

DOI: 10.19650/j.cnki.cjsi.J2615139

物理-数据双特征融合的锂离子电池跨域 SOH 估计*

赵志斌¹, 丰铭岐¹, 郑适雨¹, 武靖耀¹, 刘 雪²

(1. 西安交通大学机械工程学院 西安 710049; 2. 中国人民解放军火箭军工程大学 西安 710025)

摘 要:在能源结构转型背景下,锂离子电池健康状态(SOH)的准确估计对系统安全运行与寿命管理具有重要意义。针对片段化充电数据难以充分表征退化过程、跨工况样本分布差异导致模型泛化能力下降的问题,提出一种物理-数据双特征融合的锂离子电池跨域 SOH 估计方法。首先,基于全寿命周期数据分析与电池退化机理,提取峰值电压、累计容量、峰值处 dQ/dV 值和峰值时间占比等物理特征;同时,以片段化充电电压曲线为输入,利用卷积神经网络(CNN)提取数据驱动特征。随后,通过物理特征与数据特征融合构建兼具机理可解释性和数据表达能力的退化表征,并引入最大均值差异(MMD)对齐源域与目标域特征分布,以提升模型跨工况迁移能力。为验证所提方法,在 4 种充放电工况下开展锂离子电池退化实验,采集 39 块 18650 型 NMC 电池的全寿命周期数据,并构建 12 组跨工况迁移任务。实验结果表明,所提方法在 12 组任务中均取得最低估计误差,平均均方根误差(RMSE)为 0.022 3,平均绝对百分误差(MAPE)为 2.05%;相较仅使用数据特征的 CNN 模型,平均 RMSE 和 MAPE 分别降低约 52.6% 和 53.0%。在与长短期记忆(LSTM)、门控循环单元(GRU)、Transformer、域对抗神经网络(DANN)及典型域适应方法的对比中,所提方法整体表现更优,并在 MIT 跨批次数据集上表现出一定迁移能力。结果说明,物理特征与数据特征协同建模及 MMD 域对齐机制能够有效提升锂离子电池跨工况 SOH 估计的准确性和泛化能力。

关键词: 锂离子电池; 迁移学习; 健康状态; 域自适应

中图分类号: TH89 TM93

文献标识码: A

国家标准学科分类代码: 510.40

Cross-domain SoH estimation for lithium-ion batteries via physics-data dual-feature fusion

Zhao Zhibin¹, Feng Mingqi¹, Zheng Shiyu¹, Wu Jingyao¹, Liu Xue²

(1. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

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

Abstract: In the context of energy transition, accurate state of health (SOH) estimation of lithium-ion batteries is essential for safe system operation and lifetime management. To address the problems that fragmented charging data cannot fully characterize battery degradation and that significant sample distribution discrepancies across operating conditions reduce model generalization, this paper proposes a cross-domain SOH estimation method based on physics-data dual-feature fusion. First, degradation-sensitive physical features, including peak voltage, accumulated capacity, dQ/dV value at the peak, and peak time ratio, are extracted based on full-life-cycle data analysis and battery degradation mechanisms. Meanwhile, fragmented charging voltage curves are used as inputs, and a convolutional neural network (CNN) is employed to extract data-driven features. Subsequently, physical and data features are fused to construct a degradation representation with both mechanistic interpretability and data representation capability. Maximum mean discrepancy (MMD) is introduced to align the feature distributions between the source and target domains, thereby improving the cross-condition transfer capability of the model. To validate the proposed method, lithium-ion battery degradation experiments were conducted under four charging and discharging conditions. Full-life-cycle data from 39 NMC 18650 cells were collected, and 12 cross-condition transfer tasks were constructed. Experimental results show that the proposed method achieves the lowest estimation errors in all 12 tasks,

收稿日期: 2026-04-14 Received Date: 2026-04-14

* 基金项目: 火箭军工程大学青年基金(2025QN-B028)项目资助

with an root mean square error (RMSE) of 0.022 3 and an mean absolute percentage error (MAPE) of 2.05%. Compared with the CNN model using only data features, the average RMSE and MAPE are reduced by approximately 52.6% and 53.0%, respectively. In comparisons with long short-term memory (LSTM), gate recurrent unit (GRU), Transformer, domain-adversarial neural network (DANN), and typical domain adaptation methods, the proposed method shows better overall performance and demonstrates certain transferability on the MIT cross-batch dataset. The results indicate that collaborative modeling of physical and data features, together with MMD-based domain alignment, can effectively improve the accuracy and generalization capability of cross-condition SOH estimation for lithium-ion batteries.

Keywords: lithium-ion batteries; transfer learning; state of health; domain adaptation

0 引 言

在“双碳”战略推动能源结构转型的背景下,以锂离子电池为核心的储能系统在新型电力系统、电动交通工具及航天器等领域发挥着关键作用^[1-3]。然而,电池在长期服役中面临复杂的电化学老化与性能退化,若无法准确监控其健康状态(state of health, SOH),将引发续航骤降甚至热失控等安全事故。因此,实现 SOH 的精准估计对于保障系统安全、延长服役寿命具有重要的工程价值。

SOH 作为量化电池性能退化的关键指标,通常定义为当前最大可用容量与额定容量的比值,其准确估计是电池管理系统实现状态监测、寿命预测和故障预警的核心基础。目前的 SOH 估计方法主要可分为基于机理模型与基于数据驱动两类。前者通过建立等效电路模型或电化学模型,解析电池内部动力学行为^[4-7]。这类方法具有较为明确的物理意义,能够从内阻、极化特性、扩散过程和容量衰减规律等角度解释电池退化行为。陈猛等^[8]提出了一种基于多因子评估模型和卡尔曼滤波的锂离子电池健康状态在线估计方法引入欧姆内阻、极化内阻与极化电容 3 个参数,通过带约束的最小二乘算法进行参数权重优化与融合;Zhang 等^[9]则利用电化学阻抗谱技术通过弛豫时间分布分析解耦内部退化机制;Xiong 等^[10]提出了一种在线估计电池剩余容量的方法,引入基于分数阶阻抗模型的在线参数识别方法进行电池老化分析。基于模型的方法具有良好的机理解释能力,但通常依赖准确的模型结构和高质量参数辨识。当电池材料体系、温度、倍率或充放电协议发生变化时,固定模型及其参数可能难以保持长期有效,模型的适用性和扩展性受到一定限制。

相较之下,数据驱动方法无需显式描述复杂的电化学反应过程,而是通过从电压、电流、容量及其衍生信号中提取健康特征,建立运行数据与 SOH 之间的映射关系,展现出较强的非线性建模能力和工程适用性^[11-13]。胡循泉等^[14]提出了一种基于全局健康因子和卷积神经网络(convolutional neural network, CNN)-残差网络-双向门控循环单元-注意力机制模型的锂离子电池健康状

态估计方法,引入人工蜂群算法和残差连接进行模型优化与特征完整性保持;钱伟等^[15]提出一种基于变学习率反向传播(back-propagation, BP)神经网络和自适应渐消扩展 H_∞ 滤波的健康状态(SOH)-荷电状态(state of charge, SOC)联合估计方法,实现了电池健康状态与荷电状态的协同估计。上述研究表明,数据驱动方法能够有效挖掘运行数据中的非线性退化规律,为 SOH 估计提供了灵活的技术路径。然而,现有方法通常建立在数据相对完整、特征稳定且训练集与测试集分布较为一致条件下,其在复杂实际工况中的适用性仍受到一定限制。

因此,从工程应用角度看,当前研究仍面临 3 个相互耦合的关键问题。1) 特征可获得性不足。在实际运行过程中,受充电策略约束、用户随机行为、采样频率及存储能力限制,往往难以获得完整、连续的充放电数据,导致退化信息呈现片段化、稀疏化特征,高质量健康特征难以稳定提取。2) 退化表征不完整。单纯依赖人工构造特征,容易遗漏原始时序信号中的动态演化信息;而仅依赖深度网络从原始数据中自动学习,又容易忽略与电池退化机理直接相关的关键物理信息,导致复杂老化行为刻画不充分。3) 跨域泛化能力受限。不同充放电策略、工作倍率和环境条件会引起显著的域间分布偏移,使得在源域学习到的退化规律难以直接迁移到目标域。上述问题在卫星能源系统等复杂场景中尤为突出^[16-18]: 电池在轨服役过程中需承受剧烈温度循环、深度充放电及长期微重力环境,其老化行为呈现全局衰减与局部容量再生交织的特点,进一步放大了片段化采样与分布漂移对 SOH 在线估计可靠性的影响。

为此,本文提出一种物理-数据双特征融合的锂离子电池跨域 SOH 估计方法,主要创新贡献如下。

1) 提出一种面向片段化充电数据的物理-数据双特征融合 SOH 估计框架。该框架将基于退化机理提取的物理特征与原始充电电压曲线学习得到的数据特征进行协同建模,突破了单一特征来源对退化表征能力的限制。

2) 构建兼具物理可解释性与时序表达能力的统一退化表示。通过将增量容量(incremental capacity, IC)曲线中的退化敏感特征与片段化电压序列信息在同一特征空间中融合,提高了对复杂老化行为的刻画完整性与鲁棒性。

3) 引入基于最大均值差异 (maximum mean discrepancy, MMD) 的域对齐机制提升跨域泛化能力。针对不同充放电策略和工况条件下显著的特征分布偏移问题, 实现源域与目标域之间的知识迁移, 并在多组跨工况任务中验证了所提方法的有效性。

4) 开展了基于 4 种不同充放电策略的锂离子电池退化实验, 采集了 39 块 18650 型 NMC 电池的全寿命周期数据, 并通过 12 组跨工况迁移任务的系统验证, 证实了所提方法在 4 类工况下的有效性。

1 锂离子电池退化数据采集与特征提取

1.1 锂电池退化数据采集

本研究开展了 4 组不同充放电策略的锂离子电池老化实验^[19], 共采集了 39 只力神 18650 型镍钴锰酸锂电池的退化数据, 在 25℃ 恒温环境下由 ACTS-5V10AGGS-D 型多通道电池测试系统以 1 Hz 采样率持续记录数据, 所有电池均测试至容量衰减到初始值的 80% 以下, 视为达到寿命终点, 实验台设置如图 1 所示。




图 1 数据采集系统

Fig. 1 Data acquisition system

本研究共设置 4 种具有代表性的充放电策略, 涵盖不同电流倍率和工作模式, 能够反映多工况下电池的退化行为。

Batch-1, 包含 8 只电池。首次循环为标准容量标定: 0.5 C 恒流充电至 4.2 V, 转入恒压模式至电流衰减至 0.02 C, 静置 5 min 后以 0.2 C 恒流放电至 2.5 V。后续循环采用 2.0 C 恒流充电至 4.2 V, 恒压至电流降至 0.05 C, 静置 5 min 后以 1.0 C 恒流放电至 2.5 V, 最终静置 5 min。

Batch-2, 包含 15 只电池。首次循环同 Batch-1。后续循环采用加速充电策略: 3.0 C 恒流充电至 4.2 V, 恒

压阶段截止电流提升至 0.05 C, 静置 5 min 后维持 1.0 C 放电倍率至 2.5 V。

Batch-3, 包含 8 只电池, 进行动态放电测试。首次循环同 Batch-1。后续循环保持 2.0 C 充电, 放电倍率按预设序列 0.5、1、2、3、5 C 周期性切换直至电压降到 2.5 V, 每次放电后静置 5 min。

Batch-4, 包含 8 只电池, 进行浅放电动态测试。首次循环同 Batch-1。后续循环采用 2.0 C 恒流充电至 4.2 V, 恒压至 0.05 C, 静置 5 min 后以序列 0.5、1、2、3、5 C 周期性切换放电直至电压为 3.0 V, 放电后静置 5 min。每完成一轮序列放电后, 插入标准容量检测循环: 2.0 C 充电至 4.2 V, 恒压至 0.05 C, 静置 5 min 后以 1.0 C 放电至 2.5 V, 用于校准浅放电导致的容量虚增误差。

基于 Batch-1 ~ Batch-4 这 4 组电池全寿命周期实验数据, 本文通过可视化方法系统分析不同充放电策略下的老化趋势, 如图 2 所示。原始电压、电流、容量等时序数据的图形化呈现, 直观揭示了各策略中电池退化行为的差异特征: 充电平台特性、放电终止行为及容量衰减速率均呈现显著分化。

由图 2 可以看出, 动态放电与浅放电策略对循环稳定性及容量保持率的影响存在本质区别。4 种工况下的电压、电流随时间变化的曲线和容量随循环周期的曲线, 均存在明显差异。随着循环周期的增加, 各工况的电压、电流曲线均出现明显偏移, 与循环初期的充放电电压、电流曲线相比, 维持恒流充电的时间、结束放电的时间等关键节点逐渐发生变化。4 种工况的容量退化曲线在循环末期均呈现出非线性加速衰退的现象, 不同工况的退化曲线的退化加速拐点与退化速率存在明显的区别, 这说明不同的充放电策略会导致退化模式的显著改变。

1.2 数据特征选取

完成数据可视化分析后, 如何从动态原始数据中提取可解释的特征指标是 SOH 建模关键。原始高维时序数据中隐含的退化模式常被噪声掩盖, 而有效的特征提取不仅能够捕捉反映老化机理的核心指标, 还可以提升跨工况容量估计模型的泛化能力。

恒流阶段增量容量曲线蕴含丰富的电池衰退信息, 对其关键特征点进行解析可直接关联到电极活性材料损失、锂离子扩散阻抗等微观机理的表征。将实验所用数据按照 X 轴-电压、Y 轴-循环数、Z 轴-dQ/dV 值的布局进行三维可视化处理, 绘制其中一个实验电池的 IC 曲线图像, 如图 3 所示。

IC 曲线可视化分析表明, 其峰值随循环次数增加向高电压偏移, 且幅值逐渐衰减。该现象表明, IC 曲线峰值蕴含与电池退化密切相关的信息, 因此可以使用






图 2 不同工况下数据可视化图

Fig. 2 Visualization of the dataset under different operating conditions

IC 曲线中与峰值相关的参数来表征电池的退化程度。 基于此,本文构建了如下 4 种表征锂电池容量衰减的



(a) IC曲线随循环周期的变化的三维视图
(a) 3D view of IC curve evolution over cycles



(b) IC曲线随循环周期的变化的俯视图
(b) Top view of IC curve evolution over cycles

图3 所有循环的IC曲线三维可视化图

Fig. 3 3D visualization of the IC curves for all cycles

老化特征。

1) 峰值电压(F1), 恒流充电阶段内 dQ/dV 峰值对应的电压值, 反映充电过程中容量对电压变化最敏感的临界点电压。

2) 累计容量(F2), 从绘制 IC 曲线的起始电压至峰值电压对应采样点之间所累计的容量值, 体现该阶段电池存储电荷的能力, 与电池健康状态密切相关。

3) 峰值处 dQ/dV 值(F3), IC 曲线峰值处的 dQ/dV 数值, 表征容量随电压变化的剧烈程度, 通常与电池内部化学反应的相变过程相关。

4) 峰值时间占比(F4), 峰值电压对应采样点在 IC 曲线电压区间内的相对位置占比, 反映峰值出现的早晚, 可用于评估电池老化对充电过程的影响。

考虑到峰值特征与 SOH 之间存在非线性关系, 且特征数据中存在部分离群点, 本文选择斯皮尔曼等级相关系数作为相关性分析工具, 以评估各特征与 SOH 之间的关联程度。

从图4可以看出, F1~F4 这4个特征在4个数据集上与 SOH 的相关程度均处于强相关(0.70~1.00)或较

强相关(0.50~0.70)范围。Spearman 相关性分析表明, F1~F4 在各工况内均与 SOH 存在较强单调相关关系, 因此可作为退化敏感特征的输入。为此, 本文进一步采用主成分分析(principal component analysis, PCA)降维与核密度估计方法分析不同工况下特征分布的一致性, 并通过跨工况迁移实验验证其泛化能力。实验结果表明, F1~F4 虽然受到工况变化影响, 但仍保持与电池退化过程一致的演化趋势, 能够作为具有一定跨工况表征能力的退化特征。




图4 不同工况特征与 SOH 的相关系数热力图

Fig. 4 Heatmap of correlation coefficients between operating condition features and SOH

2 物理-数据双特征融合的域自适应方法

2.1 物理特征与数据特征协同编码

本文提出的跨域 SOH 估计模型为物理-数据双特征融合域自适应方法, 其整体结构由物理特征支路、数据特征支路、特征融合模块和域对齐模块组成, 结构如图5所示。模型输入包含两类互补信息: 一类为基于增量容量曲线及电池退化机理提取的物理特征, 包括峰值电压、累计容量、峰值处 dQ/dV 值和峰值时间占比等, 用于增强模型对电池老化本质的刻画能力; 另一类为片段化充电电压曲线中蕴含的原始时序信息, 用于表征电池在充电过程中的动态演化规律。前者侧重提供具有机理意义的退化先验, 后者侧重挖掘原始测量数据中的隐含模式, 二者分别编码后在统一特征空间中融合, 并进一步通过域自适应策略实现源域与目标域分布对齐, 最终输出 SOH 估计结果。

为保证不同循环、不同工况下输入片段具有一致的物理含义, 本文选取恒流充电阶段中的电压片段作为数据特征输入。具体而言, 首先根据电流阈值识别恒流充电阶段, 然后在该阶段内截取固定电压区间[3.7 V, 4.1 V]内的充电电压序列。对于不同循环中由于充电时间差异导致的片段长度不一致问题, 本文采用线性插值方法




图 5 本研究提出的方法的整体结构
Fig. 5 Architecture of the proposed method

将所有片段统一重采样为固定长度 128 的序列,并在输入网络前进行归一化处理。若某一循环未能完整覆盖该电压区间,则将该循环片段剔除,以避免由不完整片段引入额外误差。

在数据特征支路中,输入为部分原始充电电压曲线。针对此类一维时序数据,采用 CNN 作为编码器,并利用一维卷积(one-dimensional convolution, Conv1d)的滑动窗口机制自动提取输入信号的局部时序特性^[20],其具体参数设置如表 1 所示。

表 1 CNN 编码器参数

层数	类型	输入通道	输出通道	输出形状
1	Conv1d	2	16	$(N, 16, 64)$
2	Conv1d	16	32	$(N, 32, 32)$
3	Conv1d	32	64	$(N, 64, 16)$
4	Conv1d	64	8	$(N, 8, 8)$
5	线性层	8×8	1	$(N, 1)$

多卷积层叠加的结构可以有效提取充电电压曲线中的多尺度特征。其中,底层卷积用于捕捉信号突变、局部波形等局部特征,高层卷积则更关注电池老化特性等长期演变规律。CNN 编码器通过特征提取挖掘原始数据中蕴含的老化信息,同时显著降低输入至下游任务的参数量。

在物理特征支路中,为使从 IC 曲线中提取的退化敏感特征能够与数据特征在统一空间中实现融合,采用多层感知机(multilayer perceptron, MLP)对峰值电压、累计容量、峰值处 dQ/dV 值和峰值时间占比等特征进行非线性映射,其具体参数配置如表 2 所示。

表 2 MLP 编码器参数

层数	类型	输入通道	输出通道	激活函数	输出形状
1	线性层	4	64	修正线性单元(ReLU)	$(N, 64)$
2	线性层	64	8×8	—	$(N, 8, 8)$

通过对原始 IC 特征进行两层映射,将其投射到 64 维高阶表示空间,随后将其重新整形为 8×8 矩阵,以便于与卷积通路在同一特征空间融合。

将 CNN 与 MLP 两路编码器所提取的特征向量进行拼接,形成了同时包含原始充电电压曲线与 IC 曲线峰值信息的复合特征。源域的电压曲线与 IC 峰值特征经两路编码器处理后生成源域特征向量,目标域的特征也经过相同处理流程,得到目标域特征向量。

2.2 跨域迁移学习方法

在锂电池 SOH 的跨域预测场景中,不同的充放电策略导致源域与目标域数据呈现显著分布偏移且电池退化模式存在明显差异^[21-23]。这种非独立同分布特性限制了传统机器学习模型的泛化能力,亟需引入迁移学习以实现跨域知识迁移。本文采用领域自适应方法,通过在特征空间中重构并对齐源域与目标域之间的概率分布^[24],实现精准的跨域容量估计。

迁移学习的核心目标是突破独立同分布假设的约束,将源域中学习到的电池退化规律有效迁移至目标域^[25]。从数学角度定义,给定源域 $\mathcal{D}_s$ 与目标域 $\mathcal{D}_t$ 分别如式 (1) 和 (2) 所示。

$$\mathcal{D}_s = \{\mathbf{x}_i^s, \mathbf{y}_i^s\}_{i=1}^{n_s} \quad (1)$$

$$\mathcal{D}_t = \{\mathbf{x}_j^t\}_{j=1}^{n_t} \quad (2)$$

式中: $\mathbf{x}_i^s$ 是源域特征向量; $\mathbf{y}_i^s$ 是源域标签; n_s 是源域样本数; $\mathbf{x}_j^t$ 是目标域特征向量; n_t 是目标域样本数。

假定两域的特征空间 $\mathcal{X}_s = \mathcal{X}_t$, 其边缘分布 $P_s(X_s) \neq P_t(X_t)$, 且两域具有一致的标签空间 $\mathcal{Y}$ 。领域自适应的核心目标是学习域不变特征表示 $\phi(\cdot)$, 使得映射后的特征满足 $P_s(\phi(X_s)) \approx P_t(\phi(X_t))$, 同时保持与标签 $\mathcal{Y}$ 的强相关性。

由于目标域电池在复杂极端工况下难以通过充放电实验获取精确容量标签,导致传统监督学习所需的标注完全缺失。因此,本文构建的迁移模型仅依靠源域监督信号 $\mathcal{D}_s$ 与目标域无标签数据 $\mathcal{D}_t$, 通过隐式关系实现跨域知识迁移。

为了缩小两域之间的特征分布差异,本研究引入 MMD 作为域适应损失。MMD 是一种基于再生核希尔伯特空间(reproducing kernel Hilbert space, RKHS)的非参数量度准则,通过比较两个分布样本在特征空间中的均值嵌入距离,量化域间差异^[26]。

经过特征拼接后的源域样本特征集合为 $\{\mathbf{F}^s\}_{i=1}^{n_s}$, 目标域样本特征集合为 $\{\mathbf{F}^t\}_{j=1}^{n_t}$, MMD 的经验估计可表示为:

$$\mathcal{L}_{\text{MMD}} = \left\| \frac{1}{n} \sum_{i=1}^n f(\mathbf{F}_i^s) - \frac{1}{m} \sum_{j=1}^m f(\mathbf{F}_j^t) \right\|_{\mathcal{H}}^2 \quad (3)$$

式中: $f(\cdot)$ 为核函数映射; $\mathcal{H}$ 为 RKHS 空间。本文采用

常用的高斯核对 MMD 经验公式进行显式展开,高斯核如式 (4) 所示。

$$k(\|\mathbf{x}_i, \mathbf{x}_j\|) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|_2^2}{2\sigma^2}\right) \quad (4)$$

其中,高斯核带宽 σ 采用中位数启发式方法确定,即根据当前批次中源域与目标域融合特征之间的成对欧氏距离中位数设置核带宽。该方法能够避免人工固定带宽对不同迁移任务适应性不足的问题。每个训练批次中源域样本与目标域样本数量保持一致,以减小样本数量不均衡对 MMD 估计的影响。

使用高斯核展开后, MMD 域自适应损失计算方程如式 (5) 所示。

$$\mathcal{L}_{\text{MMD}} = \frac{1}{n} \sum_{i,j=1}^n k(\mathbf{F}_i^s, \mathbf{F}_j^s) + \frac{1}{m} \sum_{i,j=1}^m k(\mathbf{F}_i^t, \mathbf{F}_j^t) - \frac{2}{nm} \sum_{i=1}^n \sum_{j=1}^m k(\mathbf{F}_i^s, \mathbf{F}_j^t) \quad (5)$$

MMD 损失施加于物理特征与数据特征拼接后的融合特征层,而非原始输入层或最终输出层。这样既可以对齐跨域退化表征,又可以避免直接约束 SOH 输出导致预测能力下降。通过最小化 $\mathcal{L}_{\text{MMD}}$ 实现两域特征分布对齐,从而缓解域间偏移,提升跨域性能。

2.3 训练参数

在训练过程中,使用均方误差损失衡量源域真实标签与估计值之间的差距,其计算公式为:

$$\mathcal{L}_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (6)$$

式中: y_i 表示样本真实值; $\hat{y}_i$ 表示预测值; N 表示样本数量。

模型的总损失函数 $\mathcal{L}_{\text{total}}$ 包括 $\mathcal{L}_{\text{MSE}}$ 与 $\mathcal{L}_{\text{MMD}}$, 如式 (7) 所示。

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{MSE}} + \alpha \mathcal{L}_{\text{MMD}} \quad (7)$$

其中,权重系数 α 用于控制域自适应损失的权重,以平衡源域 SOH 预测误差与跨域分布对齐强度。若 α 过大,模型可能过度追求域对齐而削弱与 SOH 相关的退化信息;若 α 过小,则难以有效缓解域间偏移。

为确定合适的 α , 本文对不同权重系数进行敏感性分析,结果如图 6 所示。图 6(a) 为不同 α 下的验证集均方根误差(root mean square error, RMSE), 图 6(b) 为不同 α 下的训练波动系数。训练波动系数用于衡量训练损失的相对波动程度,其值越小表示训练过程越稳定。由图 6 可见,当 $\alpha = 0.001$ 时,模型在验证集上取得较低 RMSE,同时训练波动较小。因此,本文将 MMD 权重系数设置为 0.001。

本文所提出方法通过最小化 $\mathcal{L}_{\text{total}}$ 联合优化特征映





图 6 MMD 权重系数敏感性分析

Fig. 6 Sensitivity analysis of the MMD weight coefficient



(b) 物理-数据双特征融合的PCA降维散点图
(b) PCA scatter plot of physics-data dual-feature fusion

图 7 不同模型中经 PCA 降维后的特征散点图

Fig. 7 Scatter plot of PCA-reduced features from different models


射与预测模块,在保证预测精度的同时实现分布对齐,从而抑制域偏移对 SOH 估计的影响。训练过程中,优化器采用 Adam,批次大小设置为 128,初始学习率为 3×10^{-3} ,权重衰减系数为 5×10^{-5} ,训练轮数为 70,并引入早停机制以减小过拟合风险。以上各参数通过网格搜索技术确定最优参数组合,除模型结构相关参数外,各对比模型的公共训练参数保持一致,以保证实验结果的可比性。

3 实验与结果分析


3.1 跨域 SOH 估计模型结果与分析

为验证所提出物理-数据双特征融合方法在跨工况 SOH 估计中的有效性,选取 Batch-1 作为源域、Batch-2 作为目标域进行实验,对比不同特征建模策略在跨域场景下的表现。首先,对融合特征进行 PCA 降维,并对比仅使用数据特征与物理-数据双特征融合模型的特征分布,结果如图 7 所示。

从图 7 可见,在仅使用数据特征时,源域与目标域样本在特征空间中呈现明显分离;而在引入物理特征并进行融合后,两域样本分布显著靠近,表明物理特征有助于构建更稳定、可迁移的退化表征。



(a) 仅有数据特征的源域与目标域的KDE曲线
(a) KDE curves of the source and target domains using only data features




(b) 物理-数据双特征融合的源域与目标域的KDE曲线
(b) KDE curves of the source and target domains with physical and data feature fusion

图 8 PC1 维度缩减后的 KDE 曲线


Fig. 8 KDE curve for PC1 after dimensionality reduction

由图 8 可见,在物理-数据双特征融合与域对齐共同作用下,源域与目标域的概率密度分布峰值明显趋于一致,相比仅使用数据特征的模型,其分布偏移显著减小。

这说明融合特征不仅增强了退化信息表达能力,同时提高了跨域一致性。从迁移学习角度来看,若源域与目标域在特征空间中的分布差异较小,则模型学习到的退化规律更容易迁移至目标域。图6和7结果表明,引入物理特征后两域样本在低维特征空间中的重叠程度明显提高,说明融合特征具有更好的工况不变性,从而为后续跨域 SOH 估计提供了更加稳定的特征基础。进一步地,在目标域未参与训练的电池数据上进行 SOH 预测,结果如图9所示。



(a) 仅有数据特征的SOH预测曲线
(a) SOH prediction curves using only data features



(b) 物理-数据双特征融合的SOH预测曲线
(b) SOH prediction curves with physical and data feature fusion

图9 SOH 预测结果对比

Fig. 9 Comparison of SOH estimation results

结果表明,仅使用数据特征的模型在跨域条件下存在明显预测偏差,而物理-数据双特征融合模型的预测曲线与真实值高度吻合,能够准确跟踪电池容量衰减趋势。总体来看,物理特征能够有效补充数据特征中缺失的退化机理信息,双特征融合有助于构建更完整的老化表征,而域对齐机制进一步提升了模型在不同工况之间的可迁移性,从而显著改善跨域 SOH 估计精度。

3.2 消融对比实验结果与分析

为系统分析物理特征、数据特征及域对齐机制在模型中的作用,设计了4种不同模型进行消融实验:A模型仅使用数据特征(单路CNN模型),不引入物理特征与域对齐;

B模型采用物理特征与数据特征融合,但不进行域对齐;C模型在仅使用数据特征的基础上引入MMD域对齐;D模型采用物理-数据双特征融合与域对齐协同建模,即本文提出的方法。实验采用RMSE和平均绝对百分误差(mean absolute percentage error, MAPE)作为评价指标。

以Batch-1为源域、Batch-2为目标域的消融实验结果如图10所示。可以看出,模型A在跨域场景下误差较大,说明仅依赖数据特征难以适应工况变化;模型B在引入物理特征后,预测精度明显提升,表明物理特征能够增强退化信息表达;模型C通过域对齐降低了分布偏移,但由于缺乏物理约束,其性能仍受限制;模型D结合物理-数据双特征融合与域对齐机制,在精度和稳定性上均取得最优表现。




图10 不同方法在消融研究中容量衰减曲线的比较

Fig. 10 Comparison of capacity degradation curves by different methods in the ablation study

消融实验中不同模型跨域估计误差分析如图11所示,迁移结果如表3所示。由表3可以看出,本文方法(模型D)在12组跨工况迁移任务中均取得最低RMSE和MAPE,表明物理-数据双特征融合与MMD域对齐机制能够有效提升跨域SOH估计精度。模型A仅使用数据特征,平均RMSE和MAPE分别为0.0470和4.3711%,说明单纯依赖充电电压片段难以稳定适应工况变化。模型B引入物理特征后,平均RMSE和MAPE降至0.0322和2.8969%,表明IC曲线峰值相关特征能够补充退化机理信息。模型C在数据特征基础上引入MMD,平均RMSE和MAPE为0.0400和3.6046%,较模型A有所改善,但由于缺少物理退化特征约束,提升幅度有限。模型D综合物理特征、数据特征和域对齐机制,平均RMSE和MAPE分别降至0.0223和2.0548%,相较模型A分别降低约52.6%和53.0%,整体性能最优。

在1→2和4→2任务中,模型D的RMSE分别为0.0103和0.0092,MAPE分别为0.8425%和0.7993%,误差水平最低,说明当源域与目标域退化趋势较接近时,融合特征能够较好地捕捉共享退化规律。




图 11 消融实验中不同模型跨域估计误差分析

Fig. 11 Cross-domain estimation error analysis diagram for different models in ablation experiments

表 3 消融实验中不同模型跨域迁移结果

Table 3 Cross-domain transfer results for different models in the ablation experiment

源域→ 目标域	模型 A		模型 B		模型 C		模型 D	
	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%
1→2	0.068 8±0.003 6	6.629 0±0.351 3	0.022 1±0.001 0	1.945 0±0.087 5	0.054 4±0.002 0	5.112 1±0.189 1	0.010 3±0.000 3	0.842 5±0.024 4
1→3	0.045 1±0.002 5	4.171 8±0.233 6	0.043 9±0.001 9	3.961 0±0.174 3	0.034 6±0.001 3	3.318 6±0.126 1	0.033 2±0.001 0	3.274 8±0.098 2
1→4	0.037 4±0.002 2	3.355 0±0.194 6	0.041 2±0.001 8	3.664 4±0.157 6	0.030 8±0.001 1	2.811 4±0.098 4	0.020 3±0.000 6	1.858 4±0.059 5
2→1	0.062 0±0.003 3	5.825 1±0.314 6	0.038 8±0.001 8	3.738 5±0.175 7	0.055 6±0.001 8	4.955 3±0.163 5	0.036 2±0.001 1	3.660 4±0.113 5
2→3	0.052 7±0.003 0	4.663 2±0.265 8	0.046 0±0.002 1	4.219 2±0.194 1	0.048 9±0.001 7	4.346 7±0.147 8	0.033 8±0.000 9	3.165 8±0.088 6
2→4	0.049 8±0.002 7	4.578 0±0.251 8	0.041 8±0.002 0	3.719 3±0.178 5	0.043 4±0.001 6	3.843 5±0.138 4	0.019 5±0.000 6	1.768 5±0.0513
3→1	0.036 5±0.001 9	3.328 3±0.176 4	0.036 9±0.001 6	3.037 0±0.133 6	0.034 8±0.001 3	3.177 5±0.117 6	0.033 1±0.001 1	2.926 3±0.096 6
3→2	0.068 9±0.003 9	6.454 8±0.361 5	0.017 9±0.000 8	1.480 2±0.066 6	0.054 3±0.001 8	4.660 6±0.153 8	0.016 5±0.000 5	1.373 2±0.043 9
3→4	0.024 1±0.001 4	2.098 8±0.121 7	0.029 0±0.001 4	2.552 5±0.120 0	0.019 2±0.000 7	1.661 2±0.058 1	0.018 6±0.000 6	1.594 8±0.049 4
4→1	0.025 6±0.001 4	2.449 1±0.132 3	0.031 6±0.001 4	3.090 8±0.132 9	0.033 7±0.001 3	3.087 2±0.117 3	0.021 5±0.000 6	2.063 9±0.061 9
4→2	0.071 7±0.004 1	7.059 3±0.402 4	0.013 2±0.000 6	1.155 0±0.053 1	0.053 9±0.001 8	4.854 1±0.165 0	0.009 2±0.000 3	0.799 3±0.026 4
4→3	0.021 1±0.001 2	1.840 5±0.101 2	0.024 3±0.001 2	2.199 6±0.105 6	0.016 1±0.000 6	1.427 4±0.051 4	0.014 9±0.000 4	1.329 6±0.037 2

1→3、2→3 和 3→1 任务的误差相对较高,模型 D 的 RMSE 分别为 0.033 2、0.033 8 和 0.033 1。这主要与 Batch-3 采用动态放电策略有关,放电倍率周期性变化会改变电池极化状态和容量衰减路径,使源域与目标域退化分布差异增大。涉及 Batch-4 的 1→4、2→4、3→4 和 4→3 任务中,模型 D 的 RMSE 分别为 0.020 3、0.019 5、0.018 6 和 0.014 9,整体误差较低。尽管 Batch-4 采用浅放电动态测试,其充电阶段仍与其他工况具有一定一致性,因此基于恒流充电片段和 IC 特征构建的融合表征仍具有较好的可迁移性。

物理特征单独引入并未在所有任务中均带来性能提升。在 1→4、3→4、4→1 和 4→3 任务中,模型 B 的 RMSE 高于模型 A。由于模型 A 和模型 B 均未引入域对齐机制,二者差异主要反映不同特征组合在跨工况条件下的泛化能力差别,并不严格属于迁移学习中的负迁移现象。该结果说明,IC 峰值相关物理特征虽然具有退化机理含义,但其分布仍会受到充放电倍率、放电深度和动态放电策略影响。当源域与目标域工况差异较大时,相同 SOH 水平下的峰值位置、峰值幅值和峰值时间占比可能并不一致,使物理特征中混入工况相关信息,从而导致未对齐

条件下的特征分布不匹配和预测性能波动。

进一步对比模型 C 和模型 A 可以发现,单独对数据特征进行 MMD 域对齐在多数任务中能够降低预测误差,但在个别迁移任务中也可能出现性能下降。例如,在 4→1 任务中,模型 C 的 RMSE 和 MAPE 高于模型 A,说明当源域与目标域退化路径差异较大时,仅基于单一数据特征进行分布对齐可能出现局部负迁移或过度对齐。相比之下,模型 D 在 12 组跨工况迁移任务中均取得最低 RMSE 和 MAPE,表明物理-数据双特征融合能够提供更稳定的退化表征,MMD 对融合特征进行对齐后能够有效抑制单一特征对齐带来的负迁移风险,从而提升跨工况 SOH 估计的稳定性。

3.3 与典型 SOH 估计方法及迁移学习方法对比

为了全面评估所提方法的有效性和泛化能力,本文分别在自建 XJTU 数据集和公开 MIT 锂离子电池老化数据集上开展实验。XJTU 数据集用于验证不同充放电策略下的跨工况迁移性能;MIT 数据集由麻省理工学院发布,包含多组不同快充策略下锂离子电池的全寿命周期测试数据,可用于验证模型在不同测试平台和独立数据集上的迁移能力^[27-28]。为保证实验一致性,两类数据均采用相同的预处理流程,从恒流充电阶段截取固定电压区间内的充电电压片段,并提取对应的增量容量曲线物理特征。为保证不同循环、不同工况下输入片段具有一致的物理含义,本文选取恒流充电阶段中的固定电压区间作为数据特征输入。对于 MIT 数据集中的 LFP/graphite 电池,由于其标称电压约为 3.2 V,充电截止电压为 3.65 V,本文根据其有效充电电压范围类推选取 [3.2 V,3.5 V]作为充电片段区间。

MIT 数据集中的电池均在 30℃ 恒温环境下测试,工作电压范围为 2.0~3.6 V。充电过程采用多种快速充电策略,主要包括 C1(Q1)-C2 双阶段恒流充电、80% SOC 后 1 C 倍率(C 为充放电倍率记号,其值为充放电电流与电芯额定容量的比值)恒流-恒压充电以及电流衰减至 C/50 的截止过程。其中,C1 和 C2 分别表示第 1、第 2 阶段充电倍率,Q1 表示阶段切换时的 SOC。相比之下,放电协议较为统一,所有电池均以 4 C 恒流放电至 2.0 V。因此,该数据集的跨批次差异主要来自充电倍率组合、SOC 切换点以及测试流程差异,而非放电过程。

由表 4 可见,不同批次在充电策略数量及 C1、C2、Q1 参数分布上存在明显差异。其中,2017-06-30 批次的充电策略最为丰富,2017-05-12 批次具有更高的第一阶段充电倍率,而 2018-04-12 批次的协议组合相对集中。这些充电协议及参数分布差异使不同批次之间形成不同程度的工况分布偏移,为后续跨批次 SOH 迁移估计任务的构建提供了基础。

表 4 MIT 数据集不同批次充电协议差异
Table 4 Differences in charging protocols across different batches in the MIT dataset

批次	电芯数	独立充电策略数	第 1 阶段 倍率(C1) 范围/C	SOC 切换(Q1) 范围/%	第 2 阶段 倍率(C2) 范围/C
2017-06-30	48	43	1~6	2~80	3~6
2017-05-12	46	23	3.6~8	15~80	3~5.4
2018-04-12	46	8	3.7~5.9	15~80	3.1~5.9

为方便表述,本文将 2017-05-12、2017-06-30 和 2018-04-12 这 3 个批次分别记为 MIT Batch-1、MIT Batch-2 和 MIT Batch-3。本文选取 MIT Batch-2 作为源域,分别向 MIT Batch-1 和 MIT Batch-3 迁移,构建 Batch-2→Batch-1 和 Batch-2→Batch-3 两个跨批次 SOH 估计任务。其中,Batch-2→Batch-3 对应 2017-06-30→2018-04-12 任务,目标批次充电策略数量较少,协议组合相对集中;Batch-2→Batch-1 对应 2017-06-30→2017-05-12 任务,目标批次包含更多高倍率快充策略,且与源域在静置时间上差异明显。MIT Batch-2 在 80% SOC 后和放电后均静置 5 min,而 MIT Batch-1 对应静置时间分别为 1 min 和 1 s。上述差异会影响电池极化恢复和后续循环初始状态,使 Batch-2→Batch-1 任务具有更强的分布偏移和更高的迁移难度。

对比方法包括典型 SOH 估计模型和域自适应模型。其中,CNN、长短期记忆网络(long short-term memory, LSTM)、门控循环单元(gated recurrent unit, GRU)和 Transformer 直接利用充电电压片段进行 SOH 估计;CNN+MMD、LSTM+MMD、GRU+MMD 和 Transformer+MMD 通过 MMD 实现特征分布对齐;CNN+CORAL、LSTM+CORAL、GRU+CORAL 和 Transformer+CORAL 采用相关性对齐(correlation alignment, CORAL)进行域适应;域对抗神经网络(domain-adversarial neural network, DANN)通过对抗学习实现跨域特征迁移。除本文方法外,其余模型均以统一预处理后的充电电压片段作为输入;本文方法在此基础上融合 IC 曲线物理特征,并利用 MMD 对融合特征空间进行分布对齐。

不同方法在各类目标领域的表现如表 5 所示,可以看出,本文方法在 5 个跨域迁移任务中整体取得了较优的 SOH 估计结果。在 XJTU 数据集的 3 个跨工况任务中,本文方法均获得最低 RMSE 和 MAPE,说明物理-数据双特征融合与域对齐机制能够有效提升模型在不同充放电策略下的迁移性能。在 1→2 任务中,本文方法 RMSE 和 MAPE 分别为 0.010 3 和 0.842 5%;在 1→3 任务中, RMSE 为 0.033 2;在 1→4 任务中, RMSE 为

表 5 不同方法在各类目标领域的表现

Table 5 Performance of various data-driven methods across different target domains

方法	XJTU 数据集						MIT 数据集			
	1→2		1→3		1→4		2→1		2→3	
	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%	RMSE	MAPE/%
本文	0.010 3	0.842 5	0.033 2	3.274 8	0.020 3	1.858 4	0.079 8	4.580 5	0.014 9	1.271 4
CNN	0.068 8	6.629 0	0.045 1	4.171 8	0.037 4	3.355 0	0.084 2	4.424 9	0.031 6	2.431 4
CNN+MMD	0.054 4	5.112 1	0.034 6	3.318 6	0.030 8	2.811 4	0.084 5	4.685 0	0.031 2	2.526 9
CNN+CORAL	0.056 3	5.289 5	0.036 0	3.342 1	0.031 7	2.896 2	0.084 0	4.267 5	0.030 9	2.286 7
LSTM	0.053 8	4.978 8	0.051 8	4.691 3	0.044 2	3.902 2	0.084 9	4.853 8	0.034 6	2.772 2
LSTM+MMD	0.053 0	4.895 3	0.051 3	4.650 1	0.043 8	3.864 0	0.088 9	6.432 1	0.036 0	3.207 0
LSTM+CORAL	0.053 7	4.959 8	0.051 6	4.674 7	0.044 2	3.896 5	0.087 8	6.091 2	0.035 1	2.927 0
GRU	0.054 3	5.009 7	0.051 9	4.697 1	0.044 5	3.920 5	0.083 5	4.180 3	0.031 8	2.309 1
GRU+MMD	0.053 1	4.919 4	0.051 4	4.658 2	0.043 9	3.876 2	0.085 6	5.098 0	0.035 0	3.095 4
GRU+CORAL	0.054 4	5.049 6	0.052 1	4.729 0	0.044 5	3.923 9	0.083 4	4.134 9	0.029 0	2.143 3
Transformer	0.055 7	4.847 3	0.050 6	4.539 0	0.044 3	3.890 5	0.085 5	4.644 3	0.035 3	3.136 0
Transformer+MMD	0.050 5	4.560 6	0.047 2	4.233 5	0.040 7	3.573 3	0.088 1	5.474 2	0.033 0	2.602 6
Transformer+CORAL	0.050 0	4.527 9	0.047 1	4.219 6	0.040 6	3.562 1	0.084 2	4.372 1	0.039 0	3.121 6
DANN	0.072 1	6.174 6	0.058 1	5.270 5	0.051 3	4.516 8	0.083 0	4.270 5	0.045 0	4.055 6

0.020 3,相较于性能最优的对比模型 Transformer + CORAL 降低约 50.0%。上述结果表明,在电池体系和测试平台一致、但充放电倍率和放电策略不同的条件下,本文方法能够有效提取跨工况共享退化表征,从而降低工况变化引起的预测误差。

在 MIT 数据集的跨批次迁移任务中,本文方法同样表现出较好的适应能力。在 Batch-2→Batch-3 任务中,本文方法 RMSE 和 MAPE 分别为 0.014 9 和 1.271 4%,均优于其他对比方法;在 Batch-2→Batch-1 任务中,本文方法 RMSE 为 0.079 8,为各方法中的最低值,但 MAPE 为 4.580 5%,相较部分对比模型仍存在一定差距。这说明本文方法能够较好地降低整体预测偏差,但在部分 SOH 区间仍存在相对误差波动。

Batch-2→Batch-1 任务误差相对较高,主要是由于源域与目标域在快充倍率组合、SOC 切换点和静置时间等方面存在更明显差异,使相近 SOH 水平下的充电电压片段、IC 峰值特征和容量退化轨迹呈现不同分布,从而增加跨批次迁移难度。进一步对比可见,在该任务中,部分传统域适应方法并未稳定优于对应的原始深度学习模型,如 CNN + MMD、LSTM + MMD、GRU + MMD 和 Transformer+MMD 的误差均高于其对应基线模型,说明在强分布偏移条件下,单纯对充电电压片段提取的数据特征进行分布对齐,可能削弱与 SOH 退化相关的判别信息,导致局部负迁移或过度对齐。相比之下,本文方法仍

取得最低 RMSE,表明物理特征与数据特征的协同建模能够为域对齐提供更稳定的退化表征基础,使 MMD 对齐过程更加关注跨批次共享的老化信息,从而在较强分布偏移条件下降低整体预测误差,提高跨批次 SOH 估计的鲁棒性。

综合表 5 结果可见,CNN、LSTM、GRU 和 Transformer 等数据驱动模型主要依赖充电电压片段,缺少退化机理约束;CNN+MMD、CNN+CORAL 等域适应方法虽能缓解分布偏移,但仍主要基于单一数据特征进行对齐,在强协议偏移任务中容易出现过度对齐或泛化不足。相比之下,本文方法融合 IC 峰值相关物理特征与 CNN 数据特征,并利用 MMD 对融合特征进行域对齐,能够同时利用退化机理先验和时序波形信息。因此,本文方法在 XJTU 跨工况任务和 MIT 跨批次任务中均表现出较好的估计精度和跨域泛化能力。

4 结 论

本文针对不同工况下锂离子电池 SOH 跨域估计中存在的数据片段化与分布偏移问题,提出了一种物理-数据双特征融合的跨域 SOH 估计方法。该方法首先基于全寿命周期数据分析与电池退化机理,提取峰值电压、累计容量、峰值处 dQ/dV 值及峰值时间占比等退化敏感物理特征;同时,利用 CNN 从片段化充电电压曲线中提取

数据驱动特征,以补充人工特征难以表征的局部波形变化和动态退化信息。在此基础上,通过特征融合构建兼具物理可解释性和数据表达能力的退化表征,并引入 MMD 对源域与目标域融合特征进行分布对齐,从而提升模型在跨工况场景下的泛化能力。

实验结果表明,所提方法在 XJTU 数据集的 12 组跨工况迁移任务中均取得最低误差,平均 RMSE 为 0.022 3,平均 MAPE 为 2.05%,整体优于仅使用数据特征、仅引入域对齐以及物理-数据融合但无域对齐的消融模型。与 CNN、LSTM、GRU、Transformer、DANN 及其域适应变体相比,所提方法在 XJTU 跨工况任务和 MIT 跨批次任务中整体表现较优,说明物理特征、数据特征与域对齐机制的协同建模能够有效增强跨域退化表征能力。部分任务中误差相对较高,主要与源域和目标域之间的充放电协议、放电策略及测试流程差异较大有关,但整体结果仍验证了所提方法在跨工况 SOH 估计中的有效性和稳定性。

本文所用 XJTU 数据集来自 25℃ 恒温环境下的 18650 型 NMC 电池,所验证的工况差异主要体现在充放电倍率和放电策略变化;MIT 数据集则用于进一步验证模型在不同批次快充数据上的迁移能力。对于不同温度、容量规格下的泛化性能,仍需在后续工作中进一步验证。未来将面向更复杂工况和实际部署需求,研究更轻量化、更鲁棒的跨域 SOH 估计方法,并探索自监督迁移机制与 SOH-SOC 耦合建模在实际电池管理系统中的应用。

参考文献

- [1] 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 Shuai, Dong Jing. 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.
- [2] 赵云飞,徐俊,王霄,等. 双自适应衰减卡尔曼滤波锂电池荷电状态估计[J]. 西安交通大学学报, 2018, 52(12): 99-105.
Zhao Yunfei, Xu Jun, Wang Xiao, et al. An estimation method for state of charge of lithium-ion batteries using dual adaptive fading extended Kalman filter[J]. Journal of Xi'an Jiaotong University, 2018, 52(12): 99-105.
- [3] 张振强,马思乐,姜向远,等. 基于局部模型网络的锂电池 SOC 估计方法[J]. 仪器仪表学报, 2023, 44(7): 161-171.
Zhang Zhenqiang, Ma Sile, Jiang Xiangyuan, et al. State of charge estimation of lithium-ion batteries using local model network [J]. Chinese Journal of Scientific Instrument, 2023, 44(7): 161-171.
- [4] 赵靖英,胡劲,张雪辉,等. 基于锂电池模型和分数阶理论的 SOC-SOH 联合估计[J]. 电工技术学报, 2023, 38(17): 4551-4563.
Zhao Jingying, Hu Jin, Zhang Xuehui, et al. Joint estimation of the SOC-SOH based on lithium battery model and fractional order theory [J]. Transactions of China Electrotechnical Society, 2023, 38(17): 4551-4563.
- [5] Singh P, Chen C, Tan C M, et al. Semi-empirical capacity fading model for SoH estimation of Li-ion batteries[J]. Applied Sciences, 2019, 9(15): 3012.
- [6] Greenbank S, Howey D A. Piecewise-linear modelling with automated feature selection for Li-ion battery end-of-life prognosis [J]. Mechanical Systems and Signal Processing, 2023, 184: 109612.
- [7] 张思而,李旦,张建秋,等. 锂离子电池的等效时变内阻模型及应用[J]. 仪器仪表学报, 2024, 45(5): 118-128.
Zhang Sier, Li Dan, Zhang Jianqiu, et al. Equivalent time-varying internal resistance model of lithium-ion batteries and the corresponding applications[J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 118-128.
- [8] 陈猛,乌江,焦朝勇,等. 锂离子电池健康状态多因子在线估计方法[J]. 西安交通大学学报, 2020, 54(1): 169-175.
Chen Meng, Wu Jiang, Jiao Chaoyong, et al. Multi-factor online estimation method for lithium-ion battery health status [J]. Journal of Xi'an Jiaotong University, 2020, 54(1): 169-175.
- [9] Zhang Q, Wang D F, Schaltz E, et al. Degradation mechanism analysis and State-of-Health estimation for lithium-ion batteries based on distribution of relaxation times [J]. Journal of Energy Storage, 2022, 55: 105386.
- [10] Xiong R, Tian J P, Mu H, et al. A systematic model-based degradation behavior recognition and health monitoring method for lithium-ion batteries [J]. Applied Energy, 2017, 207: 372-383.
- [11] Feng X N, Weng C H, He X M, et al. Online state-of-health estimation for Li-ion battery using partial charging segment based on support vector machine [J]. IEEE

- Transactions on Vehicular Technology, 2019, 68(9): 8583-8592.
- [12] 骆凡, 黄海宏, 王海欣. 基于电化学阻抗谱的退役动力电池荷电状态和健康状态快速预测[J]. 仪器仪表学报, 2021, 42(9): 172-180.
- Luo Fan, Huang Haihong, Wang Haixin. Rapid prediction of the state of charge and state of health of decommissioned power batteries based on electrochemical impedance spectroscopy [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 172-180.
- [13] Liu K L, Li Y, Hu X S, et al. Gaussian process regression with automatic relevance determination kernel for calendar aging prediction of lithium-ion batteries[J]. IEEE Transactions on Industrial Informatics, 2020, 16(6): 3767-3777.
- [14] 胡循泉, 耿莉敏, 舒俊豪, 等. 采用全局健康因子和残差模型的锂离子电池健康状态估计[J]. 西安交通大学学报, 2025, 59(4): 105-117.
- Hu Xunquan, Geng Limin, Shu Junhao, et al. State of health estimation for lithium-ion batteries using global health factors and residual models[J]. Journal of Xi'an Jiaotong University, 2025, 59(4): 105-117.
- [15] 钱伟, 王亚丰, 王晨, 等. 基于 BP 神经网络与 H_∞ 滤波的锂电池 SoH-SoC 联合估计研究[J]. 仪器仪表学报, 2024, 45(6): 307-319.
- Qian Wei, Wang Yafeng, Wang Chen, et al. Joint estimation of SoH-SoC for lithium battery based on BP neural network and H_∞ filter[J]. Chinese Journal of Scientific Instrument, 2024, 45(6): 307-319.
- [16] 何盼, 孔陈杰, 陈天明, 等. 中高轨卫星钴酸锂电池在轨特性分析[J]. 电源技术, 2023, 47(10): 1294-1297.
- He Pan, Kong Chenjie, Chen Tianming, et al. In-orbit performance analysis of lithium cobalt oxide batteries for medium-to-high orbit satellites [J]. Chinese Journal of Power Sources, 2023, 47(10): 1294-1297.
- [17] 潘大为, 师杰, 杜宇航, 等. 基于 BNN-PF 的卫星锂离子电池多工况 SOH 估计[J]. 电子测量与仪器学报, 2024, 38(9): 104-115.
- Pan Dawei, Shi Jie, Du Yuhang, et al. BNN-PF-based SOH estimation of satellite lithium-ion batteries under different operating conditions [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(9): 104-115.
- [18] 陈景龙, 王日新, 李玉庆, 等. 一种基于 SD-ICA 的卫星电池健康状态估计方法[J]. 北京航空航天大学学报, 2021, 47(10): 2058-2067.
- Chen Jinglong, Wang Rixin, Li Yuqing, et al. A state of health estimation method for satellite battery based on smooth and discharge applicative increment capacity analysis[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(10): 2058-2067.
- [19] Wang F J, Zhai Z, Zhao Z B, et al. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis [J]. Nature Communications, 2024, 15: 4332.
- [20] Kiranyaz S, Avcı O, Abdeljaber O, et al. 1D convolutional neural networks and applications: A survey [J]. Mechanical Systems and Signal Processing, 2021, 151: 107398.
- [21] 李龙, 燕旭滕, 张钰声, 等. 采用迁移学习的小样本锂电池荷电状态估算方法[J]. 西安交通大学学报, 2023, 57(11): 142-150.
- Li Long, Yan Xumeng, Zhang Yusheng, et al. A small-sample state-of-charge estimation method for lithium batteries using transfer learning [J]. Journal of Xi'an Jiaotong University, 2023, 57(11): 142-150.
- [22] 翟智, 王福金, 邸一, 等. 基于分层对齐迁移学习的锂离子电池容量估计[J]. 储能科学与技术, 2023, 12(4): 1223-1233.
- Zhai Zhi, Wang Fujin, Di Yi, et al. Hierarchical alignment transfer learning for lithium-ion battery capacity estimation[J]. Energy Storage Science and Technology, 2023, 12(4): 1223-1233.
- [23] 杨淞元, 田勇, 田劲东. 基于 iCEEMDAN 和迁移学习的锂离子电池 SOH 估计[J]. 电气工程学报, 2022, 17(4): 2-10.
- Yang Songyuan, Tian Yong, Tian Jindong. State of health estimation of lithium-ion batteries based on iCEEMDAN and transfer learning [J]. Journal of Electrical Engineering, 2022, 17(4): 2-10.
- [24] Kumari S, Singh P. Deep learning for unsupervised domain adaptation in medical imaging: Recent advancements and future perspectives[J]. Computers in Biology and Medicine, 2024, 170: 107912.
- [25] Zhao Z H, Alzubaidi L, Zhang J L, et al. A comparison review of transfer learning and self-supervised learning: Definitions, applications, advantages and limitations[J].

Expert Systems with Applications, 2024, 242 (10): 122807.

[26] Li Z H, Li A, Bai F, et al. Remaining useful life prediction of lithium battery based on ACNN-Mogrifier LSTM-MMD[J]. Measurement Science and Technology, 2024, 35(1): 016101.

[27] Severson K A, Attia P M, Jin N, et al. Data-driven prediction of battery cycle life before capacity degradation[J]. Nature Energy, 2019, 4(5): 383-391.

[28] Attia P M, Grover A, Jin N, et al. Closed-loop optimization of fast-charging protocols for batteries with machine learning[J]. Nature, 2020, 578(7795): 397-402.

作者简介



赵志斌,2015 年于西安交通大学获得学士学位,2020 年于西安交通大学获得博士学位。现任西安交通大学机械工程学院副教授/特聘研究员,博导,青年拔尖人才 B 类。主要研究方向为高端装备智能运维、工业具身智能等。

E-mail:zhaozhibin@xjtu.edu.cn

Zhao Zhibin received his B.Sc. degree from Xi'an Jiaotong University in 2015, and Ph.D. degree from Xi'an Jiaotong University in 2020. He is currently an associate professor,

distinguished research fellow, Ph.D. Supervisor, and Type B Young Top-notch Talent at the School of Mechanical Engineering, Xi'an Jiaotong University. His main research interests include intelligent operation and maintenance of equipment, industrial embodied intelligence, etc.



武靖耀,2018 年于西安交通大学获得学士学位,2024 年于西安交通大学获得博士学位,主要研究方向为航空动力健康管理。
E-mail:1018680161@qq.com

Wu Jingyao received his B.Sc. degree from Xi'an Jiaotong University in 2018 and his Ph.D. degree from Xi'an Jiaotong University in 2024. His main research focus on aero-engine health management.



刘雪(通信作者),2016 年于西安理工大学获得学士学位,2019 年于西安理工大学获得硕士学位,2025 年于西安交通大学获得博士学位,现为火箭军工程大学讲师,主要研究方向为电池健康管理与寿命预测。
E-mail:xueliud@163.com

Liu Xue (Corresponding author) received her B.Sc. degree from Xi'an University of Technology in 2016, M.Sc. degree from Xi'an University of Technology in 2019, and Ph.D. degree from Xi'an Jiaotong University in 2025. She is currently a lecturer at Rocket Force University of Engineering, and her main research interests include battery health management and life prediction.