阻增大而性能衰减[8-9]，造成充放电效能下降[10-11]。这种性能衰退不仅影响设备运行效率，更可能诱发安全事故，因此，精准有效的电池健康管理系统对于保障电池全生命周期的安全与性能至关重要。

健康状态SOH（State of Health）作为电池健康管理系统安全运行的核心指标[12-13]，虽无法通过传感器直接测量，但基于电池的电压、电流、温度等数据可以有效实现精准估算[14]。当前，健康状态估计方法大致分为实验分析法、物理模型法和数据驱动法[15]。实验分析方法通常是指对电池机制进行初步研究，然后采用实验手段来分析电池的健康状态，并将影响电池健康状态的特征定义为健康指数，常见的分析方法有容量增量分析法[16-18]、差分电压分析法[19-20]等。这些实验方法能够量化老化机制，并为其他方法提供理论依据，但测试过程中其实验环境过于理想，与实际条件存在差异，难以实际应用。物理模型法实际上是实验分析法的一种拓展和延伸，它不仅依赖于实验数据的计算处理，还通过结合物理化学模型（伪二维模型[21]、单粒子模型[22]等）和滤波算法（卡尔曼滤波[23]、粒子滤波[24]等）来识别和估算相应的特征参数，或者借助数据模型挖掘电池的早期老化特征，找出复杂的映射关系，从而最终达到估算电池健康状态的目的，但该方法受限于固定参数难以适应动态老化过程，制约了其实际应用[25-26]。

近年来，随着电池管理系统中传感器的普及与物联网技术发展，海量的电池运行数据（电压、电流、温度等时间序列）得以便捷获取。与此同时，以机器学习和深度学习为代表的人工智能技术，在挖掘复杂数据模式、建立高维非线性映射、自动提取电池特征等方面展现出巨大威力。数据驱动方法有效避开了复杂的物理机理建模难题，直接从观测数据中学习与SOH之间的关联规律，具备非线性动态建模的强适应能力和在线应用的巨大潜力。在此背景下，基于数据驱动的锂电池SOH估计方法成为了该领域的研究热点。文[27-29]综述了当前锂电池健康估计方法的研究现状，详细对比了直接测量法、模型驱动法和数据驱动法的优缺点，指出了数据驱动方法在健康状态监测领域的显著优势，提出了特征工程在SOH预测中的关键作用，总结了当前研究中存在的主要挑战。XIONG等人[30-31]回顾了电池管理系统中基于模型的SOC（State of Capacity）和SOH估计算法、优缺点及未来趋势。SHRIVASTAVA等人[32]回顾了用于在线SOC估计的卡尔曼滤波算法。TIAN等人[33]讨论了锂离子电池SOH估计的分类框架。DICKSON等人[34]探讨了基于数据驱动和模型驱动算法的荷电状态估计。YANG等人[35]概述了锂离子电池健康状态的特征和估计。ZHANG等人[36]讨论了各种荷电状态估计方法，包括学习算法、自适应滤波算法和混合方法。BERECIBAR等人[37]研究了锂离子电池管理系统中健康状态的自适应方法和实验技术。VIDAL等人[38]综述了使用机器学习（Machine Learning，ML）方法对电动汽车电池的荷电状态和健康状态的估计。这些文献表明，基于数据驱动的锂电池健康状态估计取得了较为丰富的研究成果，推动着电池健康状态监测技术不断从“手工特征+浅层模型”到“自动特征+深度学习”再到“物理机理+数据驱动融合”三个阶段向前发展，为实现电池健康管理系统的技术突破奠定了基础。早期阶段，电池监测主

要依赖于专家经验手工设计电压、电流等数据的统计特征，结合SVM、线性回归等浅层模型实现初步在线估算，解决了离线实验分析的局限性，但泛化能力受限于特征表达与模型复杂度；随着人工智能和深度学习技术的发展，基于RNN、LSTM、CNN等模型自动提取电池数据深层特征成为现实，以“自动特征+深度学习”为主要手段的状态监测成为当下非常成熟的研究方法，该方法通过端到端建模显著提升了复杂工况下的估算精度，但存在数据依赖性强、可解释性差，难以揭示电池老化物理机制；未来发展正聚焦于将机理模型与数据驱动学习相融合，且相关研究成果正在呈现增长趋势，通过物理模型嵌入深度神经网络，实现物理机制与数据驱动的协同，提升估计精度和鲁棒性，增强模型可解释性和可靠性。

文章系统综述了锂离子电池老化机理和数据驱动SOH估计方法的最新研究进展，给出了数据驱动模型在SOH估计中的融合方式、应用和优缺点，并在此基础上，分析了数据驱动的SOH估计方法的未来挑战和发展展望，旨在为电池全生命周期健康管理提供理论支撑与实践指导，保障电池系统安全可靠运行。

1 电池老化机理及SOH

锂离子电池的老化主要由外部环境因素和内部因素造成[39-40]。内部因素主要是随着使用时间和循环次数的增加，电池的正极、负极、电解液以及内部部件材料发生一系列的物理和化学变化，这些降解机制会造成电池性能降低或剩余容量衰减[41-45]，其具体机理如图1所示。通常，电池老化模式分为三类：

（1）锂库存损失：锂离子因SEI生长、分解反应、锂镀层等而被消耗，不再可用于正负极之间的循环，从而导致容量衰减，也可能导致功率衰减。如果锂离子被困在活性材料的电隔离颗粒内部，也会造成锂离子的损失[46]。

（2）活性物质损失：钠离子电池阳极和阴极的活性物质由于结构紊乱、颗粒破裂、失去电接触或活性位点被电阻表面层阻塞，不再可用于锂的嵌入。这些过程会导致容量和功率衰减[47]。

（3）导电性损失：电池集流体断裂导致电子传输通路中断，以及黏合剂剥落与降解引发活性物质与集流体接触失效，共同造成电极界面电阻增加和电池导电性能下降[48]。

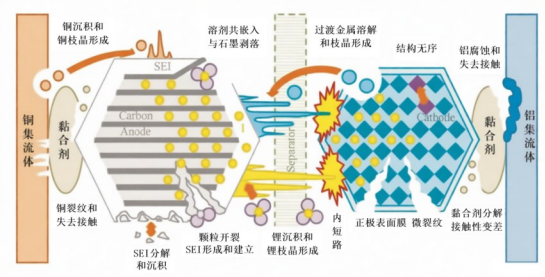


图1 锂电池降解机制示意图

Fig. 1 Schematic diagram of lithium battery degradation mechanism

锂离子电池的容量衰减同样与外部环境因素密切相关。外部环境因素主要指的是电池所处的温度[49]及其运行环境，例如充放电速率、放电深度以及充电截止电压等。这些外部因素通过加剧或抑制电池内部的降解机制影响电池的老化过程[50-52]，如图2所示。CUI等人[53]通过正交实验分析外部因素对锂电池衰减的影响，发现温度是影响容量损失的首要应力因素。

SOH表征当前电池的储存电能能力，是衡量电池健康状态的核心量化指标[54]。随着电池老化进程的推进，其可用容量会持续衰减，同时内阻增大、放电功率下降等特征参数随之变化。因此，SOH的标准定义以容量衰减[55]为基础，而内阻、功率及循环寿命等参数可作为辅助指标用于间接评估[56-60]，公式如（1）-（4）所示。

$$SOH = \frac{C_{curr}}{C_{rated}} \times 100\% \tag{1}$$

$$SOH = \frac{N_{rem}}{N_{tol}} \times 100\% \tag{2}$$

$$SOH = \frac{R_{EOL} - R_{curr}}{R_{EOL} - R_{new}} \times 100\% \tag{3}$$

$$SOH = \frac{P_{ocmp} - P_{min}}{P_{new} - P_{min}} \times 100\% \tag{4}$$

其次，在实际应用方面，基于内阻、功率、剩余可充电次数参数定义的SOH，由于电池内阻、功率与温度、充电状态有关，不易准确测量，总循环次数和剩余循环次数无法准确预测，且不适于实际应用。目前主要采用的是基于可用容量定义的SOH。

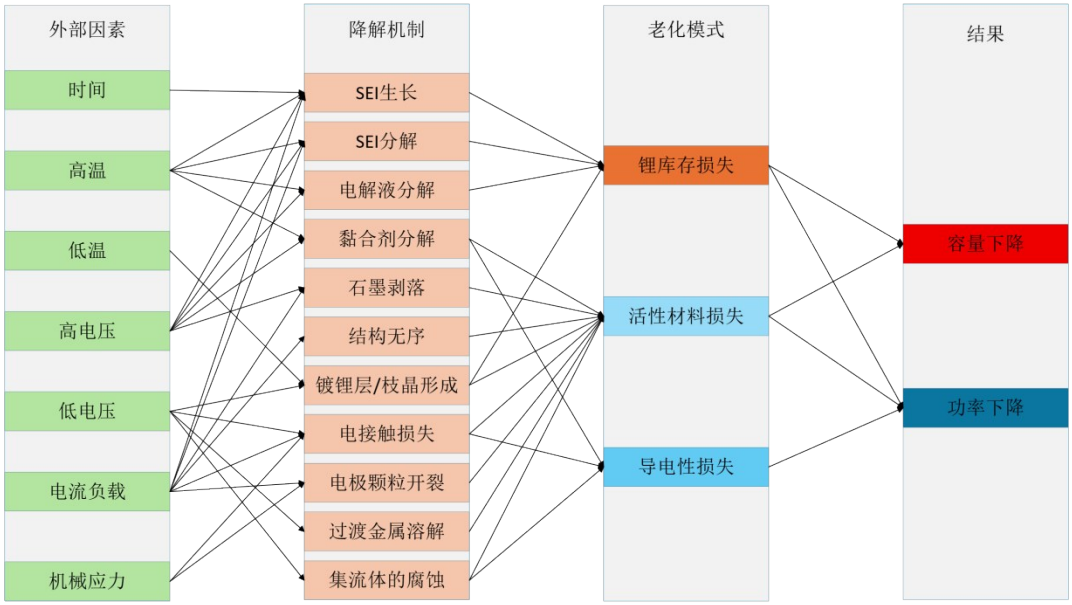


图2 外部因素影响降解机制及其老化模式的因果关系示意图

Fig. 2 Schematic diagram of the causal relationship between external factorsinfluencing the degradation mechanism and its aging mode

2 基于数据驱动的锂电池SOH估计方法

随着大数据及人工智能技术的快速发展，数据驱动技术突破了复杂非线性系统难以建模的束缚，已成为当前电池健康分析的主要研究方向之一[61-62]。锂离子电池的三种主要老化模式是电池内部的衰退，在电池外部则表现为性能数据（如电流、电压、阻抗和温度）的细微变化，数据驱动方法是从性能数据中提取特征，从数据变化的层面上，建立模仿电池老化规律的模型估计其SOH，因此，数据驱动模型并不需要了解电池内部的老化模型。当前数据驱动方法大致可以分为机器学习方法、深度学习方法和融合模型方法。

2.1 数据驱动模型估计流程

数据驱动估计健康状态的一般估计流程如图3所示。

首先，从原始数据中提取充电起始电压、充电时间、充电功率等直接健康特征，或者通过源于增量容量分析（ICA）曲线或差分电压分析（DVA）曲线的几何特征作为间接健康特征，如陆继忠等人从ICA曲线中提取峰值作为健康特征[63]，构建ICA峰值特征与SOH估计之间的非线性关系，实现电池SOH估计从一个电化学难题转化为一个特征量回归问题；张朝龙等人采用ICA曲线下的面积作为健康特征[64]，采用“面积”代替“峰值”，较好地解决了峰值特征的提取漂移和畸变问题，但也会带来不同材料、不同工况下的电池特征面积相同，从而带来电池特征信息的淹没；ZHOU等人为避免特征峰值偏移遮挡有效信息，采用机器学习方法重建ICA和DVA曲线，再从虚拟容量增量曲线和虚拟差分电压曲线中提取健康特征[65]，较好的解决了恒流工况的强依赖问题。但在实际工况下，电池的数据质量、特征量的稳健提取以及学习模型鲁棒性等问题仍然面临挑战。

然后，将健康特征数据集划分为训练集和测试集，训练集用于训练选择好的数据驱动模型，若损失函数收敛，则对训练好的模型使用测试集进行测试，否则继续训练直至损失函数收敛。训练好的模型在测试集上的误差高于误差阈值，说明模型训练失败，则对模型参数进行初始化，重新训练，若测试误差低于误差阈值，则说明模型训练成功，保存模型，结束流程。

为评估数据驱动模型对电池容量映射关系的预测效能，常以均方误差（MSE）、平均绝对误差（MAE）、均方根误差（RMSE）及决定系数（R^2）为核心指标，其中MAE与RMSE分别从绝对偏差与标准差维度量化预测精度，R^2则衡量模型对观测

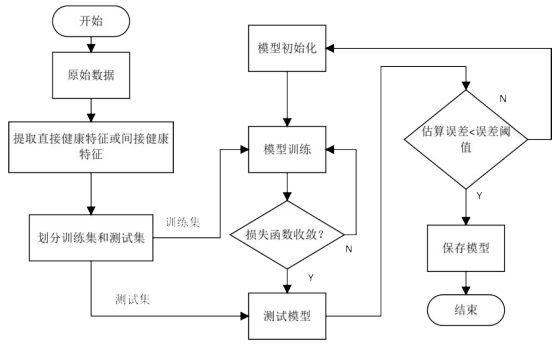


图3 数据驱动模型估计流程图

Fig. 3 Flowchart for data-driven model estimation

数据变异的解释能力，三者协同构建回归任务的性能评估体系，确保电池容量估计的可靠性，公式如（5）-（8）所示。

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}\left(y_i - \hat{y}_i\right)^2 \tag{5}$$

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n}\left|y_i - \hat{y}_i\right| \tag{6}$$

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y_i - \hat{y}_i\right)^2} \tag{7}$$

$$R^2 = 1 - \frac{\sum\left(y_i - \hat{y}_i\right)^2}{\sum\left(y_i - \bar{y}_i\right)^2} \tag{8}$$

（5）-（8）式中，n表示样本总数，y_i表示第i个样本的真实值，$\hat{y}_i$表示第i个样本的预测值，$\bar{y}_i$表示样本的平均值。

2.2 机器学习方法

机器学习方法作为一种独立的研究范式被正式引入电池健康管理领域。研究的核心范式是“手工特征+浅层模型”。研究者主要基于对电池老化机理的理解，从标准化的恒流充放电曲线中人工提取与容量衰减强相关的健康指标（Health Indicators，HIs）。随后，这些经过筛选的特征被输入支持向量回归、高斯过程回归、随机森林等经典机器学习模型中进行训练与预测。

2.2.1 支持向量机

支持向量机（SVM）是基于统计学习理论发展而来的机器学习方法，其核心思想是通过最大间隔超平面在高维空间中实现样本的最优分类，MENG等人[66]通过分析锂离子电池在电流脉冲测试下的端电压响应特征，从电压响应曲线中提取关键点和各关键点间的斜率作为潜在候选特征，通过系统比较所有可能的特征组合，采用网格搜索法优化SVM参数，选择最优特征组合建立SOH估计器。CAI等人[67]提出了一种基于进化算法的统一优化框架，将特征提取与支持向量回归参数优化整合为一个协同过程，通过遗传算法迭代优化，该框架能同时搜索最优特征组合与SVR参数，避免了传统方法中特征提取与参数优化分离导致的次优解问题，显著提升了电池健康状态估计的精度。GUO等人[68]将支持向量回归（SVR）与多特征提取结合，从恒流充电曲线中系统提取四个关键特征，采用径向基函数（RBF）核函数作为非线性映射工具，通过五折交叉验证法优化SVR的关键参数，确保模型在小样本场景下的泛化能力。SONG等人[69]将最小二乘支持向量机（LS-SVM）应用于电池健康状态的在线估计，提出了一种基于相等放电电压降的时间间隔的退化特征提取方法，该特征无需依赖其他测试协议即可从端电压样本中提取，确保了方法在实际应用中的可行性。通过三折交叉验证方法评估LS-SVM模型性能，优化了模型参数。实验表明，LS-SVM估计的SOH与实际容量衰减高度相关，相关系数均高于0.99，且估计误差小于2%，最大误差小于8%。这些研究可以得出，SVM通过其灵活的特征工程能力、鲁棒的参数优化机制及高效的核函数映射，系统性地克服了传统SOH估计方法对长期测试的依赖和小样本场景下的性能瓶颈，为电池健康管理提供了实用性的解决方案。

2.2.2 随机森林

随机森林作为机器学习领域的强大集成学习算法，在锂电池SOH估计中，随机森林能精准捕捉电池性能衰退的复杂非线性过程，有效整合循环次数、温度、内阻等多维度影响因素，同时通过自动计算特征重要性，识别关键健康指标并提供模型可解释性，从而实现高精度估计。然而，该方法存在计算成本较高的局限，如构建大量决策树需消耗较多计算资源和时间，尤其在处理大规模电池数据集时，在电池数据量有限的场景下，其性能可能逊于其他算法。此外，超参数的调优过程增加了模型开发的复杂性。

姚等人[70]将随机森林作为多模型融合的最终融合层，而非直接估计算法。从差分热伏安曲线提取10个健康因子，通过皮尔逊相关系数筛选出5个关键特征，随后结合支持向量回归和高斯过程回归进行初步预测，最终将两者输出输入随机森林回归进

行融合。该方法有效克服了单模型过拟合问题，显著提升鲁棒性。汪等人[71]将随机森林作为核心SOH估计算法，并通过遗传算法（GA）优化其超参数。通过遗传算法迭代优化随机森林的树数量、最大深度等参数，构建GA-RFR模型。该创新解决了随机森林超参数依赖人工经验的难题，显著提升收敛速度和预测性能，实现对任意SOC下退役电池的快速SOH估计。武等人[72]同样将随机森林作为核心估计算法，重点聚焦于特征优化而非模型结构改进。从充电电压曲线和增量容量（IC）曲线提取多维特征，利用随机森林内置的基尼系数自动评估各特征重要性，通过平衡模型精度与特征数量，构建最优特征组合的SOH估计模型，为电池健康状态评估提供了高效且可解释的解决方案。这些研究表明，随机森林利用其自动特征评估能力评估各特征重要性，平衡模型精度与特征数量；而优化算法驱动的参数优化机制及多模型融合策略，可以解决模型调参和计算资源的问题。

2.2.3 高斯过程回归

高斯过程回归（GPR）是一种基于贝叶斯理论的非参数回归方法，该理论假设目标函数遵循高斯过程，并能提供预测值以及不确定性估计。当应用于电池的健康状态时，它能够分析长期序列数据，并灵活捕捉它们之间的非线性关系。同样高斯过程回归算法的计算成本较高，开发人员在增强GPR时通常需要在时间和计算成本之间进行权衡。此外，关键参数的设置对算法性能有显著影响。参数选择不当可能导致模型陷入局部最优，从而产生较大的估计误差。越来越多的研究人员采用改进的启发式算法来更有效地选择模型参数。

HE等人[73]提出了一种基于改进特征提取与智能优化的高斯过程回归（GPR）方法用于锂离子电池健康状态在线估计，通过BMS系统已有的电流、电压和温度数据构建7个间接健康指标，并采用具有变异因子和基于种群多样性的自适应权重调整的粒子群优化算法，有效解决了传统方法依赖离线测量容量的难题。同时通过PCA降维和组合核函数设计提升了对电池老化非线性及容量再生现象的建模能力。LIN等人[74]也是通过电流、电压和温度构建获取间接健康指标，利用梯度下降法优化GPR超参数，解决了直接SOH测量依赖专业设备的难题。该方法通过间接特征映射SOH，避免了传统方法对电池容量/内阻的离线测量需求，同时优化后的GPR计算复杂度低，满足BMS实时在线应用需求，实测最大误差仅1.45%。张等人[75]聚焦容量再生现象对SOH估计的干扰，提出12个高阶特征经PCA降维后形成综合健康指标，并采用豪猪优化算法优化GPR核函数参数。该方案将特征与SOH相关系数从0.9550提升至0.9878，有效抑制了容量再生导致的预测波动。王等人[76]结合容量增量分析法提取峰值高度、电压及峰面积等特征，并设计神经网络核+周期核的组合核函数，通过灰狼优化（GWO）算法优化超参数。该方法精准捕捉了电池老化退化的非线性及容量再生的准周期性特征，实现RMSE仅1.03%、MAE仅0.5%的高精度预测。

为表示机器学习方法在锂电池SOH估计领域的技术特征，从特征来源、典型模型和能力边界三个层面进行归纳分析，如图4所示。机器学习方法通常以可解释健康指标为基础，将充放电曲线、IC/DV特征、温度、SOC、内阻和循环数等信息转化为模型输入，再通过SVM、随机森林或GPR建立健康指标与SOH之间的非线性映射。其中，SVM更适合小样本非线性回归，随机森林更适合高维特征处理和重要性评估，GPR则在不确定性表达方面具有优势。总体来看，该类方法在解释性和轻量化方面具有优势，但对人工特征质量依赖较强，长期时序表达能力不足。

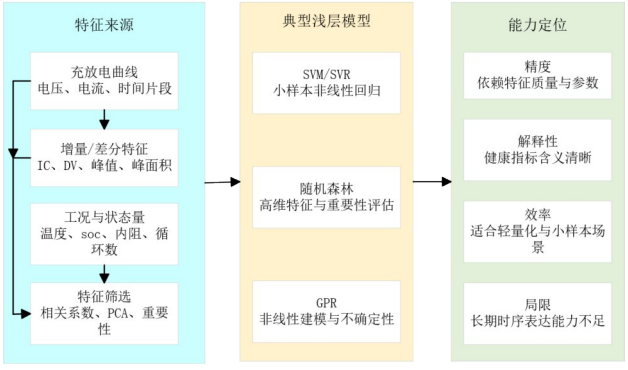


图4 机器学习方法在电池SOH估计中的特征−模型−能力图谱

Fig. 4 Feature-Model-Capability Map of Machine LearningMethods in Battery SOH Estimation

同时，表1给出了机器学习方法在输入特征选取、模型改进策略以及适应场景等方面的比较。由

表1可看出，机器学习方法的共同特点是依赖可解释健康指标和人工特征工程，适合样本规模有限、实时性要求较高或需要模型解释性的场景。其中，SVM更适合小样本非线性回归，随机森林更适合特征筛选与重要性解释，GPR则在不确定性估计方面具有优势。然而，此类方法对特征构造质量依赖较强，难以自动提取深层时序退化信息，因此逐渐与深度学习方法形成互补。

表1 机器学习方法在电池SOH估计中的比较

Table 1 Comparison of typical machine learning methods in battery SOH estimation

方法类别	主要输入或特征	代表性改进策略	适用场景	相关文献
SVM/SVR	电压响应关键点、斜率、恒流充电曲线特征、等电压降时间间隔	网格搜索、遗传算法、交叉验证、核函数优化	小样本SOH估计、在线轻量化估计	[66-69]
随机森林	IC曲线、DV曲线、差分热伏安曲线、温度、内阻、多维健康因子	基尼系数特征重要性评估、GA优化、多模型集成	健康指标筛选、特征重要性分析、多特征融合估计	[70-72]
GPR	电流、电压、温度构造的间接健康指标，容量增量峰值，高阶统计特征	PCA降维、组合核函数、PSO/GWO等启发式优化	不确定性评估、长期退化趋势分析、小中规模数据集	[73-76]

2.3 深度学习方法

随着深度学习在计算机视觉、自然语言处理等领域取得突破性成功，研究者将其引入SOH估计，推动研究进入“自动化特征学习”时代。以卷积神经网络（CNN）、长短期记忆网络（LSTM）及其变体（GRU）为代表的模型成为绝对主流。这些模型的革命性优势在于能够自动从原始或简单预处理的时间序列数据（如一个完整充电过程的电压曲线）中学习多层次、抽象的特征表示，极大地降低了对精细手工特征工程的依赖，实现了“端到端”或“半端到端”的学习。

2.3.1 前向神经网络

前向神经网络（FNN）是一种信息单向传播的深度学习模型，通过单向数据流处理静态输入特征，不依赖历史信息依赖关系。在电池健康状态估计中，FNN常用于处理BMS系统采集的静态特征。研究者采用混合架构来提高模型的精度和时序动态特性，使其成为电池SOH估计中静态特征处理的高效工具。MAWASSI等人[77]创新性地提出了一种无需反向传播的优化FNN模型，通过从放电电压曲线中提取关键健康特征（包括电压曲线下的面积和五次多项式回归系数），并系统优化隐藏层架构，在牛津电池数据集上实现了RMSE<0.14%的高精度SOH估计，显著优于传统基于反向传播的FNN模型。其优势在于避免了过拟合，提高了泛化能力，同时通过tanh激活函数有效捕捉了电池退化趋势。在物理信息融合方面，YE等人[78]提出了PIFNN模型，将P-IC与SOH的单调关系转化为物理约束纳入损失函数，通过在训练过程中引入物理约束指导训练，并在测试阶段进行二次训练以调整预测值，使模型在牛津数据集上实现了更可靠的SOH估计。此外，FU等人[79]开发了GAM-FNN框架，将特征分为四组，前三组通过稳定性加权注意力模块和特定自注意力机制进行独立处理，第四组特征与深度特征融合，构建了分层分组与融合架构，实现了MAPE仅为2.337%的高精度估计，同时通过残差连接和层归一化确保了数值稳定性。这些研究表明，FNN通过特征工程优化、结构参数系统化调整以及与物理知识的深度融合，有效克服了传统SOH估计方法对长期测试的依赖和小样本场景下的性能瓶颈，为电池健康状态评估提供了高精度、高鲁棒性且可解释的解决方案，尤其适用于嵌入式平台的实时部署需求。

2.3.2 循环神经网络

循环神经网络（RNN）是一种信息在时间维度上循环传播的深度学习模型，通过隐藏状态的时序传递处理序列输入特征，依赖历史信息动态演化。在电池健康状态估计中，RNN常用于建模老化过程的时序动态特性，能有效捕捉电池老化路径的长期依赖规律。RNN的时序建模能力显著优于前向神经网络，但计算效率较低且易受梯度消失问题影响。为此，研究者通过门控机制缓解梯度消失问题，开发出LSTM和GRU使SOH预测精度大幅提升。

LSTM作为RNN的典型变体，被广泛应用于捕捉电池老化过程中的时序依赖关系。于沛等人[80]的研究提出了一种基于VMD-LSTM的锂电池SOH预测方法，这种方法有效处理了电池容量再生现象，LSTM通过其门控机制能够捕捉电池老化过程中随时间变化的动态特性，从而显著提高了SOH

估计精度。Bharath 等人[81]提出将循环神经网络（RNN）与长短期记忆神经网络（LSTM）相结合，用于估算电池的内阻和健康状态，同时考虑了电池的各种异常运行条件。该研究通过让电池模型经历快速充电、变化的运行温度、过度使用和电池单元不平衡等导致加速退化的各种因素，生成了用于LSTM-RNN 训练和验证的数据集。LSTM-RNN 能够有效捕捉电池老化过程中复杂的时序动态特性，特别是能够从时间序列的角度检测容量衰减的内在模式，解决了传统方法难以精确建模电池在各种运行条件下加速老化和性能退化现象的问题。

GRU 作为RNN 的另一种高效变体，已成功应用于锂电池 SOH 估计[82]。该方法首先通过等压能量分析提取电池充电阶段的关键特征，然后利用CNN 提取健康因子的深层特征，最后采用 GRU 对时间序列信息进行建模。GRU 通过其简化的门控机制，在保持LSTM 捕捉长期依赖能力的同时，降低了计算复杂度，提高了模型训练效率。

BiLSTM 在锂电池 SOH 预测中展现出更强的时序建模能力，谢等人[83]提出的估计方法利用BiLSTM 其双向结构，能够从正向和反向两个角度分析电池老化过程，从而更全面地捕捉电池老化过程的动态特性。该研究提取了 6 种健康因子作为输入，包括充电时间、恒压阶段电流下降时间、电压波动情况等，通过贝叶斯优化算法对 BiLSTM 的超参数进行优化，有效提高了模型的泛化能力和预测精度。

在锂电池 SOH 估计中，单一 RNN 模型往往难以全面捕捉电池老化过程的复杂特性，因此研究者们开始探索将 RNN 变体与其他模型相结合的混合架构。这些融合方法不仅克服了单一模型的局限性，还充分发挥了不同模型的优势，使 SOH 估计的精度、鲁棒性和效率得到显著提升，成为当前锂电池健康状态估计领域的研究热点和应用趋势。

2.3.3 卷积神经网络

卷积神经网络（CNN）是一种通过空间卷积核进行信息传播的深度学习模型，能够高效提取输入数据的局部特征，无需依赖时间序列关系。在电池SOH 估计中，CNN 常用于分析电压或电流曲线的局部特征。

HUANG 等人[84]采用基于 CNN 的模型自动学习电池参数的时间特征，并用于预测电池的健康状态。CNN 能够自动从数据中学习和提取特征，具有一定程度的平移不变性和抗噪性。为提升模型性能，研究者采用贝叶斯优化算法迭代更新代理模型，寻找最优的 CNN 超参数配置，包括卷积核的数量、卷积核的大小以及池化层的大小。证明了CNN 结合贝叶斯优化在电池健康状态预测中的有效性和优越性。实验结果表明，与普通 CNN 相比，贝叶斯优化的 CNN 在 SOH 预测中表现更优，证明了 CNN 结合贝叶斯优化在电池健康状态预测中的有效性和优越性。CHENG 等人[85]则提出了一种CNN-KAN 模型用于锂电池 SOH 估计。该模型同样先利用 CNN 从充电曲线中提取局部时空特征，并采用注意力机制增强对关键模式的识别。随后，研究者引入 KAN 层替代传统全连接网络，通过自适应网格和 B 样条变换，实现从 8 维特征空间到 16 维空间的非线性映射。实验结果表明，该方法的决定系数超过 96.4%，均方根误差低于 0.86%，平均绝对误差低于 0.7%。

然而，CNN 的核心局限在于无法建模电池老化过程的时序动态特性，导致长周期 SOH 变化的预测精度受限。因此，研究者采用混合架构协同处理局部空间特征与时序依赖，从而成为电池 SOH 估计中电压曲线特征提取的高效解决方案。HUANG 等人[86]提出了一种 CNN-LSTM-TPA 融合模型用于锂电池健康状态估计。该模型结合了卷积神经网络和长短期记忆网络的优势，CNN 负责提取锂离子电池数据中的空间特征，而 LSTM 则有效捕捉时间信息。特别地，研究者引入了时间模式注意力（TPA）机制，为每个 LSTM 隐藏状态分配注意力权重，使模型能够专注于 SOH 估计中的关键时间步。实验结果表明，该模型在 NASA 和 CALCE 数据集上取得了优异的性能，验证了 CNN-LSTM-TPA 融合架构在锂电池 SOH 估计中的有效性。LI 等人[87]则提出了一种 CNN-TimesNet 的融合模型用于锂电池 SOH 估计。该研究将 CNN 与 TimesNet 相结合，CNN 同样负责从电池数据中提取局部空间特征，而 TimesNet 则专门处理时间序列数据。这种融合架构能够同时捕捉电池数据的局部空间特征和时间序列中的周期性模式，显著提升了 SOH 估计的精度。实验结果表明，与单一 CNN 或 TimesNet 模型相比，CNN-TimesNet 融合模型在多个评估指标上均表现出色，特别是在处理具有明

显周期性特征的电池老化数据时，其预测精度和稳定性得到显著提高。

2.3.4 生成对抗网络

生成对抗网络（GAN）作为一种基于生成器与判别器对抗训练的深度学习模型，通过生成高保真合成数据，在电池健康状态估计领域展现出显著应用价值，其核心优势在于突破数据稀缺限制并提升模型泛化能力。在数据增强方面，研究者通过创新训练策略显著优化了GAN的性能。YAO等人[88]提出采用与增强需求匹配的循环高斯噪声替代传统随机噪声，有效解决电池数据不平衡问题，生成的合成数据在PCA和t-SNE分析中与真实分布高度一致，经数据增强的模型在15种商用电池上实现平均绝对误差<2%，仅基于短循环电池B5训练的模型在跨电池迁移中均方根误差<1%，大幅提升了估计精度与迁移性。LIU等人[89]则将条件GAN应用于电压曲线重建，利用充电电压作为条件信息精准恢复缺失数据，相比支持向量回归、LSTM和GRU，MAE与RMSE分别降低了23.8%和77.3%，为数据缺失场景提供可靠解决方案。

在模型融合层面，GAN的应用已深度整合至多模态特征提取与优化框架，WONG等人[90]构建LSTM-GAN架构，生成包含电压、电流、温度和SOC的四维合成数据，其生成的电压/电流曲线呈现振荡特性，SOC曲线保持平滑，有效增强SOH预测的时序一致性。RAJASEKARAN等人[91]设计CNN-LSTM生成器与三重注意力判别器的混合GAN模型，通过火狐算法（FFA）优化参数，实现MAE=0.0036、MSE=4.23e-05、R^2=0.994的卓越性能，显著优于单一模型。此外，GAN正从单纯数据生成演进为特征映射与优化协同工具，YAO等人[88]引入特征映射模块引导特征-SOH曲线向数据密集区迁移，缓解短循环数据噪声问题。LIU等人[89]结合麻雀搜索算法（SSA）优化GRU超参数，进一步提升精度。这些进展表明，GAN已成为融合多源特征、提升模型鲁棒性的关键技术，聚焦于GAN与其他先进模型的深度集成及小样本高效训练，以持续推动电池SOH估计的精度与实用性发展。

2.3.5 Transformer

Transformer作为一种基于自注意力机制的序列建模架构，能够高效捕获输入序列中的全局依赖关系，无需依赖传统的递归或卷积操作[92]。在电池健康状态估计中，Transformer常用于分析电压或电流曲线的时序动态特性，精准建模电池老化过程的长期依赖。

CHEN等人[93]提出MEWOA-VMD-Transformer框架，将变分模态分解（VMD）与Transformer结合，通过VMD将电池容量衰减分解为趋势分量和波动分量，再将所有分量同时输入Transformer进行特征学习，使模型在NASA和CALCE数据集上实现了MAE低于0.25%的优异性能，相比传统Transformer模型精度提升38.13%。GU等人[94]则创新性地提出CNN-Transformer融合架构，利用CNN提取局部特征，Transformer捕获全局表示，通过交叉熵损失监督两个分支的耦合，使模型在NASA四个电池数据集上取得了优于LSTM、Transformer和CNN-LSTM的性能，MAE、MAPE和RMSE指标均显著降低。LIU等人[95]进一步提出SHMM-transformer-BiGRU混合模型，通过状态隐马尔可夫模型（SHMM）对输入序列进行语义分割，为Transformer提供结构化输入，使模型在NASA数据集上MAE降至1.83%，同时训练时间缩短至103秒，显著优于CNN-LSTM的196秒。PARK等人[96]则利用Transformer多头注意力机制进行健康指标探索，通过分析注意力权重识别与SOH估计高度相关且对配置依赖性低的5个关键健康指标，使模型在7P模块上的SOH估计均方根误差从6.31×10^{-2}大幅降至1.90×10^{-2}，实现了与配置无关的SOH估计。这些结果表明，Transformer通过自注意力机制能够有效处理电池老化过程中的长序列依赖关系，结合信号分解、特征选择和混合架构，显著提升了SOH估计的精度和鲁棒性。尽管Transformer模型在计算复杂度和参数数量方面存在挑战，但通过优化算法和架构设计，已实现计算效率与精度的平衡。

与机器学习方法相比，深度学习方法的核心优势在于能够从原始或低预处理程度的时间序列数据中自动学习多层次特征表示。根据网络结构和建模对象的不同，上述深度学习方法可进一步划分为静态特征映射、局部曲线特征、时序退化建模、数据增强建模和全局依赖建模等5种模型，图5展示了从“手工特征输入”过渡到“自动特征提取、长序列建模、数据增强和注意力解释”这一研究范式在

锂电池SOH估计中的演进关系。

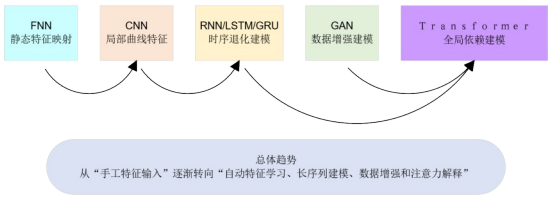


图5 深度学习方法在电池SOH估计中的模型演进关系

Fig. 5 Evolutionary Relationship of Models in Battery SOH Estimation Using DeepLearning Methods

表2总结了FNN、RNN及其变体、CNN、GAN和Transformer等深度学习模型在建模对象、核心功能及适用场景等方面的比较分析。由表2可知，深度学习方法已由早期的静态特征映射逐渐发展为面向复杂退化过程的多结构协同建模。FNN适合处理经过筛选的静态健康指标，RNN及其变体适合捕捉容量衰减的时间依赖，CNN适合提取电压或电流曲线中的局部退化模式，GAN主要用于数据增强和缺失重建，Transformer则在长序列依赖建模与注意力解释方面表现突出。总体来看，深度学习方法降低了对人工特征工程的依赖，但其性能高度依赖数据规模、训练稳定性和模型部署条件。

2.4 融合模型方法

机器学习与深度学习方法在电池SOH估计领域中各具优势，但单一模型往往难以兼顾特征可解释性、时序建模能力、跨工况泛化能力和工程部署效率。机器学习方法在小样本场景中表现稳健，能够依托健康指标筛选和特征重要性分析提供较强可解释性，但其静态建模特性限制了对长周期退化过程的刻画；深度学习方法能够从电压、电流、温度和容量序列中自动学习复杂非线性退化表征，但通常面临数据依赖性强、

表2 深度学习方法在电池SOH估计中的比较

Table 2 Comparison of Deep Learning Methods in Battery SOH Estimation

方法类别	建模对象	典型输入	核心能力	适用场景	相关文献
FNN	静态健康指标与SOH映射	多项式拟合系数、P-IC特征、分组健康指标	静态非线性映射	静态特征估计、嵌入式初步部署	[77-79]
RNN/LSTM/GRU/BiLSTM	电池老化路径的时序依赖	容量序列、健康因子序列、循环特征序列	长短期依赖建模	退化轨迹预测、长周期SOH估计	[80-83]
CNN	电压、电流或容量曲线中的局部模式	充放电曲线、IC曲线、局部时空特征	局部特征提取	曲线特征提取、与时序模型融合	[84-87]
GAN	数据增强、缺失重建与分布迁移	电压、电流、温度、SOC及其合成数据	样本生成与数据补全	小样本学习、数据缺失补全、跨电池迁移	[88-91]
Transformer	长序列全局依赖关系	容量衰减序列、分解后的趋势/波动分量、结构化健康指标序列	自注意力建模	复杂工况、长周期SOH估计	[92-96]

计算复杂度高和物理解释不足等问题。因此，近年来相关研究逐渐从单一模型转向多层级融合建模。按照融合发生的位置和作用机制，可将现有融合策略划分为特征级融合、模型级融合和决策级融合三种核心方式，如图6所示。

特征级融合发生在模型输入端，其核心目标是将多源运行数据和多类型健康指标整合为更具退化表征能力的输入特征。该类方法通常从充放电曲线、增量容量曲线（IC）、差分电压曲线（DV）、温度、SOC、内阻和循环次数等数据中构造候选健康指标，再通过相关性分析、信息论准则、PCA、随机森林等重要性评估或物理先验约束进行筛选和降维。SHMM-Transformer-BiGRU方法通过状态隐马尔可夫模型对输入序列进行语义分割，为后续

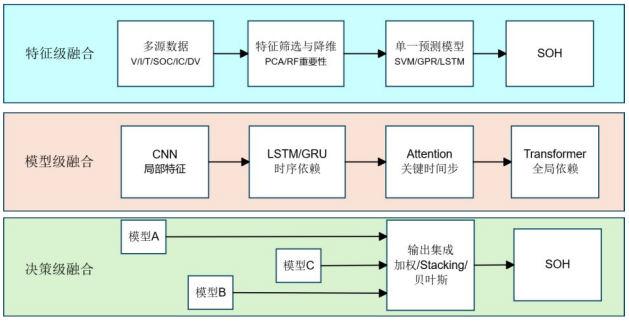


图6 融合模型的三类核心方法

Fig. 6 Three Core Approaches of the Fusion Model

Transformer和BiGRU提供结构化表征[95]；改进领域自适应迁移学习方法通过动态迁移深度调整策略增强跨工况特征适配能力[97]。近几年，真实工况与特征级融合研究得到发展，如LANUBILE等人[98]从

实际电动汽车运行数据中构造具有物理含义的能量和功率类健康指标，使模型能够在部分缺失数据和片段化充放电条件下进行SOH估计；ZHOU等人[99]面向并联电池模块，利用模块级ICA/DVA特征和信息论特征选择方法估计组级SOH。总体来看，特征级融合的优势在于计算成本较低、可解释性较强且便于嵌入BMS，但其性能仍然依赖特征构造质量，难以完全替代深层模型对复杂时序退化规律的自动学习。

模型级融合发生在网络结构内部，其核心目标是通过不同模型模块的协同建模，同时捕获局部特征、时序依赖和全局退化关系。如谢等人[100]提出CNN-BiGRU-Attention模型，将1D卷积网络的局部特征提取能力、BiGRU的序列建模能力和注意力机制的关键时间步捕获能力进行结构耦合；SHI团队[101]在CNN-BiGRU框架中引入改进多头注意力机制，以动态调整时间特征权重并降低过拟合风险；LI等人[102]将PSO与BiLSTM结合，通过全局搜索优化隐藏层节点数、学习率和正则化系数等关键超参数；张等人[103]提出SAO-BiLSTM-KAN混合模型，将KAN的非线性映射能力、BiLSTM的时序建模能力和SAO参数优化机制相结合；SHAO团队[104]提出KAL网络，以KAN模块替代传统Linformer中的MLP，增强对非线性退化特征的表示能力。除上述文献外，ZHOU等人[105]提出基于图卷积网络的SOH估计方法，将局部放电曲线片段构造成图结构，以捕获循环间退化动态；WEN等人[106]提出SSA优化的双模块BiGRU模型，在Spearman相关性筛选健康指标的基础上，通过双模块BiGRU学习序列前后文信息，并由麻雀搜索算法优化模型参数。由此可见，模型级融合能够显著增强复杂工况下的非线性表达和时序建模能力，是当前SOH估计中提升精度的主要路径，但其训练过程复杂、参数量较大，对边缘端实时部署和模型可解释性提出了更高要求。

决策级融合发生在模型输出端，其核心目标是将多个基模型的预测结果或多个预测分支的结果进行集成，以降低单模型误差和失效风险。与特征级和模型级融合不同，决策级融合不要求各基模型共享同一内部结构，而是通过加权平均、Stacking、Boosting、Bagging、随机森林回归或不确定性加权等方式综合多个模型的输出结果。已有研究中，姚等人[70]将SVR和GPR的初步预测结果输入随机森林回归器进行最终融合，属于典型的多模型输出融合；JIA等人[107]提出PSO-BiLSTM-AdaBoost框架，在BiLSTM预测基础上利用AdaBoost降低单一模型过拟合风险并提升泛化能力；YANG等人[108]采用CNN提取SOH和ΔSOH相关表征，再由随机森林给出最终SOH估计，体现了深度特征提取器与集成决策器的组合思路；HUOTARI等人[109]比较了梯度提升、LightGBM、Extra Trees、XGBoost、随机森林、LSTM和CNN-LSTM等多种方法在叉车锂电池组SOH时间序列预测中的表现，为决策级集成模型在电池组健康预测中的应用提供了参考。决策级融合更适合多工况、多数据源或多模型并行的工程场景，尤其适用于保留机器学习模型可解释性和深度学习模型表达能力的BMS系统，其局限在于需要同时训练或维护多个模型，推理成本和系统复杂度较高，且融合权重或集成策略的选择会直接影响最终估计结果。

表3梳理了三类融合策略分别对应不同的技术目标和应用场景。特征级融合侧重提高输入特征质量和模型可解释性，适合小样本和工程可部署场景；模型级融合侧重提升复杂退化过程的表征能力，适合高精度SOH估计和复杂工况建模；决策级融合侧重于降低单模型预测风险，适合多模型并行和鲁棒性要求较高的BMS应用。未来融合模型研究应避免单纯堆叠复杂模块，而应根据数据条件、部署资源和安全需求选择合适的融合层级，并进一步结合物理约束、不确定性估计和轻量化设计，实现高精度、可解释和可部署的SOH估计。

3 未来挑战与展望

3.1 基于数据驱动的锂电池健康状态估计方法对比

表4系统对比了数据驱动下电池SOH估计主要方法的性能特征。机器学习方法中，支持向量机计算量小、预测精度较高，但长期预测效果不佳；随机森林擅长处理高维数据和非线性关系建模，并具有一定特征解释能力，但计算量较大；高斯过程回归适合长期序列和不确定性建模，却对参数敏感且计算开销较高。深度学习方法呈现多样化特征：前向神经网络计算效率高但不依赖历史信息，无法建模老化时序动态特性；循环神经网络具备时序建

表3 不同融合层级的性能特征与适用场景对比

Table 3 Comparison of Performance Characteristics and Applicable Scenarios Across Different Fusion Levels

融合范式	融合位置	精度提升潜力	计算复杂度	适用场景	相关文献
特征级融合	输入端或表征层前端	中等，依赖特征质量	低至中等	小样本场景、健康指标筛选、需要物理解释	[72,75,97-99]
模型级融合	网络结构内部	高，能够同时建模局部特征和时序依赖	高	高精度估计、复杂工况、长周期退化建模	[100-106]
决策级融合	输出端	中等至高，可降低单模型误差	中等至高	多模型并行、跨工况集成、工程系统鲁棒估计	[70,107-109]

模能力，但存在梯度消失或梯度爆炸问题且计算效率较低；卷积神经网络擅长局部空间特征提取且计算效率较高，但缺乏长期时序建模能力；生成对抗网络可用于数据缺失补全和数据增强，具有较强泛化潜力，但训练成本较高且稳定性不足；Transformer序列建模能力强、特征表示全面，同样面临计算量大和参数敏感问题。

与单一模型相比，融合模型方法通过不同层级的信息整合提升SOH估计性能。特征级融合强调在输入端整合多源健康指标，具有较强可解释性和较低计算复杂度；模型级融合通过CNN、RNN、Transformer和注意力机制等模块的结构耦合提升预测精度，但计算复杂度较高；决策级融合通过多个基模型输出结果的集成提高鲁棒性，适合多工况或多模型并行场景。总体而言，单一方法难以兼顾精度、效率与泛化能力，多层级融合成为解决实际问题的重要方向。

表4 数据驱动估计模型对比

Table 4 Comparison of Data-Driven Estimation Models

驱动方法	估计模型	优点	缺点
机器学习	支持向量机	计算量小，小样本预测精度较高	长期预测效果不佳，对核函数和参数敏感
	随机森林	擅长处理高维数据和非线性关系建模，可评估特征重要性	计算量较大，长期外推能力有限
	高斯过程回归	擅长处理长期序列数据，可提供不确定性估计	计算量大，对参数和核函数敏感
深度学习	前向神经网络	不依赖历史信息，计算效率高	无法建模老化过程的时序动态特性，依赖参数和网络结构
	循环神经网络	具有时序建模能力	计算效率低，存在梯度消失和梯度爆炸问题
	卷积神经网络	具有局部空间特征提取能力，计算效率高	单独使用时缺乏时序建模能力，对参数和超参数敏感
	生成对抗网络	擅长处理数据缺失和数据增强，泛化能力较强	计算量大，训练稳定性和生成样本可靠性需验证
	Transformer	序列建模能力强，特征表示全面	计算量大，对参数和数据规模敏感
融合方法	特征级融合	可整合多源健康指标，可解释性较强，计算复杂度相对较低	依赖特征工程质量，深层时序表达能力有限
	模型级融合	可同时捕获局部特征、时序依赖和全局关系，精度提升潜力大	网络结构复杂，训练和部署成本高
	决策级融合	能降低单模型误差和失效风险，鲁棒性较强	需维护多个模型，推理成本和系统复杂度较高

3.2 未来挑战

数据驱动方法在锂电池健康状态估计领域虽已取得显著进展，但现有研究在方法论和实践层面仍存在系统性不足：

（1）理想数据与现实世界的鸿沟：绝大多数模型在实验室均一化、低噪声、完整循环的数据上开发和验证。这与真实电动汽车或储能电站中碎片化、多工况、带噪声、存在数据缺失的运行数据存在本质差异。在此鸿沟之下，估计模型的高精度在很大程度上可能是一种实验室幻象，导致模型的实用价值被高估。

（2）泛化能力的系统性缺失：模型普遍存在严重的领域依赖。针对特定电池型号、特定老化路径（固定充放电协议）训练的模型，难以推广至其他型号、其他使用历史的电池。这种泛化能力的缺失是数据驱动方法迈向广泛应用的最大障碍之一，其根源在于模型过度拟合了训练数据中的表面统计规律，而非本质的、跨领域通用的老化物理规律。

（3）可解释性与物理一致性的危机：以深度学习为主的模型是典型的“黑箱”，其内部决策逻辑不透明。这使得模型预测结果难以被电池领域的工程师所信任，也无法在出现估计失误时进行有效的原因分析和模型改进。更危险的是，模型可能学习到数据中的虚假相关性，从而在未知工况下做出违

反物理常识的错误预测，带来潜在的安全风险。

（4）从单体到电池组的研究断层：实际应用对象是电池组，但绝大多数研究聚焦于单体电池。电池组由数十至数百个不一致的单体组成，其SOH估计涉及复杂的耦合效应。目前，能够系统处理电池组不一致性、热耦合、连接阻抗等问题的数据驱动框架几乎空白。

3.3 未来展望

针对前述挑战，未来数据驱动锂电池SOH估计研究不应停留在“提高精度、增强泛化、提升可解释性”等宏观表述，而应围绕工程应用中的关键瓶颈形成分阶段研究路线。未来3-5年内，相关研究可重点从机理与数据融合、跨域泛化与终身学习、边缘计算与协同框架、电池组健康协同估计四个方向推进。其中，机理与数据融合是提升模型可信度的基础，跨域泛化与终身学习是支撑长期在线应用的关键，轻量化与云边端协同是实现BMS部署的前提，电池组级协同估计则是从单体研究走向工程系统应用的核心环节。基于工程迫切性和技术成熟度，本文进一步将后续研究划分为近期优先突破、中期重点推进和长期工程转化三个阶段，并用P0、P1和P2标识不同方向的优先级，如图7所示。

3.3.1 机理与数据融合

机理与数据融合是突破数据驱动模型可解释性不足和跨工况泛化能力弱的重要路径。未来研究应从高复杂度机理约束逐步转向可部署的轻量化物理约束。近期可优先引入单调退化约束、容量守恒约束、温度敏感性约束和等效电路模型（ECM）参数约束，使模型输出不违背基本电池老化规律。中期可将欧姆内阻、极化电阻、扩散系数等具有物理意义的参数作为神经网络中间变量，通过数据学习其时变规律，并结合参数变化解释SOH衰退机制。长期来看，可进一步探索PDE约束和多尺度电化学-热耦合模型，将宏观电压、电流和温度响应与微观电极反应、锂损失和活性材料损失联系起来。

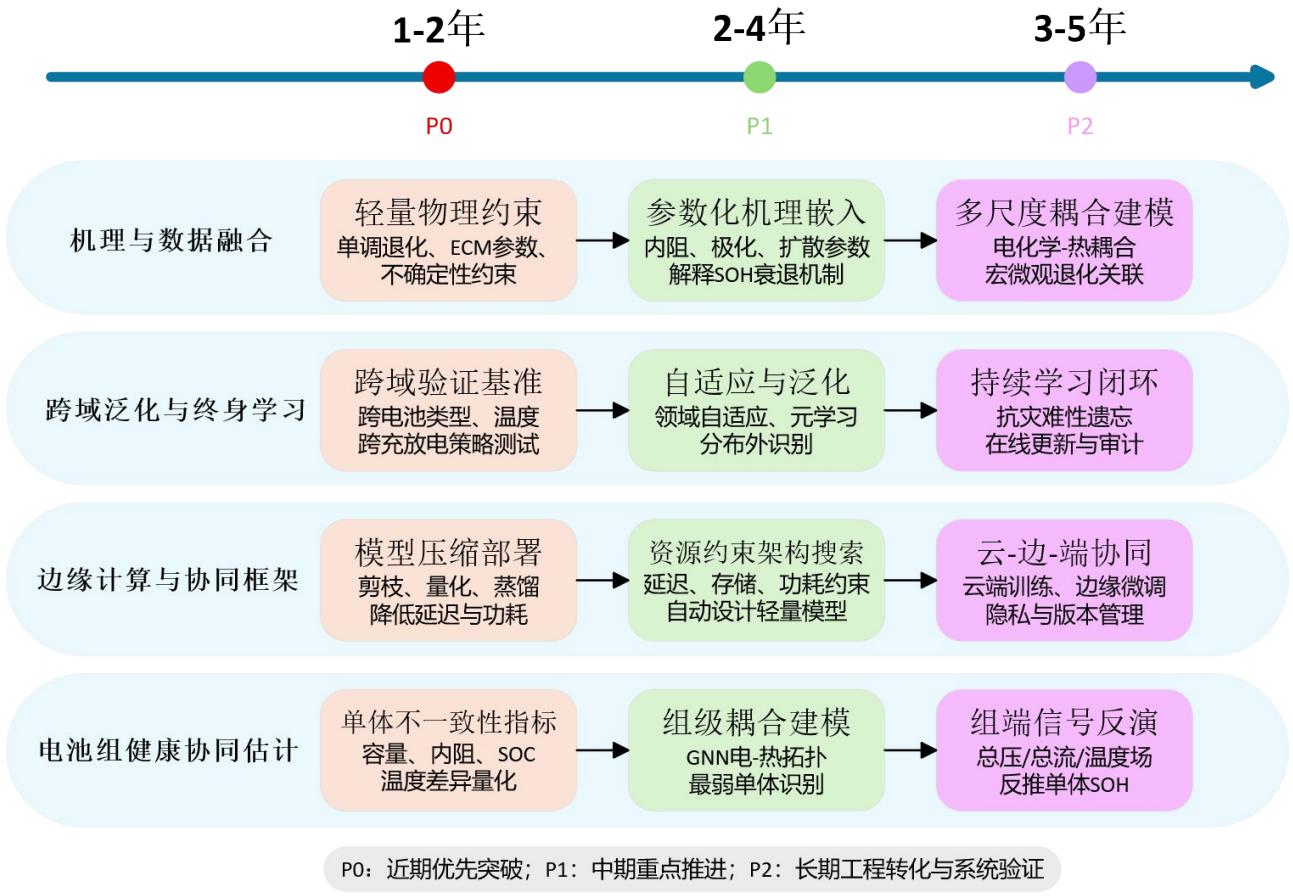


图7 数据驱动锂电池SOH估计未来3-5年研究路线

Fig. 7 Research Roadmap for Data-Driven Lithium BatterySOH Estimation in the Next 3-5 Years

具体而言，PDE约束嵌入能够提升模型物理一致性，但其空间导数计算和残差求解成本较高，短期内更适合作为离线高精度建模和机理验证工具；参数化机理模型嵌入计算负担较低，更适合未来1-3年内在BMS在线估计中优先推进；多尺度机理-数据融合能够更全面表征老化机制，但受限于多尺度数据获取、时空对齐和训练复杂度，宜作为未来3-5年的重点探索方向。由此可形成“轻量物理约束优先、参数化机理模型过渡、多尺度耦合长期突破”的研究路线。

3.3.2 面向跨域泛化与终身学习的算法

跨域泛化能力是数据驱动SOH估计从实验室数据集走向真实应用的关键。未来研究应针对不同应用条件选择差异化方法：当目标电池或目标工况仅有少量标注数据时，可优先采用元学习，使模型具备少样本快速适应能力；当目标域存在无标签或少量标签数据时，可采用领域自适应，通过对抗训练、统计分布匹配或子域对齐缩小源域和目标域差异；当目标域完全不可预先访问时，应发展领域泛化方法，使模型从多个源域中学习更稳定的退化表征。

在未来3-5年内，跨域泛化研究的重点不应仅是提高某一目标域上的预测精度，而应建立跨电池材料体系、跨制造批次、跨温度区间和跨充放电策略的统一验证框架。近期应优先构建多源域训练和跨域测试基准；中期应将领域自适应、领域泛化与不确定性估计结合，使模型能够识别分布外样本；长期应形成可持续更新的跨域SOH估计框架，实现新电池类型和新应用场景下的快速迁移。

除跨域泛化外，终身学习是面向电池全生命周期监测的关键能力。电池在服役过程中会经历早期成膜、中期缓慢衰减、后期加速退化以及容量再生或异常衰退等阶段，运行数据分布随时间持续变化。如果模型只进行一次离线训练，就难以适应长期服役过程中的工况变化；如果直接使用新数据持续微调，则可能出现灾难性遗忘，即模型在学习新温度区间、新充电策略或新电池批次后，遗忘低温工况、早期衰减阶段或罕见异常模式下的SOH映射关系。

针对灾难性遗忘问题，未来可重点发展四类方法：一是记忆回放，通过保留代表性历史样本或生成伪样本帮助模型复习旧知识；二是正则化约束，限制对历史任务重要的参数发生剧烈变化；三是参数隔离或动态网络，为不同老化阶段、工况区域或电池类型分配部分独立参数；四是分布漂移检测和不确定性触发更新，当输入数据超出已知分布时启动模型校准、云端更新或人工复核。后续研究应同时报告新工况适应精度、旧工况保持率、遗忘率和在线更新时间，而不应只报告单次测试误差。

3.3.3 面向边缘计算的轻量化与协同学习架构

面向车载和储能BMS的SOH在线估计必须满足低延迟、低功耗和有限存储条件，因此未来研究需要从“模型精度优先”转向“精度、计算量和部署成本协同优化”。近期可优先采用结构化剪枝、INT8量化和知识蒸馏等成熟压缩方法，将复杂深度模型压缩为适合边缘端运行的轻量模型；中期可结合神经架构搜索，在给定计算资源、延迟和存储约束下自动设计SOH估计模型；长期可构建云-边-端协同学习框架，做到云端负责全局模型训练和知识库维护，边缘端负责实时推断和个性化微调，端侧传感器负责数据采集、滤波和关键片段上传。

在该方向上，未来需要明确可量化的部署指标，例如模型参数量、单次推理延迟、功耗、存储占用、通信频率和在线更新成本。对于实际BMS而言，轻量化模型不能只追求压缩率，还应保证在温度变化、SOC区间变化和传感器噪声条件下的稳定性。云-边-端协同架构则需要进一步解决通信延迟、隐私保护、模型版本管理和更新安全审计等问题，避免在线更新引入新的安全风险。

3.3.4 电池组健康状态协同估计

电池组级SOH估计是数据驱动方法从单体研究走向工程应用的关键环节。实际电池组由大量单体组成，组级健康状态不仅取决于单体容量衰减，还受到单体不一致性、热耦合、电连接拓扑、均衡策略和局部异常传播的影响。因此，未来研究应从三个方面推进。

首先，应发展基于图神经网络（GNN）的电池组电-热耦合建模方法，将单体电池视为节点，将电连接关系、热传导路径和相邻单体影响视为边，通过消息传递机制刻画单体间相互作用。该方向近期可从固定拓扑和小规模模块入手，中长期再扩展到动态拓扑和复杂热边界条件。其次，应建立单体不一致性与组级SOH之间的映射关系，统一容量、内阻、SOC和温度差异等不一致性指标，

分析其对组级可用容量、功率能力和寿命短板的影响。最后，应探索从组端总电压、总电流和温度场反演单体SOH的方法，以降低传感器成本和系统复杂度。但该问题本质上属于欠定反演，未来必须引入拓扑先验、物理约束和不确定性估计，否则容易出现解不唯一和噪声放大问题。

总体而言，未来3-5年电池组SOH研究的关键目标应从估计平均SOH转向识别最弱单体、预测不一致性演化和服务均衡控制策略优化。只有将单体估计、组内耦合、异常识别和控制决策结合起来，数据驱动SOH估计方法才能真正支撑工程BMS中的安全管理与寿命优化。

4 结 论

本文综述了基于数据驱动的锂电池健康状态估计方法的最新研究进展，系统阐述了锂电池老化机理与SOH概念，详细介绍了当前数据驱动方法在SOH估计领域的技术方案。针对数据驱动方法，将其归纳为机器学习方法、深度学习方法以及融合方法三类，深入分析了各类方法模型的性能特点与实际应用局限。通过系统比较不同方法在精度、鲁棒性、计算效率和可解释性等方面的优劣，总结分析当前数据驱动法中不同方法的优势与局限性，揭示了现有研究在模型的可解释性、模型泛化能力、实际部署及电池组健康状态协同估计方面的挑战，展望了未来研究方向与研究重点，为进一步提升锂电池可靠性关键技术提供参考。

参 考 文 献

[1] MENG T, Lin Z, SHAMASH Y A. Distributed cooperative control of battery energy storage systems in DC microgrids[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(3): 606-616.

[2] KERMANSARAVI A, REFAAT S S, TRABELSI M, et al. AI-based energy management strategies for electric vehicles: Challenges and future directions[J]. Energy Reports, 2025, 13: 5535-5550.

[3] WANG Y, TIAN J, SUN Z, et al. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems[J]. Renewable and Sustainable Energy Reviews, 2020, 131: 110015.

[4] MA Y, LI B, LI G, et al. A nonlinear observer approach of SOC estimation based on hysteresis model for lithium-ion battery[J]. IEEE/CAA Journal of Automatica Sinica, 2017, 4(2): 195-204.

[5] 李建林, 肖珩. 锂离子电池建模现状综述[J]. 储能科学与技术, 2022, 11(2): 697-703.
LI J L, XIAO H. Review on modeling of lithium-ion battery[J]. Energy Storage Science and Technology, 2022, 11 (2): 697-703.

[6] 梁新成, 张勉, 黄国钧. 基于BMS的锂离子电池建模方法综述[J]. 储能科学与技术, 2020, 9(6): 1933-1939.
LIANG X C, ZHANG M, HUANG G J. Review on lithium-ion battery modeling methods based on BMS[J]. Energy Storage Science and Technology, 2020, 9(6): 1933-1939.

[7] UNGUREAN L, CÂRSTOIU G, MICEA M V, et al. Battery state of health estimation: a structured review of models, methods and commercial devices[J]. International Journal of Energy Research, 2017, 41(2): 151-181.

[8] 梁培维, 张彦会. 基于欧姆内阻对锂电池健康状态的估算[J]. 电源技术, 2019, 43(10): 1623-1625,1704.
LIANG P W, ZHANG Y H. Estimation of lithium battery health based on ohmic internal resistance[J]. Chinese Journal of Power Sources, 2019, 43 (10): 1623-1625,1704.

[9] 张钰, 赵志衡, 周海睿. 基于随机充电片段和DBFN-ML的锂电池健康状态估计[J]. 储能科学与技术, 2026, 15(6): 2368-2379.
ZHANG Y, ZHANG Z H, ZHOU H R. Estimation of lithium-ion battery state of health based on random charging segments and DBFN-ML[J]. Energy Storage Science and Technology, 2026, 15 (6): 2368-2379.

[10] LIU K, LI K, PENG Q, et al. A brief review on key technologies in the battery management system of electric vehicles[J]. Frontiers of mechanical engineering, 2019, 14(1): 47-64.

[11] SUI X, HE S, VILSEN S B, et al. A review of non-probabilistic machine learning-based state of health estimation techniques for Lithium-ion battery[J]. Applied Energy, 2021, 300: 117346.

[12] 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.

[13] 吴盛军, 袁晓冬, 徐青山, 等. 锂电池健康状态评估综述[J]. 电源技术, 2017, 41(12): 1788-1791.
WU S J, YUAN X D, XU Q S, et al. Review on lithium-ion battery health state assessment[J]. Chinese Journal of Power Sources, 2017, 41 (12): 1788-1791.

[14] 熊庆, 邸振国, 汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述[J]. 高电压技术, 2024, 50(3): 1182-1195.
XIONG Q, DI Z G, JI S C. Review on Health State Estimation and Life Prediction of Lithium-ion Batteries[J]. High Voltage Engineering, 2024, 50 (3): 1182-1195.

[15] XIAO Y Q, WEN J S, YAO L, et al. A comprehensive review of the lithium-ion battery state of health prognosis methods combining aging mechanism analysis[J]. Journal of Energy Storage, 2023, 65: 107347.

[16] ZHANG S, ZHAI B, GUO X, et al. Synchronous estimation of state of health and remaining useful lifetime for lithium-ion battery using the incremental capacity and artificial neural networks[J]. Journal of Energy Storage, 2019, 26: 100951.

[17] ZHANG C, WANG Y, GAO Y, et al. Accelerated fading recognition for lithium-ion batteries with Nickel-Cobalt-Manganese cathode using quantile regression method[J]. Applied Energy, 2019, 256:

113841.

[18] TANG X, WANG Y, LIU Q, et al. Reconstruction of the incremental capacity trajectories from current-varying profiles for lithium-ion batteries[J]. Iscience, 2021, 24(10).

[19] 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.

[20] LIU G, OUYANG M, LU L, et al. Online estimation of lithium-ion battery remaining discharge capacity through differential voltage analysis[J]. Journal of Power Sources, 2015, 274: 971-989.

[21] RAMADASS P, HARAN B, GOMADAM P M, et al. Development of first principles capacity fade model for Li-ion cells[J]. Journal of the Electrochemical Society, 2004, 151(2): A196-A203.

[22] BARTLETT A, MARCICKI J, ONORI S, et al. Electrochemical model-based state of charge and capacity estimation for a composite electrode lithium-ion battery[J]. IEEE Transactions on Control Systems Technology, 2015, 24(2): 384-399.

[23] ZHOU X, STEIN J L, ERSAL T. Battery state of health monitoring by estimation of the number of cyclable Li-ions[J]. Control Engineering Practice, 2017, 66: 51-63.

[24] BARTLETT A, MARCICKI J, ONORI S, et al. Model-based state of charge estimation and observability analysis of a composite electrode lithium-ion battery[C]. 52nd IEEE Conference on Decision and Control. IEEE, 2013: 7791-7796.

[25] 李肖辉, 陈北海, 古领先, 等. 锂离子电池健康状态评估方法研究进展[J]. 电源技术, 2021, 45(6): 818-822.
LI X H, CHEN B H, GU L X, et al. Research progress of health assessment methods for lithium ion batteries[J]. Chinese Journal of Power Sources, 2021, 45 (6): 818-822.

[26] 杨杰, 王婷, 杜春雨, 等. 锂离子电池模型研究综述[J]. 储能科学与技术, 2019, 8(1): 58-64.
YANG J, WANG T, DU C Y, et al. Overview of the modeling of lithium-ion batteries[J]. Energy Storage Science and Technology, 2019, 8(1): 58-64.

[27] 马兹林, 李云潘, 詹振飞, 等. 锂离子电池健康状态估计方法综述[J]. 重庆理工大学学报(自然科学), 2025, 39(12): 1-10.
MA Z L, LI Y P, ZHAN Z F, et al. A review of health state estimation methods for ithium-ion batteries[J]. Journal of Chongqing University of Technology (Natural Science), 2025, 39 (12): 1-10.

[28] ZHANG M, YANG D, DU J, et al. A review of SOH prediction of Li-ion batteries based on data-driven algorithms[J]. Energies, 2023, 16(7): 3167.

[29] XIA F, WANG K, CHEN J. State of health and remaining useful life prediction of lithium-ion batteries based on a disturbance-free incremental capacity and differential voltage analysis method[J]. Journal of Energy Storage, 2023, 64: 107161.

[30] XIONG R, CAO J, YU Q, et al. Critical review on the battery state of charge estimation methods for electric vehicles[J]. IEEE Access, 2017, 6: 1832-1843.

[31] 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.

[32] SHRIVASTAVA P, SOON T K, IDRIS M Y I B, et al. Overview of model-based online state-of-charge estimation using Kalman filter family for lithium-ion batteries[J]. Renewable and Sustainable Energy Reviews, 2019, 113: 109233.

[33] TIAN H, QIN P, LI K, et al. A review of the state of health for lithium-ion batteries: Research status and suggestions[J]. Journal of Cleaner Production, 2020, 261: 120813.

[34] HOW D, HANNAN M, LIPU M, 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.

[35] YANG S, ZHANG C, JIANG J, et al. Review on state-of-health of lithium-ion batteries: Characterizations, estimations and applications[J]. Journal of cleaner production, 2021, 341: 128015.

[36] ZHANG R, XIA B, LI B, et al. State of the art of lithium-ion battery SOC estimation for electrical vehicles[J]. Energies, 2018, 11(7): 1820.

[37] BERECIBAR M, GANDIAGA I, VILLARREAL I, et al. Critical review of state of health estimation methods of Li-ion batteries for real applications[J]. Renewable and Sustainable Energy Reviews, 2016, 56: 572-587.

[38] 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.

[39] 王琛航, 丰晓宇, 张欣瑶, 等. 极端条件下锂离子电池失效机制研究进展[J]. 材料工程, 2025, 53(7): 57-67.
WANG C H, FENG X Y, ZHANG X Y, et al. Research progress in failure mechanisms of lithium-ion batteries under extreme conditions[J]. Journal of Materials Engineering, 2025, 53(7): 57-67.

[40] 王天鸢, 郭城志, 吴宝坤, 等. 适用于全生命周期容量损失机制诊断的锂离子电池OCV老化模型研究[J]. 机械工程学报, 2023, 59(22): 124-139.
WANG T S, GUO C Z, WU B K, et al. OCV Aging Model of Lithium-ion Batteries for Whole-life Capacity-loss Mechanism Diagnosis[J]. Journal of Mechanical Engineering, 2023, 59(22): 124-139.

[41] LI Y, GUO W, STROE D, et al. Evolution of aging mechanisms and performance degradation of lithium-ion battery from moderate to severe capacity loss scenarios[J]. Chemical Engineering Journal, 2024, 498: 155588.

[42] 金建新, 虞儒新, 刘刚, 等. 锂离子电池健康状态估算方法研究进展[J]. 电气工程学报, 2024, 19(1): 33-48.
JIN J X, YU R X, LIU G, et al. Research Progress on State-of-health Estimating Method for Lithium-ion Batteries[J]. Journal of Electrical Engineering, 2024, 19(1): 33-48.

[43] 王怡, 陈学兵, 王愿习, 等. 储能锂离子电池多层级失效机理及分析技术综述[J]. 储能科学与技术, 2023, 12(7): 2079-2094.
WANG Y, CHEN X B, WANG Y X ,et al. Overview of multilevel failure mechanism and analysis technology of energy storage

lithium-ion batteries[J]. Energy Storage Science and Technology, 2023, 12(7): 2079-2094.

[44] BIRKL C R, ROBERTS M R, MCTURK E, et al. Degradation diagnostics for lithium ion cells[J]. Journal of Power Sources, 2017, 341: 373-386.

[45] LI Y, SHI H, WANG S, et al. A comprehensive review of remaining useful life prediction methods for lithium-ion batteries: Models, trends, and engineering applications[J]. Journal of Energy Chemistry, 2025.

[46] LI W, LI H, HE Z, et al. Electrochemical failure results inevitable capacity degradation in Li-ion batteries—a review[J]. Energies, 2022, 15(23): 9165.

[47] MARIN-MONTIN J, ZURITA-GOTOR M, MONTERO-CHACÓN F. Numerical analysis of degradation and capacity loss in graphite active particles of li-ion battery anodes[J]. Materials, 2022, 15 (11): 3979.

[48] 郝增辉, 刘训良, 孟缘, 等. 电极界面微观结构对固态锂离子电池性能的影响[J]. 储能科学与技术, 2023, 12(7): 2095-2104.
HAO Z H, LIU X L, MENG Y, et al. Effect of electrode interface microstructure on the performance of solid-state lithium-ion battery[J]. Energy Storage Science and Technology, 2023, 12(7): 2095-2104.

[49] DENG B, LI W, CAI W, et al. Capacity fade of high-energy Li [Ni0. 8Mn0. 1Co0. 1] O2/Graphite lithium-ion battery as affected by cell mechanical constraint and subsequent stresses[J]. Journal of Cleaner Production, 2024, 448: 141722.

[50] SHARMA A, DAS A, JANGID M K, et al. Suppressing Irreversible Capacity Loss and Improving Stability during High Voltage Cycling of Li-Ion Battery Cathodes via a Carefully Designed "Formation Cycle" Protocol[J]. Journal of The Electrochemical Society, 2025, 172(2): 020531.

[51] HUANG Q, ZHANG X, LV X, et al. Electrochemical aging protocol governed capacity losses and structure degradations in layered LiNi0. 8Co0. 1Mn0. 1O2 oxides[J]. Small, 2023, 19(42): 2302086.

[52] 张祎柔, 曾晓淇, 李家星, 等. 锂离子电池颗粒尺度下电化学-热-力过充模型[J]. 物理学报, 2025, 74(3): 204-216.
ZHANG H R, ZENG X Q, LI J X, et al. Electrochemical-thermal-mechanical overcharge model on a scale of particle for lithium-ion batteries[J]. Acta Physica Sinica, 2025, 74(3): 204-216.

[53] CUI Y, DU C, YIN G, et al. Multi-stress factor model for cycle lifetime prediction of lithium ion batteries with shallow-depth discharge[J]. Journal of Power Sources, 2015, 279: 123-132.

[54] 张欣怡, 伍嘉浩, 张璐平, 等. 锂离子电池健康状态评估方法研究新进展[J]. 河南科学, 2024, 42(12): 1717-1740.
ZHANG X Y, WU J H, ZHANG L P, et al. New Research Progress of the State of Health Estimation Methods for Lithium-Ion Batteries[J]. Henan Science, 2024, 42(12): 1717-1740.

[55] 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.

[56] 金帅, 董静. 基于数据驱动的锂离子电池健康状态估计研究进展综述[J]. 仪器仪表学报, 2024, 45(3): 45-59.
JIN S, DONG J. Review on progress of data-driven based health state estimation for lithium-ion batteries[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 45-59.

[57] 李放, 闵永军, 张涌. 基于大数据的动力锂电池可靠性关键技术研究综述[J]. 储能科学与技术, 2023, 12(6): 1981-1994.
LI F, MIN Y J, ZHANG Y. Review of key technology research on the reliability of power lithium batteries based on big data[J]. Energy Storage Science and Technology, 2023, 12(6): 1981-1994.

[58] LIU Z T, TAN C, LENG F. A reliability-based design concept for lithium-ion battery pack in electric vehicles[J]. Reliability Engineering & System Safety, 2015, 134: 169-177.

[59] SHAHRIARI M, FARROKHI M. Online state-of-health estimation of VRLA batteries using state of charge[J]. IEEE Transactions on Industrial Electronics, 2013, 60(1): 191-202.

[60] BARRÉ A, DEGUILHEM B, GROLLEAU S, et al. A review on lithium-ion battery ageing mechanisms and estimations for automotive applications[J]. Journal of Power Sources, 2013, 241: 680-689.

[61] 王震坡,王秋诗,刘鹏,等. 大数据驱动的动力电池健康状态估计方法综述[J]. 机械工程学报,2023,59(2):151-168.
WANG Z P, WANG Q S, LIU P, et al. Review on Techniques for Power Battery State of Health Estimation Driven by Big Data Methods[J]. Journal of Mechanical Engineering, 2023, 59(2): 151-168.

[62] 何洪文, 王浩宇, 王勇, 等. 基于实车运行数据的锂离子电池健康状态估计[J]. 机械工程学报, 2023, 59(22): 46-58.
HE H W, WANG H Y, WANG Y, et al. Lithium-ion Battery State of Health Estimation Based on Real-world Driving Data[J]. Journal of Mechanical Engineering, 2023, 59(22): 46-58.

[63] 陆继忠, 彭思敏, 李晓宇. 基于多特征量分析和LSTM-XGBoost模型的锂离子电池SOH估计方法[J]. 储能科学与技术, 2024, 13(09): 2972-2982.
LU J Z, PENG S M, LI X Y. State-of-health estimation of lithium-ion batteries based on multifeature analysis and LSTM-XGBoost model[J]. Energy Storage Science and Technology, 2024, 13(09): 2972-2982.

[64] 张朝龙, 陈阳, 刘梦玲, 等. 一种基于ICA-T特征和CNN-LA-BiLSTM的锂离子电池健康状态估计方法[J]. 储能科学与技术, 2025, 14(3): 1258-1269.
ZHANG C L, CHEN Y, LIU M L, et al. A state of health estimation method for lithium-ion batteries using ICA-T features and CNN-LA-BiLSTM[J]. Energy Storage Science and Technology, 2025, 14 (3): 1258-1269.

[65] ZHOU Q, 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 [J]. Electrical Engineering and Systems Science, 2025. Https://doi.org/10.48550/arXiv.2502.19586.

[66] MENG J, CAI L, LUO G, et al. Lithium-ion battery state of health

estimation with short-term current pulse test and support vector machine[J]. Microelectronics Reliability, 2018, 88: 1216-1220.

[67] CAI L, MENG J, STROE D I, et al. An evolutionary framework for lithium-ion battery state of health estimation[J]. Journal of Power Sources, 2019, 412: 615-622.

[68] GUO Y F, HUANG K, HU X Y. A state-of-health estimation method of lithium-ion batteries based on multi-feature extracted from constant current charging curve[J]. Journal of Energy Storage, 2021, 36: 102372.

[69] SONG Y, LIU D, LIAO H, et al. A hybrid statistical data-driven method for on-line joint state estimation of lithium-ion batteries[J]. Applied Energy, 2020, 261: 114408.

[70] 姚博炜, 赖扬品, 韦锦易, 等. 基于差分热伏安法的锂离子电池SOH多模型融合估计方法[J]. 数字制造科学, 2023, 21(2): 126-130.
YAO B W, LAI Y P, WEI J Y, et al. Multi - model Fusion Estimation Method for Lithium - ion Battery SOH Based on Differential Thermal Voltammetry[J]. Digital Manufacture Science, 2023, 21 (2): 126-130.

[71] 汪宇航, 黄海宏, 王海欣, 等. 基于荷电状态差异的退役电池健康状态快速估计研究[J]. 仪器仪表学报, 2023, 44(12): 55-68.
WANG Y H, HUANG H H, WANG H X, et al. Research on fast estimation of the state of health of retired batteries based on the state of charge differences[J]. Chinese Journal of Scientific Instrument, 2023, 44(12): 55-68.

[72] 武骥,方雷超,刘兴涛,等. 基于特征优化和随机森林算法的锂离子电池SOH估计[J]. 机械工程学报,2024,60(12):335-343.
WU J, FANG L C, LIU X T, et al. State of Health Estimation of Lithium-ion Battery Based on Feature Optimization and Random Forest Algorithm[J]. Journal of Mechanical Engineering, 2024, 60 (12): 335-343.

[73] HE Y, BAI W, WANG L, et al. SOH estimation for lithium-ion batteries: An improved GPR optimization method based on the developed feature extraction[J]. Journal of Energy Storage, 2024, 83: 110678.

[74] LIN C, TUO X, WU L, et al. Combining Multi-Indirect Features Extraction and Optimized Gaussian Process Regression Algorithm for Online State of Health Estimation of Lithium-Ion Batteries[J]. Journal of Electrochemical Energy Conversion and Storage, 2025, 22(3): 031009.

[75] MEI Z, ZHANG J. Joint Prediction of SOH and RUL for Lithium Batteries Using CPO-BP-AdaBoost and GPR Models[J]. Journal of The Electrochemical Society, 2025, 172(7): 070538.

[76] 王琛, 闵永军. 基于容量增量曲线与GWO-GPR的锂离子电池SOH估计[J]. 储能科学与技术, 2023, 12(11): 3508-3518.
WANG C, MIN Y J. SOH estimation of lithium-ion batteries based on capacity increment curve and
GWO-GPR[J]. Energy Storage Science and Technology, 2023, 12 (11): 3508-3518.

[77] MAWASSI H, HERMANN G, ABDESLAM D O, et al. Optimized FNN-Based SOH Estimation: Methodology and Performance Analysis[C]. International Colloquium on Methods and Tools for Decision Support. Singapore: Springer Nature Singapore, 2024: 393-402.

[78] YE J, XIE Q, LIN M, et al. A method for estimating the state of health of lithium-ion batteries based on physics-informed neural network[J]. Energy, 2024, 294: 130828.

[79] FU Z, SUN B, JIA Y, et al. SOH estimation framework for batteries considering label normalization and feature stability under real-world data[J]. Applied Energy, 2026, 403: 127023.

[80] 于沛, 宫大鹏, 王淑娴, 等. 基于VMD-LSTM的锂电池健康状态预测[J]. 北京石油化工学院学报, 2025, 33(2): 57-63.
YU P, GONG D P, WANG S X, et al. Battery Health State Prediction Based on VMD-LSTM[J]. Journal of Beijing Institute of Petrochemical Technology, 2025, 33(2): 57-63.

[81] BHARATH Y K, ANANDU V P, VINATHA U, et al. Long - Term Estimation of SOH Using Cascaded LSTM - RNN for Lithium Batteries Subjected to Aging and Accelerated Degradation[J]. Energy Storage, 2024, 6(8): e70066.

[82] 汪晓璐, 赵筛筛, 张朝龙. 基于等压能量分析与CNN-GRU-MHA的锂电池SOH估计方法[J]. 电气工程学报, 2025, 20(3): 233-241.
WANG X L, ZHAO S S, ZHANG C L. SOH Estimation Method for Lithium Batteries Based on Isobaric Energy Analysis and CNN-GRU-MHA[J]. Journal of Electrical Engineering, 2025, 20(3): 233-241.

[83] 谢小鹏, 王银河, 熊鹏宇, 等. 基于贝叶斯优化BiLSTM的锂电池SOH预测[J]. 电源技术, 2025, 49(5): 1013-1018.
XIE X P, WANG Y H, XIONG P Y, et al. SOH prediction of lithium batteries based on Bayesian-optimized BiLSTM[J]. Chinese Journal of Power Sources, 2025, 49(5): 1013-1018.

[84] HUANG X, WEI J, HUANG J, et al. Enhanced Lithium-Ion Battery SOH Estimation Using Bayesian-Optimized CNN Deep Learning Approach[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2024, 38(11): 2452020.

[85] CHENG K, ZHANG C, SHAO K, et al. A SOH Estimation Method for Lithium-Ion Batteries Based on CPA and CNN-KAN[J]. Batteries, 2025, 11(7): 238.

[86] HUANG J, HE T, ZHU W, et al. A lithium-ion battery SOH estimation method based on temporal pattern attention mechanism and CNN-LSTM model[J]. Computers and Electrical Engineering, 2025, 122: 109930.

[87] LI Y, QIN X, CHAI M, et al. SOH evaluation and RUL estimation of lithium-ion batteries based on MC-CNN-TimesNet model[J]. Reliability Engineering & System Safety, 2025, 261: 111125.

[88] YAO W, LAI R, TIAN Y, et al. State of health estimation of lithium-ion batteries using data augmentation and feature map[J]. IEEE Transactions on Transportation Electrification, 2024.

[89] LIU X, GAO Z, TIAN J, et al. State of health estimation for lithium-ion batteries using voltage curves reconstruction by conditional generative adversarial network[J]. IEEE Transactions on Transportation Electrification, 2024, 10(4): 10557-10567.

[90] WONG K L, CHOU K S, TSE R, et al. A novel fusion approach consisting of GAN and state-of-charge estimator for synthetic battery operation data generation[J]. Electronics, 2023, 12 (3): 657.

[91] RAJASEKARAN E, VENKATANARAYANAN S. State-of-Health (SoH) prediction for electric vehicle battery systems using GAN-based models with triple attention mechanisms[J]. Journal of Energy Storage, 2025, 134: 118143.

[92] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need[C]. Red Hook: Curran Associates, 2017: 5998-6008.

[93] CHEN Y, HUANG X, HE Y, et al. Edge–cloud collaborative estimation lithium-ion battery SOH based on MEWOA-VMD and Transformer[J]. Journal of Energy Storage, 2024, 99: 113388.

[94] GU X, SEE K W, LI P, et al. A novel state-of-health estimation for the lithium-ion battery using a convolutional neural network and transformer model[J]. Energy, 2023, 262: 125501.

[95] LIU Z, LIU Y, ZHANG Y, et al. Data-driven lithium-ion battery SOH prediction: A novel SHMM-transformer-BiGRU hybrid neural network method[J]. Measurement, 2025: 118579.

[96] PARK S, KIM Y, YOO R, et al. Transformer-based framework for configuration-agnostic Li-ion battery SoH estimation by exploring novel health indicators[J]. Chemical Engineering Journal, 2025: 172197.

[97] 郭向伟, 袁江龙, 陈岗, 等. 基于改进领域自适应迁移学习的锂电池SOH估计[J]. 电子测量与仪器学报, 2026, 40(1): 81-90.
GUO X W, YUAN J L, CHEN G, et al. SOH Estimation for Lithium Batteries Based on Improved Domain Adaptive Transfer Learning [J]. Journal of Electronic Measurement and Instrumentation, 2026, 40(1): 81-90.

[98] LANUBILE A, BOSONI P, POZZATO G, et al. Domain knowledge-guided machine learning framework for state of health estimation in Lithium-ion batteries[J]. Communications Engineering, 2024, 3 (1): 168.

[99] ZHOU Q, ANDERSON D, SUN J. State of health estimation for battery modules with parallel-connected cells under cell-to-cell variations[J]. ETransportation, 2024, 22: 100346.

[100] 谢国民, 刘澳. 基于混合特征提取和机器学习的锂离子电池健康状态估计[J]. 电力系统自动化, 2025, 49(21): 120-134.
XIE G M, LIU A, et al. State of Health Estimation for Lithium-ion Batteries Based on Hybrid Feature Extraction and Machine Learning[J]. Automation of Electric Power Systems, 2025, 49(21): 120-134.

[101] SHI Z G , XU J Z, AL-WESABI I, et al. Accurate state of health estimation based on the multi-feature extracted and improved MHA assisted CNN-BiGRU model for lithium-ion batteries[J]. Journal of Energy Storage, 2025, 131: 117598.

[102] LI S H, JIANG Z L, ZHU Z W, et al. A framework of joint SOC and SOH estimation for lithium-ion batteries: Using BiLSTM as a battery model[J]. Journal of Power Sources, 2025, 635: 236342.

[103] 张彬桥, 邹霖, 万刚. 基于SAO-BiLSTM-KAN的电池健康状态估计[J]. 浙江电力, 2026, 45(1): 57-65.
ZHANG B Q, ZOU L, WAN G. SOH estimation for lithium-ion batteries based on SAO-BiLSTM-KAN[J]. Zhejiang Electric Power, 2026, 45(1): 57-65.

[104] SHAO L Y , ZHANG Y, ZHENG X J, et al. SOH estimation of lithium-ion batteries subject to partly missing data: A Kolmogorov-Arnold-Linformer model[J]. Neurocomputing, 2025, 638: 130181.

[105] ZHOU K Q, QIN Y, YUEN C. Graph neural network-based lithium-ion battery state of health estimation using partial discharging curve[J]. Journal of Energy Storage, 2024, 100: 113502.

[106] WEN J, JIA C, XIA G. State of health prediction of lithium-ion batteries for driving conditions based on full parameter domain sparrow search algorithm and dual-module bidirectional gated recurrent unit[J]. Energy, 2025: 138292.

[107] JIA C, XIA G, SHI Y, et al. Incremental capacity-based multi-feature fusion model for predicting state-of-health of lithium-ion batteries[J]. IEEE Transactions on Instrumentation and Measurement, 2025.

[108] YANG N, SONG Z, HOFMANN H, et al. Robust State of Health estimation of lithium-ion batteries using convolutional neural network and random forest[J]. Journal of Energy Storage, 2022, 48: 103857.

[109] HUOTARI M, ARORA S, MALHI A, et al. Comparing seven methods for state-of-health time series prediction for the lithium-ion battery packs of forklifts[J]. Applied Soft Computing, 2021, 111: 107670.