

DOI:10.20189/j.cnki.CN/61-1527/E.202605010

基于自适应增强与集成学习的锂离子 电池健康状态预测方法

张 严, 郑建飞, 张 鑫, 韩其辉, 涂 锐

(火箭军工程大学, 西安 710025)

摘 要: 针对锂离子电池退化过程中存在非线性强、特征复杂以及单一模型泛化能力有限等问题, 提出一种基于自适应增强(adaptive boosting, AdaBoost)与集成学习的锂离子电池健康状态(state of health, SOH)预测模型。首先, 从电池增量容量曲线和充放电温度曲线中提取幅值、位置和面积等多维特征, 构建 8 类健康因子(health indicators, HIs), 并通过 Pearson 相关性分析验证其有效性; 其次, 利用卷积神经网络(convolutional neural network, CNN)提取局部退化特征, 采用双向门控循环单元(bidirectional gated recurrent unit, BiGRU)刻画电池退化动态演化规律, 并引入自注意力机制(self-attention mechanism, SAM)增强模型对关键退化信息的感知能力, 三者共同构成弱学习器, 并通过 AdaBoost 集成策略融合为强预测器, 从而提升模型预测精度与鲁棒性; 最后, 在 NASA、CALCE 和 Oxford 三组数据集上进行验证。实验结果表明: 所提方法具有较高的预测精度和良好的泛化能力, 能够准确跟踪电池全生命周期 SOH 退化轨迹, 并有效降低老化后期误差波动, 平均绝对误差和均方根误差分别低至 0.002 913 和 0.004 146; 此外, 所提算法在跨数据集迁移场景中, 仅需目标电池全部运行数据的 10% 即可实现对其 SOH 的高精度预测。

关键词: 锂离子电池; 健康状态预测; 集成学习; 健康因子; 自适应增强算法

中图分类号: TM912

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2026)05-0104-12



听
音
音
聊
科
研
与
作
者
互
动

锂离子电池凭借高能量密度、长使用寿命和无记忆效应等优势^[1], 被广泛应用于新能源汽车、武器装备、储能电站和便携式电子设备等领域^[2]。然而, 随着日历老化与循环老化的持续演进, 电池的性能状态和可用容量不可避免地发生衰减^[3-4]。这种非线性退化不仅造成电池使用性、可靠性和安全性持续下降, 更使电池主动安全运维与智能化管控面临严峻挑战^[5]。因此, 准确预测锂离子电池健康状态(state of health, SOH)对保障系统安全运行^[6]、优化充放电策略^[7]和制定科学维护方案^[8]具有重要意义。

近年来, 健康管理预测技术(prognostics and health management, PHM)在电池 SOH 预测领域

发展迅猛。现有研究方法主要包括基于实验室测量^[9]、基于物理化学模型^[10]和基于数据驱动^[11] 3 类, 这些方法在实现路径、适用场景与性能表现等方面存在显著差异。基于实验室测量的方法主要通过直接测试电池关键性能参数获取其退化信息, 常用方法包括库伦计数法、开路电压法和电化学阻抗谱法(electrochemical impedance spectroscopy, EIS)等。Lee 等^[12]提出了一种增强库伦计数法, 并将其用于电池荷电状态(state of charge, SOC)和 SOH 联合估计。Pang 等^[13]基于部分 EIS 曲线, 实现了对电池 SOH 的实时估计。这类方法原理简单、物理意义明确, 但无法实现在线监测, 通常仅作

收稿日期: 2026-03-31

修回日期: 2026-04-26

录用日期: 2026-05-23

基金项目: 国家自然科学基金(62227814, 62233017, 62373369)

第一作者: 张严(1996—), 男, 博士研究生, 主要从事电池智能管理研究。

引用格式: 张严, 郑建飞, 张鑫, 等. 基于自适应增强与集成学习的锂离子电池健康状态预测方法[J]. 火箭军工程大学学报, 2026, 40(5): 104-115. Zhang Yan, Zheng Jianfei, Zhang Xin, et al. Adaptive boosting and ensemble learning-based state of health prediction method for lithium-ion batteries[J]. Journal of Rocket Force University of Engineering, 2026, 40(5): 104-115.

为标定基准^[14]。

锂离子电池本质上是一种参数时变的电化学反应,其运行过程涉及离子传输、热对流和界面反应等多物理场耦合^[15]。针对实验室测量存在通用性差、测试周期较长等问题,研究人员提出了基于物理化学模型的方法。该类方法通过构建电池电化学反应机理模型或外部等效电路模型,结合状态估计算法实现 SOH 的在线估计^[16],常见模型主要包括伪二维模型、二阶 RC 模型、分数阶模型和多物理场耦合模型等。Zhang 等^[17]从等效电路模型中提取了 6 个关键物理参数,将其用于电池剩余寿命预测任务。Shan 等^[18]提出将智能优化算法与伪二维模型相结合,实现了不同工况下的电池 SOH 精准预测。尽管基于电池物理化学模型的方法具有较强的可解释性,但其求解过程较为复杂,对模型结构和参数精度的依赖性较强,无法彻底解决参数漂移问题。

基于数据驱动的方法凭借无需先验机理知识和具备强大的非线性拟合能力,逐渐成为电池预测领域的研究热点^[19]。该类方法通过深入挖掘电压、电流和温度等多源异构数据中的老化信息,构建起从观测数据到 SOH 状态空间的映射模型。常用算法包括高斯过程回归(Gaussian process regression, GPR)、支持向量机(support vector machine, SVM)以及各类深度神经网络等。郑启达等^[20]提出了在线顺序极限学习机算法,并将其用于电池 SOH 预测任务。胡远志等^[21]将长短期记忆网络(long short-term memory, LSTM)与 Informer 网络相融合,实现了电池 SOH 的在线估计。尽管数据驱动方法在刻画电池非线性退化轨迹方面表现优异,并在单一工况或单一电池类型的预测任务中取得了较高精度,但其仍存在一定的局限性。一方面,现有方法多依赖单一模型,特征表征能力有限,难以同时兼顾局部退化特征、全局时序演化规律及关键退化信息,缺乏多时空尺度特征融合能力,导致对复杂退化过程的耦合建模不足;另一方面,健康因子构建不够系统,部分研究多集中于单一维度特征,缺乏与 SOH 之间相关性的充分验证,输入特征有效性不足,从而影响模型预测精度。此外,现有模型通常仅在单一数据集或单一工况下进行训练与验证,当面向跨电池类型、多工况场景时,由于退化特征和数据分布差异显著,模型性能会明显下降,难以兼顾预测精度与鲁棒性,从而限制了其在工程应用中的推广。

综上,锂离子电池 SOH 预测在复杂退化过程、

多源信息协同表征和跨场景泛化应用等方面仍面临诸多挑战。具体而言,电池退化过程受温度、充放电倍率、循环深度和运行环境等多因素共同影响,其老化轨迹呈现显著的非线性、时变性和差异性,即使同类型电池在相同运行条件下也可能表现出不同的衰退规律,导致其 SOH 演化过程难以被精确刻画。同时,实际采集的电压、电流、温度及增量容量等多源数据存在复杂关联,关键退化特征难以被有效提取,进一步限制了观测数据与电池 SOH 状态间映射关系的建立。此外,不同电池材料体系、运行条件及退化模式间存在明显差异,导致不同应用场景间数据分布发生偏移,使模型在跨电池类型、跨工况和跨数据集迁移过程中面临性能退化问题,难以满足实际应用对高精度、高可靠性 SOH 预测的需求。

基于此,本文提出一种基于自适应增强(adaptive boosting, AdaBoost)与集成学习的锂离子电池 SOH 预测模型。该模型融合了特征工程、时序建模、集成优化和注意力机制等多种技术,利用 AdaBoost 对多个 CNN-BiGRU-SAM 弱学习器进行自适应迭代集成,以提升模型对关键退化特征的表征能力,从而实现对电池 SOH 的高精度预测。该模型围绕实际工程应用与复杂工况环境下电池 SOH 预测关键问题构建针对性解决路径,其中 CNN 用于提取局部退化特征、BiGRU 用于捕捉全局时序演化规律, SAM 则用于强化关键退化信息感知,从而实现多时空尺度特征的深度耦合,弥补了单一模型特征表征的局限性。针对电池退化轨迹差异化的问题,利用 AdaBoost 集成策略的自适应权重机制,通过迭代训练来动态调整样本权重与弱学习器权重,对退化轨迹复杂、预测误差大的样本赋予更高权重,使模型聚焦于差异化退化特征的学习,同时通过多个弱学习器的加权融合,综合各学习器的优势,有效适配不同电池、不同工况下的差异化退化轨迹,最终实现电池 SOH 的高精度、强泛化预测。

1 基础理论

1.1 电池 SOH 定义

SOH 是表征锂离子电池性能衰减程度的重要指标,通常定义为电池当前实际容量与额定容量的比值,计算公式为

$$S_{OH} = \frac{Q_c}{Q_n} \times 100\% \quad (1)$$

式中: S_{OH} 为当前电池健康状态; Q_c 为电池当前实际容

量; Q_n 为电池额定容量。电池 SOH 能够直观反映电池老化程度, 是电池状态评估与寿命预测的重要依据。

1.2 卷积神经网络

卷积神经网络(convolutional neural network, CNN)具有局部连接和权值共享等特点, 能够从原始数据中自动提取局部特征, 并有效减少模型参数, 因此被广泛应用于复杂系统的特征提取与非线性建模^[22]。通常, CNN 网络由输入层、卷积层、池化层、全连接层和输出层组成。其中, 输入层主要完成数据标准化与维度对齐, 为后续特征学习提供高质量输入; 卷积层通过卷积核在输入数据上的局部滑动运算来提取局部关联特征; 池化层通过对卷积层输出特征进行下采样, 在降低特征维度和计算复杂度的同时, 增强模型对局部扰动和噪声的鲁棒性; 全连接层则对前序各层提取的局部特征进行非线性整合与全局映射, 从而形成更高层次的特征表示^[23]。

1.3 双向门控循环单元

门控循环单元(gated recurrent unit, GRU)通过引入门控单元机制, 能够有效缓解循环神经网络中的梯度消失和梯度爆炸问题, 从而提升对时序信息的建模能力。具体而言, GRU 通过更新门和重置门对历史信息与当前输入信息进行自适应筛选和融合, 从而实现对时序信息的动态调节与高效传递^[24-25]。其中, 重置门用于调节历史隐藏状态对当前候选隐藏状态计算的影响程度, 以保留与当前输入相关的关键信息; 更新门用于控制历史隐藏状态与候选隐藏状态间的融合比例, 从而抑制冗余信息干扰。具体计算公式为

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (2)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (3)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t] + b_h) \quad (4)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (5)$$

式中: $\sigma(\cdot)$ 为 Sigmoid 激活函数; x_t 为当前时刻的输入特征; $\odot$ 为逐元素乘法; r_t 和 z_t 为当前时刻下的重置门和更新门输出; $\tilde{h}_t$ 和 h_t 分别为当前时刻的候选隐藏状态和最终隐藏状态; h_{t-1} 为前一时刻下的最终隐藏状态; W_r 、 W_z 和 W_h 为权重矩阵; b_r 、 b_z 和 b_h 为偏置。

在此基础上, 双向门控循环单元(bidirectional gated recurrent unit, BiGRU)通过同时引入前向和后向 2 个 GRU 结构, 对序列的双向依赖关系进行建模。BiGRU 能够同时利用历史信息和未来信息, 并通过融合双向特征, 实现对时序数据的双向建模与

表征^[26]。

1.4 自注意力机制

自注意力机制(self-attention mechanism, SAM)作为一种高效的特征增强机制, 能够精准聚焦输入序列中的关键片段, 同时有效过滤无关或冗余信息, 因此被广泛应用于复杂时序信号的显著性表征^[27]。具体而言, SAM 通过计算输入序列不同位置之间的相关性, 自适应分配特征权重, 从而突出关键信息并抑制冗余信息。注意力权重计算公式为

$$\alpha_{ij} = \frac{\exp(g_{ij})}{\sum_{k=1}^T \exp(g_{ik})} \quad (6)$$

式中: g_{ij} 为位置 i 与位置 j 之间的相关性得分; T 为输入序列长度。

1.5 AdaBoost 集成策略

AdaBoost 作为一种典型的集成学习方法, 其核心思想是通过迭代训练多个弱学习器, 并自适应地调整样本权重与学习器权重, 最终将多个弱学习器加权集成为一个高精度的强学习器^[28], 具体流程如下。

1) 样本权重初始化。在算法初始阶段, 为训练集中的各样本赋予相同的权重, 从而构成初始样本权重分布矩阵 D_1 , 表达式为

$$D_1 = [\omega_{1,1} \ \omega_{1,2} \ \dots \ \omega_{1,N}], \omega_{1,i} = \frac{1}{N} \quad (7)$$

式中: $\omega_{1,i}$ 为第 i 个训练样本在初始阶段的权重; N 为训练样本总数。

2) 弱预测器的权重计算。在第 m 轮迭代中, 根据当前样本权重分布训练得到第 m 个弱预测器, 并计算其在训练集上的预测误差。随后, 依据预设误差阈值进一步计算该弱预测器的总体误差率, 并根据误差率确定其对应的权重系数, 从而表征该弱预测器在最终集成模型中的贡献度。误差率计算公式为

$$e_{m,i} = |G_m(X_i) - Y_i| \quad (8)$$

式中: $e_{m,i}$ 为第 m 轮迭代中第 i 个训练样本的预测误差; $G_m(\cdot)$ 为第 m 个弱预测器; Y_i 为第 i 个训练样本的真实标签; X_i 为第 i 个训练样本的输入特征。

3) 强预测模型构建。在完成第 m 轮训练后, 算法根据预测性能对样本权重进行动态调整, 构建新的样本权重分布 D_{m+1} 。该机制通过增强高误差样本的关注度、降低低误差样本的影响, 使模型能够在后续迭代中更有效地捕捉电池非线性退化中的复杂特征。具体计算过程为

$$D_{m+1} = [\omega_{m+1,1} \ \omega_{m+1,2} \ \dots \ \omega_{m+1,N}] \quad (9)$$

$$\omega_{m+1,i} = \begin{cases} \frac{\omega_{m,i}}{Z_m} \times 1.1 & e_{m,i} > \theta \\ \frac{\omega_{m,i}}{Z_m} & e_{m,i} \leq \theta \end{cases} \quad (10)$$

式中: $Z_m = \sum_{i=1}^N \omega_{m,i}$ 为归一化因子; θ 为预设误差阈值。在完成预设的全部迭代轮次后,算法根据各弱预测器的权重系数进行线性加权融合,最终构建具备高泛化能力的强预测模型。

AdaBoost 集成策略计算成本可控,本地化部署简单。在计算资源消耗方面,通过设置 3 个计算量较小的学习器和 500 次迭代来平衡模型预测精度与计算成本,普通 CPU 单轮训练时间为 10~15 min,满足在线检测需求。从本地化部署成本来看,本文所采用的 AdaBoost 集成策略具有部署门槛低、成本可控的优势。一方面,AdaBoost 算法本身结构简洁、逻辑清晰,无需依赖高端算力硬件,可基于普通工业控制芯片或边缘计算设备实现本地化部署,无需购置高性能服务器,大幅降低了硬件部署成本;另一方面,本文选用的 CNN-BiGRU-SAM 弱学习器已通过权值共享、丢弃层设置等方式简化了模型结构,减少了参数数量,降低了模型对存储资源的需求,进一步降低了本地化部署的硬件成本。此外,AdaBoost 的迭代训练过程可在云端完成,本地

化部署仅需加载训练好的强预测模型进行推理,无需现场进行复杂的迭代训练,降低了本地化部署的操作难度和运维成本。

2 AdaBoost-CNN-BiGRU-SAM 算法

准确预测锂离子电池 SOH 是实现电池退化状态评估、突发故障预防和主动安全预警的重要前提。然而,锂离子电池老化过程受内部电化学反应、环境温度、充放电工况及材料性能衰退等多重因素共同影响,其退化行为呈现出显著的非线性、时变性和个体差异性,导致传统单一模型在 SOH 预测任务中存在特征提取不充分、预测精度受限及泛化能力不足等问题。针对上述问题,本文提出了一种基于 AdaBoost 与集成学习的锂离子电池 SOH 预测模型。从电池增量容量(incremental capacity, IC)曲线及充放电温度曲线中提取 8 类健康因子(health indicators, HIs)作为输入特征,利用 AdaBoost 对训练样本进行自适应重加权,并对多个 CNN-BiGRU-SAM 弱学习器进行迭代训练与误差反馈,最终实现对锂离子电池 SOH 的高精度预测。图 1 为所提算法的整体框架,具体流程如下。




图 1 所提算法的整体框架

Fig. 1 Overall framework of the proposed algorithm

1)数据预处理及 SOH 提取。原始充放电数据

中包含大量噪声与冗余信息,直接输入模型会显著

降低其预测性能,因此数据预处理与 SOH 提取是模型构建的基础。本文通过对 NASA、CALCE 和 Oxford 数据集中的原始充放电数据进行清洗与重构,剔除噪声样本与无效数据,并按充放电周期整理为标准老化序列,为后续特征提取提供高质量数据载体。同时,根据电池当前可用容量与初始额定容量计算各循环对应的 SOH 值,明确模型输出目标,为特征与 SOH 间映射关系的建立奠定基础。

2)IC 曲线构建与 HIs 提取。考虑到电池 IC 曲线和充放电温度曲线特征参数与电池老化机理具有强耦合性,本文将 IC 曲线作为表征电池内部状态变化及容量衰退特征的核心载体^[29]。具体而言,基于电池充电电压-容量曲线构建 IC 曲线,从幅值、位置、面积 3 个维度提取 6 类 HIs;同时,针对内部非均匀热边界条件,引入充电温度峰值时间和放电温度峰值时间两类温度特征,以全面刻画电池老化过程中的电化学与热特性变化。进一步通过 Pearson 相关性分析验证各 HIs 与 SOH 之间的相关性,确保所构建特征集的有效性,为后续模型精准捕捉退化规律提供高质量输入,并避免冗余特征对模型性能的干扰。

3)弱学习器构建与 AdaBoost 集成训练。针对单一模型难以兼顾局部特征挖掘、全局时序建模及关键信息识别的缺陷,本文将 CNN-BiGRU-SAM 作为 AdaBoost 框架中的弱学习器,通过多模块协同实现对电池退化特征的全方位表征,为 AdaBoost 集成优化提供高性能基础学习单元。其中,CNN 凭借局部连接与权值共享的特性,能够精准提取并捕捉电池老化过程中的局部退化特征;BiGRU 通过双向时序建模能力,有效捕捉电池老化过程中的动态演化规律,解决了传统时序模型难以兼顾历史与未来退化信息的问题;SAM 则通过自适应分配特征权重,强化模型对关键退化信息的感知能力,有效弥补了传统模型对不同特征贡献度无差异化区分的不足。在此基础上,AdaBoost 集成策略通过迭代训练与自适应权重更新机制,对多个 CNN-BiGRU-SAM 弱学习器进行融合,重点提升模型对复杂非线性退化样本的表征能力,通过动态调整样本权重,使模型在迭代过程中聚焦于高误差样本,逐步弥补单一弱学习器的预测缺陷,最终融合形成高精度强预测器。

4)电池 SOH 预测与模型性能评估。模型训练完成后的 SOH 预测与性能评估是验证所提方法有效性的关键环节,也是衔接模型构建与工程应用的重要步骤。本文将测试样本输入所提模型中,实现

对锂离子电池全生命周期 SOH 演化过程的精准预测,同时采用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)等评价指标进行定量分析,并结合多数据集、多工况及跨电池类型预测任务的对比分析,系统评价了模型的预测精度与泛化能力。

3 实验验证与结果分析

为系统评估所提模型在不同老化工况、不同电池类型及不同预测场景下的适用性与鲁棒性,本文选取 3 组公开电池老化数据集开展实验研究。通过健康因子提取、相关性分析以及多模型对比等手段,对模型预测性能进行定量评价,并从数据集特性、特征构建逻辑和预测结果 3 个层面展开深入分析,以验证所提方法在复杂工况和跨电池类型场景下的有效性与优越性。网络参数设置参考深度学习模型中常用设置原则,并结合验证集的预测误差进行优化调整,在保证模型收敛性能和预测精度的同时,兼顾模型复杂度与计算成本,最终确定本文模型的网络参数如表 1 所示。

表 1 所提模型的网络参数设置

Table 1 Network parameters of the proposed model

参数	设定值
迭代次数/次	500
学习率	0.001
正则化系数	0.000 1
注意力机制键值	50
丢弃率	0.1
GRU 神经元个数/个	128
学习器个数/个	3

3.1 数据集描述

锂离子电池老化过程受材料体系、生产工艺及外部环境等多重因素共同影响,不同数据集往往表现出差异化的性能退化特征。因此,本文分别选取 NASA、CALCE 和 Oxford 公开锂离子电池老化数据集作为实验对象,以全面评估所提模型在多种场景下的预测性能和泛化能力。

NASA 数据集来源于 Ames 研究中心开展的 18650 型锂离子电池常温循环老化实验^[30]。本文选取 B0005 电池作为实验对象,其额定容量为 2 Ah,正极材料为镍钴铝酸锂。实验在 25 ℃ 恒温箱内进行,采用恒流恒压充电协议。NASA 数据集的显著特征在于电池容量退化过程中伴随频繁的

容量回升现象,即电池在静置阶段由于内部电化学梯度恢复而表现出局部非线性波动。

CALCE 数据集来源于马里兰大学先进生命周期工程中心开展的方形锂离子电池常温老化实验^[31]。本文选取其中的 CS2-35 作为训练对象,CS2-36 和 CS2-37 作为测试对象,其额定容量为 1.1 Ah,正极材料为钴酸锂。实验在 25 °C 恒温箱内进行,采用 0.5C 充放电倍率开展加速老化测试,记录电池从初始状态至寿命终点(end of life,EOL)的全生命周期退化数据。CALCE 数据集容量衰减趋势相对平稳,能够反映电池退化的动态演化规律,适用于评估模型对电池退化趋势的拟合能力。

Oxford 数据集来源于牛津大学开展的软包锂离子电池高温老化实验^[32]。本文选取其中的 Cell1 作为训练对象,Cell3 和 Cell8 作为测试对象,其标称容量为 0.74 Ah,正极材料为镍锰钴酸锂。实验在 40 °C 恒温箱内进行,采用 1C 充放电倍率开展加速老化测试。Oxford 数据集旨在通过加速老化实验模拟极端热环境下的电池退化行为,适用于验证模型在复杂环境条件下的预测精度和泛化能力。

3.2 HIs 提取

构建 IC 曲线是表征锂离子电池内部状态变化及容量衰退特征的重要分析手段,其基本原理为:在电池充放电过程中,容量会随电压变化呈现出不同的增量特征,通过计算容量对电压的一阶导数可获得 IC 曲线。随着电池充放电次数不断增加,受锂离子损失(lithium inventory loss,LLI)与活性物质损失(loss of active material,LAM)等机理影响,IC 曲线的峰值位置、峰值高度和峰形特征会发生显著变化。因此,基于 IC 曲线特征参数的提取与分析,可有效解耦电池容量退化规律,并为电池 SOH 预测提供关键支撑。图 2 为 NASA-B0005 充放电循环信息及 IC 曲线。图中, Q 表示电池容量,单位为 Ah; U 表示电池端电压,单位为 V。







图 2 NASA-B0005 充放电循环信息及 IC 曲线

Fig. 2 Charging and discharging cycle information and IC curves of NASA-B0005

如图 2(a) 所示,随着循环次数的增加,充电电压曲线整体变化趋势基本一致,但后期循环达到截止电压所需时间逐渐缩短,电池容量持续衰减,同时极化程度逐渐增强。图 2(b) 展示了充电电流演化规律,随着老化程度的增加,恒压阶段电流衰减速度加快,容量衰减与内阻增长对充电动态过程的影响逐渐增强。图 2(c) 给出了充电温度变化过程,不同循环阶段下温度变化趋势基本一致,但温度峰值及对应位置随循环发生偏移,电池老化过程中的产热特性随之变化。图 2(d) 为 IC 曲线演化结果,随着循环次数增加,IC 峰值逐渐降低并发生偏移,

峰形逐渐变宽,LLI、LAM 及极化增强等退化机制持续累积。综上所述,充电电压、电流、温度与 IC 特征均能够从不同维度描述电池退化过程,为后续健康状态评估提供特征依据。

在实验环境中,由于充放电深度具有随机性且数据采集过程存在非连续性,因而难以获取覆盖电池全生命周期的完整循环数据。同时,原始数据易受噪声干扰,直接建模将显著影响特征提取的有效性。因此,有必要通过滤波预处理来提升数据质量。为此,本文选取两种典型滤波方法(移动平均滤波和中值滤波)进行对比分析,并从噪声抑制能力与特征保留完整性两个方面进行综合评估,最终确定采用中值滤波对数据进行预处理。在此基础上,基于滤波后的充电 IC 曲线及充放电温度曲线,提取 8 类 HIs。其中,IC 曲线特征从幅值、位置和面积 3 个维度进行系统表征,以刻画电池内部电化学退化行为,同时引入温度特征以反映电池热响应特性,从而在电化学与热行为两个层面揭示电池老化过程与 SOH 之间的内在映射关系,确保所提特征能够较为全面地反映电池老化状态,具体特征定义如下。

1)幅值特征:将 IC 曲线的峰值和平均值分别定义为 HIs1 和 HIs3。其中,HIs1 用于表征特定电压区间(3.7~4.2 V)内的电化学反应活性;HIs3 旨在刻画电池老化过程中的退化轨迹。

2)位置特征:将 IC 峰值对应的电压定义为 HIs2,以表征电池老化过程中电化学相变点的热力学漂移行为。

3)面积特征:将 IC 曲线总面积以及峰值左、右两侧面积分别定义为 HIs4、HIs5 和 HIs6。其中,HIs4 用于表征电池有效充电容量;HIs5 和 HIs6 分别用于刻画 IC 曲线在不同子区间内的非对称演化特征。

4)温度特征:将充电温度峰值时间和放电温度峰值时间分别定义为 HIs7 和 HIs8。其中,HIs7 用于表征充电过程中电池热行为随老化进程的动态演化;HIs8 用于刻画放电阶段热响应特性与电池健康状态的内在关联。

为验证所构建 HIs 与电池 SOH 间的相关性,本文采用 Pearson 相关系数进行定量分析,其计算公式为

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (11)$$

式中: r 为 Pearson 相关系数; x_i 和 y_i 分别为输入变

量与真实值; $\bar{x}$ 和 $\bar{y}$ 分别为输入变量与目标变量的均值; n 为变量总数。一般而言,当相关系数大于 0.8 时,表明变量间具有较强的相关性;当相关系数小于 0.8 时,则表明变量间的相关性较弱。为验证所提取 HIs 在不同电池体系下的普适性和鲁棒性,本文基于 NASA、CALCE 和 Oxford 数据集,绘制了 HIs 与 SOH 间 Pearson 相关系数热图,结果如图 3 所示。由图 3 可得,所提取的健康因子在 3 组数据集中均与 SOH 保持较高相关性,验证了这些特征在电池 SOH 表征中的有效性和跨数据集应用潜力。




图 3 Pearson 相关系数热图

Fig. 3 Heat map of Pearson correlation coefficients

3.3 消融实验

为验证所提算法在电池 SOH 预测中的有效性和可靠性,本文将提取的 8 类 HIs 作为模型输入,并在不同工况和跨电池类型场景下开展性能评估。具体而言,对 NASA 数据集,分别选取 B0005 电池全部循环老化数据的前 50% 和 60% 作为训练集,将训练完成后的模型分别应用至剩余老化数据上进行测试,以评估所提方法对不同退化阶段 SOH 的预测能力,并通过消融实验验证本文所提方法中各关键模块的有效性,相关预测结果如图 4 所示。为进一步验证所提模型的预测精度并对结果进行量化分析,本文选取 MAE 和 RMSE 对预测结果进行量化分析,计算公式为

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$


式中: y_i 为真实值; $\hat{y}_i$ 为预测值。各方法预测误差如表 2 所示。

图 4 为不同模型预测与真实 SOH 退化曲线的对比结果。其中,BiGRU 能有效跟踪 SOH 整体衰减趋势,但随着循环次数的增加,预测曲线与真实退化轨迹间产生严重偏差。引入 CNN 特征提取模块后,CNN-BiGRU 模型预测曲线与真实值的贴合


度显著提升,表明 CNN 模块可有效挖掘退化过程中的局部特征,缓解纯时序模型的偏差漂移问题。引入自注意力机制的 CNN-BiGRU-SAM 模型,在老化后期预测精度略有提升,但仍存在一定程度的误差累积,难以完全匹配真实退化轨迹。与 CNN-BiGRU 模型相比,AdaBoost-CNN-BiGRU 模型预测曲线的稳定性与贴合度均有明显改善,验证了集成学习对模型泛化能力与鲁棒性的增强作用。此外,本文所提模型的预测曲线全程与真实值高度重合,预测区间内无明显偏差累积,展现出最优的长期预测性能,充分证明各模块协同作用的有效性。

由表 2 可知,在两个不同规模的训练集上,各模型预测结果的 MAE 和 RMSE 均随着模块的逐步引入而呈现出明显的下降趋势,模型预测精度不断提升。相较于基准模型 BiGRU, CNN-BiGRU 模型的预测误差明显下降,表明卷积特征提取模块能够增强模型对 SOH 退化特征的特征能力;进一步引入 SAM 注意力机制后,模型误差继续减小,表明注意力机制有助于提升模型对关键退化信息的提取能力;在此基础上,AdaBoost 集成策略进一步优化了模型预测性能。最终,本文所提模型在两个训练集上的预测结果均取得相对最低误差,相较于基础模型 BiGRU 降低了 90% 以上。上述结果表明, CNN 特征提取、SAM 注意力机制与 AdaBoost 集

成策略的协同融合能够有效提升模型对电池退化特征的学习能力,使其在不同训练数据规模下均保持较高的 SOH 预测精度与稳定性。



(a) 电池全部退化数据的 50% 作为训练集



(b) 电池全部退化数据的 60% 作为训练集

图 4 NASA-B0005 不同训练集预测结果

Fig. 4 Prediction results of different training sets in NASA-B0005 dataset

表 2 消融实验结果

Table 2 Results of ablation experiments

训练集类型	SOH 估计算法	预测误差	
		MAE	RMSE
B0005 电池全部 退化数据的 50%	BiGRU	0.041 764	0.061 547
	CNN-BiGRU	0.021 175	0.028 835
	CNN-BiGRU-SAM	0.006 758	0.007 578
	AdaBoost-CNN-BiGRU	0.006 489	0.007 562
	所提算法	0.004 158	0.005 691
B0005 电池全部 退化数据的 60%	BiGRU	0.036 946	0.047 635
	CNN-BiGRU	0.017 264	0.021 215
	CNN-BiGRU-SAM	0.005 628	0.006 129
	AdaBoost-CNN-BiGRU	0.005 014	0.005 896
	所提算法	0.003 296	0.004 077

注:粗体表示每列最优值。

3.4 对比实验

为验证本文所提方法相较于其他预测方法的优越性,在 CALCE 和 Oxford 数据集上开展模型对比实验。具体而言,选用 CS2-35 和 Cell1 电池的全生命周期老化数据作为训练集,分别在 CS2-36 和 Cell3 电池全生命周期老化数据上进行测试,同时将

所提方法与 Bi-TKAN-Att^[27]、Transformer、CNN-LSTM 和 BiGRU 的预测结果进行比较,结果如图 5 所示,各方法预测误差如表 3 所示。

如图 5 所示,本文所提方法在 CALCE 和 Oxford 数据集上均能够较好地跟踪真实 SOH 退化轨迹,预测曲线与真实曲线间保持较高一致性,可有

效捕捉电池长期衰退趋势及局部变化特征。相比之下, BiGRU 模型在老化后期逐渐产生预测偏差, Transformer 和 CNN-LSTM 模型能够描述整体退化趋势,但对部分局部波动特征的拟合能力仍存在不足。Bi-TKAN-Att 的预测结果虽优于上述部分

对比模型,但在局部循环阶段仍存在一定的预测偏离。图 5 中局部放大区域进一步展示了不同模型在细节变化上的差异,本文所提方法在电池老化中后期仍能保持较高的预测一致性,未出现误差随循环推进而持续累积的现象。

表 3 不同训练集下各 SOH 估计算法的误差

Table 3 Errors of various SOH prediction algorithms under different training datasets

测试集类型	SOH 估计算法	预测误差	
		MAE	RMSE
CS2-36 全生命周期老化数据	BiGRU	0.038 177	0.044 170
	CNN-LSTM	0.018 558	0.022 729
	Transformer	0.013 829	0.017 487
	Bi-TKAN-Att ^[27]	0.005 510	0.006 440
	所提算法	0.002 913	0.004 146
Cell3 全生命周期老化数据	BiGRU	0.025 707	0.028 175
	CNN-LSTM	0.018 778	0.021 922
	Transformer	0.015 022	0.017 959
	Bi-TKAN-Att ^[27]	0.006 313	0.007 875
	所提算法	0.003 355	0.004 111

注:粗体表示每列最优值。




图 5 不同模型在 CALCE 和 Oxofrd 数据集上的预测结果

Fig. 5 Prediction results of different models on the CALCE and Oxofrd datasets

由表 3 可知,在 CS2-36 电池全生命周期预测任务中,本文所提方法的预测误差最低,其 MAE 和 RMSE 分别为 0.002 913 和 0.004 146。相比 Bi-TKAN-Att,本文方法的 MAE 和 RMSE 分别降低约 47.13% 和 35.62%;相比 Transformer 模型,误差降

低约 78.94% 和 76.29%;相比 CNN-LSTM 模型,MAE 和 RMSE 分别下降约 84.30% 和 81.76%;相较于 BiGRU 模型,误差降低幅度分别达到 92.37% 和 90.61%。在 Cell3 电池全生命周期预测中,本文方法同样保持最优性能,与 Bi-TKAN-Att 相比,MAE 和 RMSE 分别降低约 46.86% 和 47.80%。上述结果表明,本文方法在不同研究对象和全生命周期预测场景下均具有较高的预测精度,融合多尺度特征提取、时序建模与集成优化策略能够有效提升模型对复杂退化模式的学习能力,增强 SOH 长期预测的稳定性与泛化性能。

3.5 跨数据集验证

为进一步验证所提模型在不同电池类型下的跨数据集迁移能力,本文采用 B0005 电池全生命周期数据作为源域数据集,对模型进行预训练,使其学习通用 SOH 退化特征。随后,将 CS2-37 和 Cell8 电池全生命周期数据作为目标域数据集,并分别选取其 10% 的循环数据用于模型微调,利用迁移后的模型对剩余 90% 的循环数据进行 SOH 预测,跨数据集预测结果如图 6 所示。

由图 6 可知,在仅使用目标域 10% 数据的情况下,模型仍能精准捕捉 SOH 的整体衰减趋势与局部波动特征,未出现明显的偏差累积现象。同时,局部放大图清晰显示,本文模型对 SOH 曲线细微波动的拟合效果较好。尽管目标电池与源域电池

的老化模式、数据分布存在差异,但所提模型仍能通过少量目标域数据实现快速适配,在跨数据集场景下保持较高的预测精度,充分证明了其优异的泛化能力与迁移学习性能。




图6 跨数据集迁移结果

Fig. 6 Results of cross-dataset transfer

4 结论

针对电池 SOH 预测过程中退化机理复杂、特征耦合性强以及单一模型泛化能力差等问题,提出一种基于 AdaBoost 与集成学习的锂离子电池 SOH 预测模型。该模型能够有效融合多维健康因子信息,充分挖掘电池老化过程中的局部退化特征、时序演化规律和关键退化信息,有效提升了 SOH 的预测精度,可为电池寿命预测、故障预警及安全运维提供理论参考和技术支撑,主要结论如下。

1) 基于电池 IC 曲线和充放电温度曲线,提取了幅值特征、位置特征和面积特征共 8 类 HIs,并通过相关性分析验证其与电池 SOH 间的关联性。结果表明,所构建的 8 类 HIs 与电池 SOH 均具有强相关性,相关性系数的绝对值均超过 0.8,可有效表征电池容量衰退过程中的关键退化信息,为 SOH 预测模型提供可靠的特征基础;

2) 本文以多维 HIs 作为模型输入,构建了基于 CNN-BiGRU-SAM 的弱学习器,并进一步引入 AdaBoost 集成框架对多个弱学习器进行加权融合优化,实现了局部退化特征、时序演化规律与关键退化信息

的协同表征。消融实验中,本文方法在仅使用 B0005 电池全部退化数据的 50% 作为训练集的情况下,其预测结果的 MAE 和 RMSE 分别达到 0.004 158 和 0.005 691,相较于基础模型 BiGRU 降低了 90% 以上。

3) 本文在 CALCE 和 Oxford 电池数据集上开展了不同模型的对比实验及本文方法的跨数据集迁移实验。结果表明,所提方法在不同电池类型和退化场景下均具有较高的预测精度,并且可以有效提取不同电池类型间的共性退化特征,在有限目标域样本条件下仍具备良好的适应性和泛化能力。

参考文献

- [1] Zhang Yan, Zheng Jianfei, Pei Hong, et al. Multi-task learning in battery lifecycle management: from lab to field[J]. Energy Storage Materials, 2026, 87: 105049.
- [2] 邵焕峥. 基于大数据与深度学习的锂电池 SOC 与 SOH 联合评估方法[J]. 储能科学与技术, 2025, 14(9): 3564-3566.
Shao Huanzheng. Joint evaluation method for SOC and SOH of lithium batteries based on big data and deep learning[J]. Energy Storage Science and Technology, 2025, 14(9): 3564-3566.
- [3] 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 Qing, Di Zhenguo, Ji Shengchang. Review on health state estimation and life prediction of lithium-ion batteries[J]. High Voltage Engineering, 2024, 50(3): 1182-1195.
- [4] Hu Xiaosong, Xu Le, Lin Xianke, et al. Battery lifetime prognostics[J]. Joule, 2020, 4(2): 310-346.
- [5] Zheng Jianfei, Ren Jincheng, Zhang Jianxun, et al. A lifetime prediction method for lithium-ion batteries considering storage degradation of spare parts[J]. Energy, 2023, 282: 128460.
- [6] Chen Jianguo, Han Xuebin, Sun Tao, et al. Analysis and prediction of battery aging modes based on transfer learning[J]. Applied Energy, 2024, 356: 122330.
- [7] Wang Lei, Qiu Yong, Yuan Wenchuang, et al. Next-generation battery safety management: machine learning assisted life-time prediction and performance enhancement[J]. Journal of Energy Chemistry, 2025, 109: 726-739.
- [8] 任超, 司小胜, 张正新. 退化模型动态校准的备件订购与替换联合决策[J]. 火箭军工程大学学报, 2025, 39(4): 22-31.

- Ren Chao, Si Xiaosheng, Zhang Zhengxin. Joint decision-making for spare parts ordering and replacement based on dynamic calibration of degradation models [J]. *Journal of Rocket Force University of Engineering*, 2025, 39(4): 22-31.
- [9] 余健辉, 杨海东, 徐康康, 等. 基于量子粒子群优化混合神经网络的锂电池 SOH 估计 [J]. *传感器与微系统*, 2026, 45(3): 165-171.
- Yu Jianhui, Yang Haidong, Xu Kangkang, et al. SOH estimation of lithium battery based on quantum particle swarm optimization hybrid neural network [J]. *Transducer and Microsystem Technologies*, 2026, 45(3): 165-171.
- [10] Guo Wendi, Sun Zhongchao, Vilsen S B, et al. Review of "grey box" lifetime modeling for lithium-ion battery: combining physics and data-driven methods [J]. *Journal of Energy Storage*, 2022, 56: 105992.
- [11] 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 Zilin, Li Yunpan, Zhan Zhenfei, et al. A review of health state estimation methods for lithium-ion batteries [J]. *Journal of Chongqing University of Technology (Natural Science)*, 2025, 39(12): 1-10.
- [12] Lee J, Won J. Enhanced coulomb counting method for SoC and SoH estimation based on coulombic efficiency [J]. *IEEE Access*, 2023, 11: 15449-15459.
- [13] Pang Zheyuan, Yang Kun, Song Zhengxiang, et al. A new method for determining SOH of lithium batteries using the real-part ratio of EIS specific frequency impedance [J]. *Journal of Energy Storage*, 2023, 72: 108693.
- [14] Wang Chao, Li Wanjun, Yan Zhengqiang, et al. Operando battery monitoring using lab-on-fiber optical sensing technologies (Measurement Methodology) [J]. *IEEE Instrumentation & Measurement Magazine*, 2025, 28(7): 13-17.
- [15] 朱建功, 戴海峰, 王学远, 等. 从电池管理到电化学数字电源 [J]. *电气工程学报*, 2024, 19(1): 3-22.
- Zhu Jiangong, Dai Haifeng, Wang Xueyuan, et al. Battery management towards the digitalized electrochemical power source [J]. *Journal of Electrical Engineering*, 2024, 19(1): 3-22.
- [16] 徐乐, 邓忠伟, 谢翌, 等. 锂离子电池高精度机理建模、参数辨识与寿命预测研究进展 [J]. *机械工程学报*, 2022, 58(22): 19-36.
- Xu Le, Deng Zhongwei, Xie Yi, et al. Review on research progress in high-fidelity modeling, parameter identification and lifetime prognostics of lithium-ion battery [J]. *Journal of Mechanical Engineering*, 2022, 58(22): 19-36.
- [17] Zhang Yongzhi, Feng Xinhong, Zhao Mingyuan, et al. In-situ battery life prognostics amid mixed operation conditions using physics-driven machine learning [J]. *Journal of Power Sources*, 2023, 577: 233246.
- [18] Shan Runzhe, Wang Yaxuan, Wang Chao, et al. A method for battery health estimation under variable operating conditions based on the fusion of simplified electrochemical model and alpha evolution-back propagation model [J]. *Journal of Energy Storage*, 2025, 123: 116866.
- [19] 李银, 王建峰, 莫伟权, 等. 基于数据驱动的锂离子电池剩余寿命预测综述 [J]. *电源学报*, 2025, 23(7): 253-265.
- Li Yin, Wang Jianfeng, Mo Weiquan, et al. Review on data-driven remaining useful life prediction for lithium-ion batteries [J]. *Journal of Power Supply*, 2025, 23(7): 253-265.
- [20] 郑启达, 赵谡, 汪彪, 等. 基于在线顺序极限学习机模型的锂离子电池健康状况预测 [J]. *电力工程技术*, 2026, 45(2): 51-59.
- Zheng Qida, Zhao Su, Wang Biao, et al. Lithium-ion battery health prediction based on online sequential extreme learning machine model [J]. *Electric Power Engineering Technology*, 2026, 45(2): 51-59.
- [21] 胡远志, 陈飞, 刘西, 等. 融合 LSTM 与 Informer 网络的锂离子电池 SOH 估计 [J]. *武汉大学学报(理学版)*, 2025, 71(6): 813-820.
- Hu Yuanzhi, Chen Fei, Liu Xi, et al. SOH estimation of lithium-ion batteries integrating LSTM and informer network [J]. *Journal of Wuhan University (Natural Science Edition)*, 2025, 71(6): 813-820.
- [22] Ke Leisi, Lin Mingqiang, Meng Jinhao, et al. A sparse SOH estimation framework based on clustered voltage segments and multi-head CNN under arbitrary charging condition [J]. *Energy*, 2026, 344: 140057.
- [23] 赵志宏, 李春秀, 窦广鉴, 等. 基于 MTF-CNN 的轴承故障诊断研究 [J]. *振动与冲击*, 2023, 42(2): 126-131.
- Zhao Zhihong, Li Chunxiu, Dou Guangjian, et al. Bearing fault diagnosis method based on MTF-CNN [J]. *Journal of Vibration and Shock*, 2023, 42(2): 126-131.
- [24] 成心怡, 郑建飞, 张琪, 等. 面向多传感器耦合数据健康指标构建的装备剩余寿命预测方法 [J]. *火箭军工程大学学报*, 2025, 39(4): 11-21.
- Cheng Xinyi, Zheng Jianfei, Zhang Qi, et al. Remaining useful life prediction of equipment based on health index construction from multi-sensor coupled data [J]. *Journal of Rocket Force University of Engineering*, 2025, 39(4): 11-21.

- [25] Zheng Jianfei, Chen Dongnan, Hu Changhua, et al. TBiGAN-based parallel networks for remaining useful life prediction of multi-stage degraded bearings[J]. Pattern Recognition, 2026, 172: 112349.
- [26] 韩其辉, 杨立浩, 郑建飞, 等. 基于空间重构与并行化建模的滚动轴承剩余寿命预测方法[J]. 火箭军工程大学学报, 2025, 39(5): 127-136.
- Han Qihui, Yang Lihao, Zheng Jianfei, et al. Spatial reconstruction and parallelizing modeling-based remaining useful life prediction method of rolling bearings[J]. Journal of Rocket Force University of Engineering, 2025, 39(5): 127-136.
- [27] 姜蕾, 郑建飞, 胡昌华, 等. 双向建模增强 TKAN 和全局注意力机制融合的滚动轴承剩余寿命预测[J]. 自动化学报, 2025, 51(8): 1857-1868.
- Jiang Lei, Zheng Jianfei, Hu Changhua, et al. Bidirectional modeling-enhanced TKAN and global attention mechanism fusion for rolling bearing remaining useful life prediction[J]. Acta Automatica Sinica, 2025, 51(8): 1857-1868.
- [28] 叶宏, 范旭明, 徐敏, 等. 基于 AdaBoost-RF-ResNet18 的储能电站火灾早期预警算法[J]. 供用电, 2024, 41(11): 99-104.
- Ye Hong, Fan Xuming, Xu Min, et al. Early fire warning algorithm of storage power station based on AdaBoost-RF-ResNet18[J]. Distribution & Utilization, 2024, 41(11): 99-104.
- [29] 蔡志强, 王兆强, 胡昌华, 等. 基于复杂网络的重大装备健康指标构建方法[J]. 火箭军工程大学学报, 2025, 39(4): 1-10.
- Cai Zhiqiang, Wang Zhaoqiang, Hu Changhua, et al. Construction method for health index of complex network-based major equipment[J]. Journal of Rocket Force University of Engineering, 2025, 39(4): 1-10.
- [30] Saha B, Goebel K. Battery data set[DS]. NASA Prognostics Data Repository, NASA Ames Research Center, Moffett Field(2007)[2026-03-29].
- [31] CALCE. CALCE battery dataset[DS/OL]. Center for Advanced Life Cycle Engineering, University of Maryland(2014-12-31)[2026-03-29]. <https://calce.umd.edu/battery-data>.
- [32] Birkel C, Howey D. Oxford battery degradation dataset 1[DS/OL]. University of Oxford(2017)[2026-03-29]. <https://doi.org/10.5287/bodleian:ko2kdmgyg>.

Adaptive Boosting and Ensemble Learning-Based State of Health Prediction Method for Lithium-Ion Batteries

ZHANG Yan, ZHENG Jianfei, ZHANG Xin, HAN Qihui, TU Rui

(Rocket Force University of Engineering, Xi'an 710025, China)

ABSTRACT: To address the problems of strong nonlinearity, complex features, and limited generalization ability of a single model for the lithium-ion battery degradation process, a state of health (SOH) prediction model based on adaptive boosting (AdaBoost) and ensemble learning was proposed. First, multidimensional features, such as the amplitude, position, and area, were extracted from the incremental capacity and charge-discharge temperature curves of batteries. Eight types of health indicators were constructed, and the effectiveness of each was verified using a Pearson correlation analysis. Second, a convolutional neural network was used to extract local degradation features, and a bidirectional gated recurrent unit was adopted to characterize the dynamic evolution law of battery degradation. A self-attention mechanism was introduced to enhance the ability of the model to perceive key degradation information. These three modules jointly formed a weak learner, which was further integrated into a strong predictor through the AdaBoost ensemble strategy, thereby improving the prediction accuracy and robustness of the model. Finally, the proposed method was validated on three datasets, namely NASA, CALCE, and Oxford. The results show that the proposed method achieves high prediction accuracy and strong generalization ability. It can accurately track the full-life-cycle SOH degradation trajectory of batteries and effectively reduce error fluctuations in the later aging stage, with mean absolute error and root mean square error values as low as 0.002 913 and 0.004 146, respectively. In addition, the proposed algorithm requires only 10% of the complete operation data of the target battery to achieve high-precision SOH prediction in cross-dataset transfer scenarios.

KEYWORDS: lithium-ion battery; state of health prediction; ensemble learning; health indicator; adaptive boosting algorithm

(编辑:刘建民)