

DOI:10.11784/tdxbz202501016

基于多尺度健康因子-BEAST 分解和 SARIMA 模型 结合的锂离子电池剩余使用寿命预测

姚 芳¹, 韩永康¹, 李 谦², 汤 雨¹, 张正宣¹

(1. 河北工业大学电气工程学院, 天津 300401;
2. 国网天津市电力公司电力科学研究院, 天津 300392)

摘要: 锂离子电池的剩余使用寿命(RUL)预测对电池管理和安全性至关重要。现有的 RUL 预测方法多依赖大量历史数据, 且在复杂工况下精度较低, 计算负担重。为解决这些问题, 本文结合健康因子(HI)、贝叶斯时序分解估计器(BEAST)和季节性差分自回归移动平均模型(SARIMA), 提出了一种新颖的 RUL 预测方法。与传统方法不同, 本文创新性地采用 HI 替代最大可放电容量, 能够更精确地反映电池衰退过程; 同时, 结合贝叶斯时序分解估计器对 HI 进行分解与重构, 提高了预测精度, 减少了对大量历史数据的依赖; 最后, 利用季节性差分自回归移动平均模型对电池衰退的时序数据进行建模, 显著提高了预测精度和计算效率。实验结果表明, 以动态工况电池(CS#7)为例, 所提方法在电池衰减 5% 时, 最大相对误差小于 2%, 衰减 10% 时小于 4.31%; 相比 LSTM 和 LSSVM 方法, 本文方法在 MAE 上分别降低了 16.6% 和 25.9%, 计算效率分别提高了 55.2% 和 22.8%。

关键词: 锂离子电池; 剩余使用寿命; 健康因子; BEAST 分解; SARIMA 模型

中图分类号: TM911

文献标志码: A

文章编号: 0493-2137(2026)01-0077-13

Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Combination of Multiscale Health Indicators-BEAST Decomposition and SARIMA Modeling

Yao Fang¹, Han Yongkang¹, Li Qian², Tang Yu¹, Zhang Zhengxuan¹

(1. College of Electrical Engineering, Hebei University of Technology, Tianjin 300401, China;
2. Electric Power Research Institute, State Grid Tianjin Electric Power Company, Tianjin 300392, China)

Abstract: Predicting the remaining useful life (RUL) of lithium-ion batteries is critical for battery management and safety. Existing RUL prediction methods mostly rely on a large amount of historical data and are less accurate and computationally burdensome under complex operating conditions. To address these issues, this paper proposes a novel RUL prediction method by combining the health indicators (HI), the Bayesian estimator of abrupt change, seasonality, and trend (BEAST), and the seasonal autoregressive integrated moving average (SARIMA) model. Different from the traditional method, this paper innovatively adopts HI to replace the maximum dischargeable capacity, which can reflect the battery decline process more accurately. Meanwhile, the decomposition and reconstruction of HI in combination with BEAST improves the prediction accuracy and reduces the dependence on a large amount of historical data. Finally, the SARIMA model for the time-series data of battery decline considerably improves the prediction accuracy and computational efficiency. The experimental results indicate that for batteries under dynamic operating conditions (CS#7), the proposed method maintains maximum relative errors below 2% at 5% capacity degradation and 4.31% at 10% degradation. Compared with the long short-term memory and least square sup-

收稿日期: 2025-01-17; 修回日期: 2025-03-26.

作者简介: 姚 芳 (1972—), 女, 博士, 教授.

通信作者: 姚 芳, yaofang@hebut.edu.cn

基金项目: 河北省自然科学基金资助项目 (E2022202056).

Supported by the Natural Science Foundation of Hebei Province, China (No. E2022202056).

port vector machine methods, the method in this paper reduces the mean absolute error by 16.6% and 25.9% and improves the computational efficiency by 55.2% and 22.8%, respectively.

Keywords: lithium-ion batteries; remaining useful life; health indicator (HI); BEAST decomposition; seasonal autoregressive integrated moving average (SARIMA) model

锂离子电池因其能量密度高^[1]、寿命长^[2]、自放电率低^[3]等优点,被广泛应用于电动汽车、电网储能、航空航天^[4]等领域。然而,随着使用次数的增加,锂离子电池内部会产生锂离子析出、隔膜损伤和电解质氧化等副反应^[5],这些副反应导致电池性能衰减^[6],最终降低电池的使用寿命。因此,准确预测电池剩余使用寿命,对优化电池使用、减小电池事故风险、避免经济损失具有积极意义。

锂离子电池剩余使用寿命(remaining useful life, RUL)是指在一定充放电条件下从当前状态衰减至终止阈值(GB/T 31484—2015 规定为容量的 80%)时的循环次数。目前,锂离子电池 RUL 预测方法主要包括模型法和数据驱动法^[7-8]。

模型法包括电化学模型以及等效电路模型。电化学模型可以精确反映内部物质的物理化学特性,对于诊断衰减模式、精确预测很有意义。如范立明等^[9]基于电极材料的质量和容量、内部阻抗描述容量衰减过程,建立电池电化学模型进行 RUL 预测;但电化学建模需要通过电化学阻抗谱、扫描电镜等获取内部状态,所需时间和经济成本较高,而且建立模型泛化能力有限^[10]。等效电路模型在精度和复杂度上相对平衡,一阶或二阶 RC 是最常用的等效电路模型。孙冬等^[11]提取 R_{omean} 、 R_{omin} 、 R_0 与荷电状态(state of charge, SOC)曲线预测健康状态(state of health, SOH)衰减。与电化学模型相似,等效电路模型在稳定工况下 RUL 预测精度高,但模型的性能受电流和温度等外部条件变化的影响较大,从而影响预测精度。

与传统模型法相比,基于数据驱动的 RUL 预测方法不需要复杂建模,将电池视为一个黑箱^[12],直接从电池循环数据中挖掘来表征电池退化趋势的健康因子(health indicator, HI)来进行 RUL 预测,节约建模成本,为电池 RUL 预测提供了新思路。HI 的提取与选择作为基于数据驱动方法的最重要环节,直接影响电池 RUL 预测的准确性和可靠性。充放电容量虽然是反映电池退化特征的最直观的物理量,但将容量作为 HI 并不是最佳选择。首先,电池容量的测量需要依靠精密且昂贵的仪器,不易直接测得,大多数情况下并不是直接测量,而是从可直接测量的电压、电流、充放电时间等物理量间接计算而来^[13]。再者,容量是表征电池目前性能,仅仅依靠容量变化将会失去

电池退化过程的其他有用信息,进而影响电池 RUL 预测性能。因此,除了电池容量,还可从电池充放电数据中提取可有效表征电池老化特征的 HI,来提高电池 RUL 的预测精度和泛化能力。

目前基于数据驱动的典型方法包括滤波算法^[14]、神经网络算法^[15]、机器学习算法^[16]等。Chen 等^[17]提取等压降放电时间当作 HI,使用支持向量回归(support vector regression, SVM)进行电池 SOH 估计。Wang 等^[18]将充电容量(Q_{charge})和恒流充电时间(t_{CC})作为 HI,利用无迹卡尔曼滤波进行迭代计算,以此克服电池 RUL 预测过程的非线性状态的计算误差,但计算复杂度较高,不适合在线应用。Pang 等^[19]基于增量容量(incremental capacitance, IC)曲线进行分析,从 IC 曲线中提取峰下区域面积和 dQ/dU 峰值作为 HI 并结合高斯过程回归模型预测电池 RUL,但模型计算效率较低,且不适应动态工况要求。Liu 等^[20]将电池容量作为 HI,使用经验模态分解对电池容量进行分解降噪来评估电池衰减趋势,实现了电池 RUL 预测,但存在计算复杂度高、实时性不足的问题。方斯顿等^[21]从锂电池充放电过程中提取的多个时间特征,基于间接 HI 和鲸鱼优化算法(whale optimization algorithm, WOA)优化的双向长短期记忆网络的实现了锂电池 SOH 估计,但模型实时性较差,不利于在线应用。Saleem 等^[22]提出的 TransRUL 模型,利用 Transformer 架构捕捉电池退化的长期依赖关系,在 CALCE 数据集上预测精度高,但存在数据需求大、泛化能力弱的局限。

综合来看,基于数据驱动的 RUL 预测方法更受国内外学者欢迎,但仍存在些许问题:①电池 HI 的提取直接影响电池 RUL 预测的有效性,可靠的电池 HI 成为数据驱动方法的最重要环节;②目前数据驱动方法依赖大量实验数据进行训练,计算效率较低,且难以适应复杂工况;③目前数据驱动方法缺乏不确定性分析,仅通过建立输入和输出之间的映射关系,来实现 RUL 的点估计,难以量化预测结果的置信区间或错误范围。

基于上述问题,本文设计多尺度 HI-贝叶斯时序分解估计器-季节性差分自回归移动平均模型(HI-BEAST-SARIMA)的 RUL 预测方法。该方法通过融合动静态工况尺度与多时间尺度特征,提取电池多尺

度 HI，基于相关系数法筛选高关联性 HI 作为 RUL 预测模型输入，有效解决单维度 HI 在复杂工况下表征失真的问题；利用贝叶斯时序分解估计器 (Bayesian estimator of abrupt change, seasonality, and trend, BEAST) 分解与重构 HI 序列，避免容量回升导致的局部波动和测试噪声对 RUL 预测结果造成干扰，提升了预测精度；使用季节性差分自回归移动平均 (seasonal autoregressive integrated moving average, SARIMA) 模型可在小样本数据进行电池 RUL 预测，无需依赖大量实验数据，不仅适应电池长期衰退和复杂工况的变化，还可输出 RUL 预测的置信区间来量化预测结果的可靠性，为电池 RUL 的可靠预测提供有力支持。

1 电池 HI 提取与验证

1.1 数据来源

本文选取 3 种电池数据来提取电池 HI，以此提高 RUL 预测方法的泛化性。第 1 类是本文设计的恒流充放电循环测得的电池数据；第 2 类是选择马里兰大学数据集中放电截止电压动态变化的 CS2#7 电池数据；第 3 类是选择 NASA 数据集中放电电流动态变化的 RW17 电池数据。第 1 类数据用以表征恒流充放电循环下的 RUL 的退化进程，第 2 类和第 3 类数据用以表征动态工况循环下的 RUL 退化趋势。

1.1.1 恒流充放电工况数据集

本文使用 $2\text{ A}\cdot\text{h}$ 的 NCM18650 电池进行恒流充放电循环实验，基于不同应力条件设计开展循环寿命试验。实验应力条件设计基于以下依据。

(1) 充放电倍率：增大充放电倍率，加速锂离子嵌入/脱嵌过程中的浓差极化与欧姆极化，导致电极活性材料颗粒微裂纹扩展和 SEI 膜非均匀增厚^[23]。当倍率超过材料本征扩散速率时，会引起锂金属析出的不可逆损伤，加速电池的容量衰减和老化衰退。

(2) 环境温度：根据 Arrhenius 方程，温度每升高 $10\text{ }^{\circ}\text{C}$ 化学反应速率加倍^[24-25]。高温 ($>45\text{ }^{\circ}\text{C}$) 会加速电解液分解和正极过渡金属溶解，低温 ($<0\text{ }^{\circ}\text{C}$) 则通过增大电荷转移阻抗诱发锂枝晶生长。由此说明，环境温度可显著影响电池的循环寿命。

实验设备包括新威电池检测系统、程式温湿箱和上位机，测试平台如图 1 所示。实验方案设计如下：

- (1) 对电池试样进行容量测试和混合动力脉冲特性测试，筛选一致性良好的实验电池；
- (2) 为研究不同环境温度、充放电电流对单体电

池退化的影响，将充电倍率 I_C 、放电倍率 I_D 、环境温度 t_a 作为加速应力进行循环寿命试验，具体实验方案如表 1 所示；

(3) 每间隔 50 次充放循环测试容量、内阻、准开路电压，开展典型动态工况测试；

(4) 记录分析电池容量、电压、内阻数据，总结衰减规律。




图 1 电池循环寿命测试平台
Fig.1 Battery cycle life test platform

表 1 典型应力下电池循环寿命试验方案

Tab.1 Battery cycle life test program under typical stress

实验组别	应力条件		
	I_C	I_D	$t_a/^{\circ}\text{C}$
1	1.0 C	1.0 C	25
2			45
3	2.0 C	2.0 C	25
4			45
5		2.5 C	25
6			45
7	1.0 C	DST	25

注：DST 为动态应力工况 (dynamic stress test)，即动态变化的电流放电。

1.1.2 马里兰大学(CALCE)公开数据集

为模拟电池放电深度不确定的情况，不同循环阶段的放电截止电压需随机设定。选用马里兰大学公开数据集的 CS#2 电池作为动态电压工况实验数据集，该电池为 $1.1\text{ A}\cdot\text{h}$ 的 LiCoO_2 电池，充电采用恒流-恒压方式，其放电电压随各循环在 $2.7\sim3.9\text{ V}$ 之间动态变化，具体工况如图 2 所示。

1.1.3 NASA 公开数据集

为模拟电池工作电流随机波动的情况，不同循环阶段的放电电流需要随机设定。选用 NASA 公开数据集的 RW17 电池作为动态电流工况的实验数据集，该电池为 $2\text{ A}\cdot\text{h}$ 镍钴铝 (nickel cobalt aluminum, NCA) 电池，充电采用恒流-恒压方式，在各循环间使用 $0.5\sim5.0\text{ A}$ 随机电流序列放电，具体工况如图 3 所示。






图 2 CS#2 电池动态放电工况

Fig.2 Dynamic discharge condition of CS#2 battery



(a) 前 10 个循环下的电压波形



(b) 前 10 个循环下的电流波形

图 3 RW17 电池动态放电工况

Fig.3 Dynamic discharge condition of RW17 battery

1.2 多尺度 HI 提取与验证

电池在循环老化进程中, 电池最大放电容量是表征老化程度最直接的量, 但电池容量不易测得. 因此, 本次研究从可直接测得的电压、电流、充放电时间及容量增量等物理量入手, 选取可有效表征电池退化进程的 HI, 利用 HI 进行电池 RUL 预测.

为提升电池 RUL 预测的鲁棒性, 本文提出的“多尺度 HI”从工况和时间两个尺度提取电池退化特征.

(1) 工况尺度: 为有效提取电池在不同应用工况下的退化特征, 进一步提高 RUL 预测的泛化能力, 分别在恒流充放电、动态放电电压、动态放电电流工况循环下提取多工况尺度 HI.

(2) 时间尺度: 为有效利用电池在不同循环周期内的退化特征, 分别在短时间尺度、中时间尺度和长

时间尺度下提取多时间尺度 HI.

短时间尺度表示为单次或几次循环, 用以捕捉瞬时性能波动; 短时 HI 如充电时间 (t_{CC})、放电电压增量比 ($\Delta Q/\Delta U$) 等.

中时间尺度表示为几百次循环, 用以反映电池线性衰减趋势; 中时间尺度 HI 如充电容量保持率 (Q_{charge}) 等.

长时间尺度表示为全生命周期循环, 用以表征电极极化加剧. 长时间尺度 HI 如起始放电电压 (U_{SOCmax}) 等.

基于 Pearson 与 Spearman 相关系数计算 HI 与最大可放电容量的相关性, 选择各尺度中与容量相关性最高的因子, 确保多维度覆盖电池退化特征. 相关系数计算如下.

1) Pearson 相关系数

Pearson 相关系数 r 是最常用的相关系数, 直接反映了两个变量之间线性相关的强弱, 可以表达为

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

式中: n 为循环次数; x_i 为第 i 次循环下 HI; y 为容量. Pearson 系数在 $-1 \sim 1$ 之间, 绝对值越接近 1 则表示相关性越强.

2) Spearman 相关系数

Spearman 相关系数是一个非参数指标, 可以评估两个变量之间的严格单调关系. 有两个变量 x_i 和 y_i ($i = 1, 2, \dots, n$), 然后将它们的元素按升序排列. Spearman 等级相关系数 ρ 可以表示为

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (2)$$

$$d_i = r_g(x_i) - r_g(y_i) \quad (3)$$


式中 $r_g(x_i)$ 和 $r_g(y_i)$ 分别表示 x_i 和 y_i 在升序后的新秩序.

1.2.1 恒流充放循环下电池 HI 提取与验证


从恒流充放循环充放电过程的电压、电流和温度数据中提取反映电池退化的 HI. 各 HI 随电池退化的变化趋势如图 4 所示.

图 4(a) 为电池起始放电电压 (U_{SOCmax}) 随循环次数的变化情况. 随着循环次数增加, U_{SOCmax} 整体呈现下降趋势, 表明电池内部阻抗升高和极化效应加剧. 起始放电电压下降是老化早期的敏感指标, 可先于容量衰减被发现. 例如, SEI 膜增厚引起的阻抗升高可通过电压变化直接反映, 而容量可能尚未显著


下降。




(a) 起始放电电压变化曲线



(b) 恒流充电时间变化曲线



(c) 放电过程的增量容量变化曲线



(d) 充电容量变化曲线

图 4 恒流循环下各 HI 随电池退化的变化趋势

Fig.4 Variation trend of each health indicator under constant current cycling

图 4(b) 为不同循环次数下, 电池充电过程中恒流充电时间 (t_{CC}) 变化曲线。随着循环次数增加, 电池的恒流充电时间与总充电时间的比值随着循环增加逐渐降低。恒流充电时间直接反映电池可用容量的

变化, 随着电池老化的加深, 内部锂金属沉积会减少可用活性锂, 加速容量衰减, 同样缩短恒流充电时间。

图 4(c) 为电池放电过程中增量容量变化曲线 ($U-dQ/dU$)。增量容量曲线对老化机理具有特异性, 随着循环次数的增加, $U-dQ/dU$ 曲线收缩, 表明单位电压内电池放出容量减少。考虑到 dQ/dU 计算和滤波处理的复杂性, 提取放电起始-终止阶段内容量增量与电压增量的比值 $\Delta Q/\Delta U$ 作为 HI。 $\Delta Q/\Delta U$ 为当前循环下放电容量 $Q_{current}$ 和放电始末电压差 ($U^{SOC_1} - U^{SOC_2}$) 的比值, 即

$$\frac{\Delta Q}{\Delta U} = \frac{Q_{current}}{U^{SOC_1} - U^{SOC_2}} \quad (4)$$

图 4(d) 为电池充电容量 Q_{charge} -循环次数变化曲线。随着循环次数增加, 电池充电容量逐渐减低, 容量保持率整体呈现下降趋势。

这些物理量通过直接或间接反映 SEI 膜增长、锂沉积等微观老化过程, 能够替代最大容量作为 HI。

为了选择最相关的 HI, 计算了恒流循环条件下电池 HI 与最大可放电容量的 Pearson 和 Spearman 相关系数, 结果如表 2 所示。

表 2 恒流循环条件下电池 HI 与最大可放电容量的相关系数

Tab.2 Correlation coefficients between battery HI and maximum dischargeable capacity under constant current cycling conditions

HI	Pearson 相关系数	Spearman 相关系数
$U^{SOC_{max}}$	0.979 9	0.982 3
t_{CC}	0.987 5	0.988 1
Q_{charge}	0.993 1	0.992 6
$\Delta Q/\Delta U$	0.994 4	0.995 2


由表 2 可以看出, Q_{charge} 和 $\Delta Q/\Delta U$ 的 Pearson 和 Spearman 相关系数最接近 1.000 0, 因此, 选择电池实际充电容量 Q_{charge} 和放电 $\Delta Q/\Delta U$ 作为 HI, 替代最大可放电容量用于 RUL 预测。

1.2.2 动态工况循环下电池 HI 提取与验证



从电池 CS2#7 和 RW17 动态工况充放循环数据中提取反映电池退化的各类 HI。动态工况以 CS2#7 为例, 各 HI 随电池退化的变化趋势如图 5 所示。

图 5(a) 为 CS2#7 的 $\Delta Q/\Delta U(CC)$ 变化曲线, $\Delta Q/\Delta U(CC)$ 是充电恒流段起始 SOC_1 和终止 SOC_2 之间的容量增量和电压增量的比值, 反映电池内部反应的动力学特性, 老化电池的 $\Delta Q/\Delta U(CC)$ 变化曲线呈现下降趋势。具体数学表达式为

$$\frac{\Delta Q}{\Delta U(CC)} = \frac{Q_{current}}{U^{SOC_1} - U^{SOC_2}} \quad (5)$$



(a) 容量增量和电压增量的比值变化曲线

(b) 电池 $\text{std}(\Delta Q)/\text{std}(\Delta U)$ 的比值变化曲线

(c) 起始放电电压变化曲线

图 5 电池 CS2#7(动态工况循环)的 HI 随电池退化的变化趋势

Fig.5 Variation trend of HI of battery CS2#7(dynamic duty cycle) with battery degradation

图 5(b) 为 CS2#7 的 $\text{std}(\Delta Q)/\text{std}(\Delta U)$ 变化曲线, $\text{std}(\Delta Q)/\text{std}(\Delta U)$ 为 1 min 间隔内电量增量的标准差与电压增量的标准差的比值, 物理意义为充放电过程中电量和电压波动的稳定性, 可捕捉电池内部微观结构的变化(如 SEI 不均匀性或锂枝晶分布), 提供容量之外的动态老化信息, 尤其在早期老化阶段更敏感. 具体数学式为

$$\frac{\text{std}(\Delta Q)}{\text{std}(\Delta U)} = \frac{\sqrt{\frac{\sum_{i=1}^c (Q_i - \bar{Q})^2}{c-1}}}{\sqrt{\frac{\sum_{i=1}^e (U_i - \bar{U})^2}{e-1}}} \quad (6)$$

式中 c 和 e 为 1 min 间隔内电量与电压的数据个数.

图 5(c) 为电池 CS2#7 的起始放电电压值

(U_{SOCmax}) 变化曲线, 随着循环次数增加, 电池起始放电电压整体呈现下降趋势, 放电过程中电压下降速率加快. 如电池老化进程中的锂枝晶生长可能刺穿隔膜, 造成活性锂损失和界面阻抗升高, 进一步降低初始放电电压.

动态工况循环下的 HI 同样可有效表征电池的衰退趋势, 不仅提供更早期的老化预警, 还能区分不同失效模式, 可作为 HI 进行电池 RUL 预测.

电池 CS2#7 和 RW17 动态工况循环条件下 HI 与最大可放电容量的 Pearson 和 Spearman 相关系数计算结果如表 3 所示.

表 3 动态工况循环下电池 HI 与最大可放电容量的相关系数

Tab.3 Correlation coefficients between battery HI and maximum dischargeable capacity under dynamic duty cycle conditions

电池类型	HI	Pearson 相关系数	Spearman 相关系数
CS2#7	$\Delta Q/\Delta U(\text{CC})$	0.997 8	0.994 7
	$\text{std}(\Delta Q)/\text{std}(\Delta U)$	0.887 5	0.885 1
	U_{SOCmax}	0.898 5	0.883 1
RW17	$\Delta Q/\Delta U(\text{CC})$	0.927 3	0.912 5
	$\text{std}(\Delta Q)/\text{std}(\Delta U)$	0.932 5	0.943 7
	U_{SOCmax}	0.899 8	0.900 1

由表 3 可见, 择优选取 $\Delta Q/\Delta U(\text{CC})$ 作为电池 CS2#7 的用于动态工况 RUL 预测的 HI, 选取 $\text{std}(\Delta Q)/\text{std}(\Delta U)$ 作为电池 RW17 用于动态工况 RUL 预测的 HI.

2 电池 RUL 预测方法

本节提出了 RUL 预测算法, 具体包括基于 BEAST 的 HI 分解与重构、SARIMA 模型建模和 RUL 预测, 整体预测框架如图 6 所示.

2.1 基于 BEAST 的 HI 分解与重构

在电池的充放电循环中, 无论是恒流工况还是动态工况, HI 通常表现出明显的尖峰和周期性波动. 这些波动既源于电池衰退过程中的测量噪声, 也包含由于充放电速率、电池温度等使用条件变化引起的容量恢复效应. 这些波动不仅仅是噪声, 也反映了电池健康状态的动态变化, 且随着电池衰退的加剧, 波动幅度更加剧烈. 因此, 本文认为恢复特性对电池 RUL 预测至关重要, 并通过分解和重构的方式合理利用了这一信息, 避免了传统滤波算法中可能丢失关键信息的风险.

为了提取电池衰退和恢复的有效趋势, 本文采用 BEAST, 对 HI 进行分解和重构. 通过 BEAST 分解




图 6 RUL 预测总体架构

Fig.6 RUL prediction overall architecture

和重构的方式合理利用了衰退和恢复的有效信息,避免了传统滤波算法中可能丢失关键信息的风险. 具体为:从 HI 中提取有效的趋势项 $T(t)$ 和季节项 $S(t)$,最后叠加趋势项 $T(t)$ 和季节项 $S(t)$ 形成新序列,便于后续进行电池 RUL 预测.

BEAST^[26]可基于贝叶斯推理将时间序列分解出季节项 $S(t)$ 、趋势项 $T(t)$ 以及趋势突变点 TCP 和周期突变点 SCP. BEAST 本质上是一个贝叶斯线性回归模型,将 1 维时间序列 $y(t)$ 视为多个基函数 x 的线性组合,可表示为

$$y(t_i) = S(t_i; \Theta_S) + T(t_i; \Theta_T) + \varepsilon_i \quad (7)$$

式中: $S(t_i; \Theta_S)$ 和 $T(t_i; \Theta_T)$ 分别为季节项和趋势项; ε_i 为设定高斯噪声.

季节项 $S(t)$ 近似为分段谐波模型,时间序列划分为 $z+1$ 个区间,形式为

$$S(t) = \sum_{l=1}^{L_k} \left[a_{k,l} \sin\left(\frac{2\pi lt}{T}\right) + b_{k,l} \cos\left(\frac{2\pi lt}{T}\right) \right] \quad (8)$$

式中: T 为信号周期; L_k 为第 k 段谐波阶数; l 为傅里叶项的基数; $a_{k,l}$ 和 $b_{k,l}$ 分别为 l 阶正弦项和余弦项的系数.

趋势项 $T(t)$ 表示为关于 $\tau_j (j=1, 2, \dots, w)$ 处的 m 节分段线性函数形式,其将时间序列划分为 $w+1$ 个区间 $[\tau_j, \tau_{j+1}]$,形式为

$$T(t) = a_j + b_j K \quad (9)$$

$$\tau_j \leq K < \tau_{j+1}, j = 0, 1, \dots, w$$

其中季节项变化点数量 K 及时序趋势项变化点数量 w 及时序 τ_j 是未知参数,需要根据后验推理得到.

以电池 CS2#7 为例,图 7 展示了 HI 的分解过程、原始 HI 序列和重构后的 HI 序列.

由图 7 可见,电池 CS2#7 的衰退速率在不同阶段受放电深度影响存在差异.通过 BEAST,将 HI 分解为趋势项和季节项,分别代表电池的衰退过程和周期性变化.这一方法有效提取了电池的衰退趋势,区分了衰退与恢复特征,并保留了恢复信息.与传统方法仅剔除波动不同,这种分解方式提升了 RUL 预测的精度,确保了恢复过程对预测的贡献.


2.2 SARIMA 模型建模

在电池退化过程中,其性能衰退往往呈现出显著的非线性特征,因此需要基于大量历史数据提取其演变规律以预测 RUL. SARIMA 作为一种非线性时间序列分析方法^[27],在短期预测中展现出独特优势:首先,该模型能够有效处理小样本条件下的非平稳时间序列,通过差分运算将其转化为平稳序列;其次,它可同步解析时间序列的趋势性、周期性和随机性特征^[28];再者,该方法不仅能基于历史规律进行外推预测,还能量化预测结果的不确定性区间.鉴于上述特点,本研究选用 SARIMA 模型进行电池 RUL 预测.


SARIMA 由趋势分量和季节分量复合构成,可表示为 $ARIMA(p, d, q) (P, D, Q)_s$. (p, d, q) 用于趋势分量, (P, D, Q) 用于季节分量, s 为时间序列周期. (P, D, Q) 与 (p, d, q) 定义了 SARIMA 模型的阶数,其中 P 和 p 为自回归阶数,它用于保留历史信息的影响, D 和 d 为差分阶数,表示过去时间点的差异量, Q 和 q 为移动平均阶数,表示历史时间点观测到的误差值的线性组合.建模流程如图 8 所示,包含 5 个核心步骤.

步骤 1 平稳性检验.


(1) 获取采用 BEAST 分解重构后的 HI 序列 (容量衰减 10% 以内).



(a) 详细的 HI 分解过程



(b) 电池 CS2#7 原始 HI 序列



(c) 电池 CS2#7 重构后的 HI 序列

图 7 电池 CS2#7 的 HI 分解和重构结果

Fig.7 Battery CS2#7 HI decomposition and reconstruction results

(2) 使用增广迪基-富勒(augmented Dickey-Fuller, ADF)检验方法来检验平稳性,设定原假设 H_0 为序列平稳;备选假设 H_1 为序列非平稳.显著性水平设为 $\alpha = 0.05$,若检验统计量 $ADF < \text{临界值}$ 且假设概率小于 0.05,则拒绝 H_0 ,证明 HI 序列为非平稳,

采用步骤 2 的差分运算进行平稳化.




图 8 SARIMA 模型建模流程

Fig.8 Modeling flow process of SARIMA model

步骤 2 差分运算处理.

对非平稳序列时间序列进行必要的趋势差分和季节差分处理,得到平稳的 HI 序列,并确定最终的 d 和 D . 具体公式为

$$\nabla^d = (1 - B)^d y_t \quad (10)$$

$$\nabla_s^D = (1 - B^s)^D y_t \quad (11)$$

式中 B 为滞后算子.

步骤 3 白噪声检验.

使用 Ljung-Box 检验对平稳 HI 序列进行白噪声检验,验证差分后序列是否为随机噪声.如果通过检验,表明模型拟合良好,可以进行后续建模;否则,返回步骤 2,重新调整差分阶数或进一步平稳化数据.

步骤 4 拟合 SARIMA 模型.

计算样本自相关函数值和偏相关函数值,寻找自相关函数值、偏相关函数值开始呈现趋于 0 的“拖尾”特性,初步确定 p, q, P, Q 值;使用最小二乘法估计模型模型参数,计算模型残差和赤池信息准则(Akaike information criterion, AIC)值,根据 AIC 准则寻找 AIC 取最优值的阶数.

步骤 5 模型验证与评估.

为验证 SARIMA 模型的泛化能力并避免过拟合,采取以下措施:

(1) 样本划分与滚动预测:将重构后的 HI 序列划分为训练集和测试集为 8 : 2 的比例,采用滚动预测策略逐步验证模型预测性能;

(2) 信息准则优化:通过 AIC 与贝叶斯信息准则(Bayesian information criterion, BIC)联合优化,限制模型阶数($p + q + P + Q \leq 6$)以避免过度参数化,当两准则出现冲突时,优先选择结构更简洁的模型以降低

过拟合风险;

(3) 残差分析: 通过白噪声检验验证模型的有效性, 确保模型充分捕捉序列特征. 如果残差存在自相关性或模型不满足验证标准, 返回调整模型阶数进行重新拟合.

2.3 RUL 预测

电池的 RUL 预测分为以下 4 个步骤.

步骤 1 确定 RUL 预测起点与阈值.

电池 RUL 预测需要选择预测起点, 本文拟使用电池 90% C_D (C_D 为最大可用容量) 为 RUL 预测起点的选择该起点的依据如下:

(1) 工程标准参考: 根据 GB/T 31484—2015 标准, 电池容量衰减至 80% C_D 为寿命终止阈值, 而 90% C_D 作为预测起点可保留 10% 的容量衰减窗口, 确保足够的剩余寿命预测空间, 避免过早预测导致误差累积;

(2) 数据敏感性分析: 电池容量衰减至 90% C_D 时, HI 已呈现显著且稳定的衰退趋势, 利于 SARIMA 模型捕捉规律, 据此确定 90% C_D 为 RUL 预测起点, 并根据容量衰减 5% 和 10% 对应 HI 的变化量, 推算出衰减至 85% C_D 和 80% C_D 的阈值 $-\Delta HI_5\%$ 和 $-\Delta HI_{10\%}$, 作为寿命终点判据.

步骤 2 构建 HI 时间序列模型.

通过最大可放电容量 C_D 衰减 10% 以内的 HI 数据和 SARIMA 模型构建 HI 时间序列模型 $HI_{g+1} = f(HI_g, HI_{g-1}, \dots, HI_{g-h}), h < g$;

步骤 3 预测 RUL.

通过 SARIMA 所构建的 HI 时间序列模型向后预测 l 步, 判断 HI 预测值是否达到衰减 5% 和 10% 阈值条件, 若小于阈值则延长预测步长. 计算从预测起点到终止阈值所经历的循环数, 即得到电池当前的 RUL.

步骤 4 不确定性量化.

在进行 RUL 预测时, 使用 SARIMA 模型的预测结果并结合 3σ 法则, 输出 95% 置信度下的预测置信区间. 这为 RUL 预测结果提供不确定性分析, 帮助量化预测的可靠性.

3 实验验证

本文选取 3 种电池数据来验证本文方法的 RUL 预测性能. 使用本文设计的恒流充放电循环的电池数据验证恒流充放电循环下的 RUL 预测, 使用 NASA 的 RW17 和 CALCE 的 CS2#7 电池数据来验

证动态工况循环下的 RUL 预测.

为了评估所提出的模型的预测精度, 本文使用了绝对误差 (E_A)、相对误差 (E_R)、平均绝对百分比误差 (E_{MA}) 评价 RUL 预测准确性, 可分别表示为

$$E_A = |T_{RUL} - P_{RUL}| \quad (12)$$

$$E_R = \frac{|T_{RUL} - P_{RUL}|}{T_{RUL}} \quad (13)$$

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Q_i - \hat{Q}_i}{Q_i} \right| \quad (14)$$

式中: T_{RUL} 和 P_{RUL} 分别为 RUL 的真实值和预测值; Q_i 和 $\hat{Q}_i$ 分别为容量的真实值和预测值.

3.1 预测起点选择验证

为验证预测起点 (90% C_D) 的合理性, 本节以电池 CS2#7 (动态工况) 为例, 对比不同起点 (100% C_D 、95% C_D 和 90% C_D) 的预测效果, 结果如表 4 所示.

表 4 动态工况循环下电池 (CS2#7) RUL 预测结果与误差
Tab.4 Battery (CS2#7) RUL prediction results and errors for cell CS2#7 with different prediction starting points

预测起点	衰减阈值	$P_{RUL}/\text{次}$	$T_{RUL}/\text{次}$	$E_A/\text{次}$	$E_R/\%$
100% C_D	85% C_D	434	427	6	1.41
	80% C_D	530	538	8	1.49
95% C_D	85% C_D	430	427	3	0.70
	80% C_D	533	538	5	0.93
90% C_D	85% C_D	428	427	1	0.23
	80% C_D	534	538	4	0.74


由表 4 可知, 以 90% C_D 为起点时, 预测绝对误差 (E_A) 和相对误差 (E_R) 均显著低于 100% C_D 和 95% C_D . 其原因为: 过早预测 (如 95% C_D) 时, HI 的时序波动尚未充分体现衰退趋势, 导致模型拟合不稳定; 而 90% C_D 起点下, HI 序列已包含足够的退化信息, 且数据噪声相对较低, 提升了预测可靠性. 此外, 90% C_D 符合工程标准 (GB/T 31484—2015) 对剩余寿命窗口的定义. 因此, 本文后续实验均以 90% C_D 作为预测起点.

3.2 恒流工况循环下电池 RUL 预测结果


图 9 中展示了 25 °C-1.0 C 充电-1.0 C 放电循环、45 °C-1.0 C 充电-1.0 C 放电循环、45 °C-2.0 C 充电-2.5 C 放电循环的 3 类 RUL 预测结果. 表 4 记录了这 3 种循环条件下从预测起点开始继续衰减 5% 和 10% 对应的实测循环次数、预测循环次数、误差与 RUL. 结合图 9 和表 5 分析恒流循环下电池 RUL 预测结果.

由图 9 可见, 电池衰减趋势随着温度变化略有区别, 受实验时充放电之间静置时间的影响, 电池衰减


过程中存在“短暂恢复”和“恢复后下降”的情况。25℃-1.0C 充电-1.0C 放电、45℃-1.0C 充电-1.0C 放电和 45℃-2.0C 充电-2.5C 放电起始预测起点分别为 334、385 和 250 次循环, HI 预测值与真实值曲线基本吻合, 且 HI 预测值都在 95%置信区间内, 预测可靠性较高。



(a) 25℃-1.0C 充电-1.0C 放电循环



(b) 45℃-1.0C 充电-1.0C 放电循环



(c) 45℃-2.0C 充电-2.5C 放电循环

图 9 恒流工况循环下的电池 RUL 预测结果

Fig.9 Battery RUL prediction results under constant-current duty cycle

根据表 5 可知, 在 3 种循环条件下, 电池继续衰减 5% 的预测相对误差分别为 1.06%、1.73% 和 1.38%; 电池继续衰减 10% 的预测相对误差分别为 3.84%、3.96% 和 1.71%。结果表明, 所提出的 RUL 预测方法在恒流循环条件下具有较低的预测误差, 且能够提供置信区间, 较为精确地反映电池的衰退过程。

表 5 恒流工况循环下电池 RUL 预测结果与误差


Tab.5 Battery RUL prediction results and errors under constant current duty cycle

循环条件	衰减阈值	$P_{RUL}/$ 次	$T_{RUL}/$ 次	$E_A/$ 次	$E_R/\%$	RUL 置 信区间
25℃-1.0C 充	85% C_D	556	562	6	1.06	[534, 556]
电-1.0C 放电	80% C_D	731	702	27	3.84	[700, 731]
45℃-1.0C 充	85% C_D	511	520	9	1.73	[499, 511]
电-1.0C 放电	80% C_D	682	656	26	3.96	[650, 682]
45℃-2.0C 充	85% C_D	292	288	4	1.38	[280, 317]
电-2.5C 放电	80% C_D	344	350	6	1.71	[344, 380]


注: 循环条件顺序为环境温度-充电倍率-放电倍率。

3.3 动态工况循环下电池 RUL 预测结果

图 10 为动态工况循环下的电池 RUL 预测结果, 图 10(a) 为电池 CS2#7 的 RUL 预测结果, 图 10(b) 为电池 RW17 的 RUL 预测结果。表 6 为两种循环条件下从预测起点到衰减 5% 和 10% 对应的实测循环次数、预测循环次数、误差与 RUL。



(a) 电池 CS2#7



(b) 电池 RW17

图 10 动态工况循环下的电池 RUL 预测结果

Fig.10 Battery RUL prediction results under dynamic duty cycle

由图 10 可知, 电池衰退过程中受不一致的放电深度和电流影响, 存在恢复效应。为避免偶然性, 采用连续低于阈值的几个循环来判定终止, 并以低于阈值的循环段中的首个循环计算 RUL 及预测误差。电池 CS2#7 和电池 RW17 的预测起点分别为 330 次和 141 次。在衰减至 5% 和 10% 的过程中, 其预测值及置信区间在衰减过程中均紧邻真实值波动, 且严格位于

95%置信区间内。

值得注意的是,虽然 CS2#7 预测曲线末尾段(500 次循环后)出现小幅突变,但电池 CS#7 的 RUL 预测值依旧具有较高精度。究其原因,此突变现象源于动态工况与模型的交互作用。

(1) 动态工况影响:CS2#7 电池的放电截止电压在 2.7~3.9 V 之间动态变化,导致其 HI 序列存在非平稳的季节性波动。

(2) 模型机制:在预测阶段,SARIMA 模型通过 (p, d, q) (P, D, Q) 参数对趋势和季节项进行联合建模,当电池接近寿命终点时,季节项的周期性波动与趋势项的加速衰减叠加,导致预测曲线末尾段出现小幅突变。

表 6 动态工况循环下电池 RUL 预测结果与误差

Tab.6 Battery RUL prediction results and errors under dynamic duty cycle

电池类型	衰减阈值	$P_{RUL}/\text{次}$	$T_{RUL}/\text{次}$	$E_A/\text{次}$	$E_R/\%$	RUL 置信区间
CS2#7	85% C_D	428	[427,429]	1	0.23	[413,444]
	80% C_D	534	[538,540]	4	0.74	[510,540]
RW17	85% C_D	201	[195,198]	6	2.98	[177,204]
	80% C_D	218	[209,214]	9	4.31	[203,220]


由表 6 可知,电池 CS2#7 在衰减 5%和 10%时的相对误差为 0.23%和 0.74%,显著低于 RW17 的 2.98%和 4.31%。所有预测值严格位于 95%置信区间内,验证了该方法对动态工况不确定性的合理量化能力。结果表明,所提方法通过分解-重构机制解耦动态工况的短期波动与长期衰退,在复杂条件下实现高精度预测,同时置信区间为工程决策提供可靠性依据。

3.4 RUL 预测方法验优


为验证本文所提出 RUL 预测方法中 HI 序列分解重构效果和 SARIMA 模型的预测性能,以两种动态工况循环的电池为例,与不分解 HI 的 SARIMA 方法、使用 BEAST 分解 HI 的 LSTM^[29]和 LSSVM^[30]方法进行比较验优。几种预测方法下电池 CS2#7 和 RW17 的 RUL 预测结果如图 11 和表 7 所示。为方便比较各方法预测的精度,图 8 省略拟合模型所用的 HI,从预测起点开始绘制 HI 真实值与预测值。

从图 11 和表 7 可以看出,本文方法在预测精度和计算效率上均显著优于其余 3 种方法。下面结果对比分析均以电池 CS#7 为例,相较于单独 SARIMA 模型,本文方法平均绝对误差(E_{MA}^{HI})从 0.051 3 降至 0.036 1(降幅 29.6%),寿命终点绝对误差(E_A^{EOL})由 51 次循环大幅缩减至 4 次循环,运行时间仅增加 1.12 s,验证了 BEAST 时序分解对预测精度提升的关键作用。相较于 LSTM 和 LSSVM 方法,本文方法

E_{MA}^{HI} 分别降低了 16.6%和 25.9%;运行效率方面,本文 SARIMA 模型通过参数化建模取代了深度学习的复杂训练过程,单次预测耗时相较于 LSTM 和 LSSVM 分别提升 55.2%和 22.8%。综合来看,本文提出的电池 RUL 预测方法兼顾预测精度和计算效率优势,为电池管理系统(battery management system, BMS)应用提供了高可靠性、低计算成本的技术路径。



(a) 电池 CS2#7



(b) 电池 RW17

图 11 动态工况循环下电池 RUL 预测典型方法比较

Fig.11 Comparison of typical methods for battery RUL prediction under dynamic duty cycle

表 7 动态工况循环下电池的 RUL 预测误差与运行时间

Tab.7 RUL prediction error vs runtime for batteries under dynamic duty cycle

电池类型	预测方法	E_{MA}^{HI}	$E_A^{EOL}/\text{次}$	运行时间/s
CS2#7	单独 SARIMA	0.051 3	51	22.56
	本文方法	0.036 1	4	23.68
	BEAST + LSTM	0.043 3	11	52.84
	BEAST + SVM	0.048 7	13	30.65
RW17	单独 SARIMA	0.068 9	10	13.31
	本文方法	0.059 7	6	14.19
	BEAST + LSTM	0.067 3	9	39.08
	BEAST + LSSVM	0.063 4	8	23.56

4 结 论

本文提出了一种基于 HI、贝叶斯估计器分解与季节性差分自回归移动平均(HI-BEAST-SARIMA)的电池 RUL 预测方法,有效提升了电池衰退预测的精度与可靠性,主要结论如下。

(1) 通过融合动静态工况特征与多时间尺度退化信息,构建了多尺度 HI 体系,突破了传统单一容量指标存在的表征失真局限,有效改善了 HI 在复杂工况条件下动态适应性不足的缺陷,显著提升了电池 RUL 模型在复杂工况下的泛化性能。

(2) 将 HI 与 BEAST 方法结合,对电池 HI 序列进行分解,提取出趋势项和季节项,从而有效捕捉电池衰退过程中的长期趋势和短期周期性波动。与其他简单滤波方法不同,本文通过保留电池恢复过程中的有效信息,避免了对电池衰退状态的误判,提高了 RUL 预测的精度和鲁棒性。

(3) 引入 SARIMA 对电池 RUL 进行时序建模,不仅能在小样本数据情况下精准捕捉电池状态的变化趋势,还能适应电池在不同工况下的周期性变化,显著提高了电池 RUL 预测的精度。最后,计算出模型预测结果的 95%置信区间,量化了预测结果的可靠性。

(4) 经多工况验证,本文方法能够适应不同工况条件下锂电池的 RUL 预测需求,具有较高的预测精度和较强的泛化能力。具体而言,本文方法在电池衰减 5%时预测相对误差小于 2.00%,衰减 10%时小于 4.31%。以电池 CS#7 为例,相较于 LSTM 和 LSSVM 方法,本方法预测 E_{MA}^{HI} 仅为 0.036 1,在维持高精度的同时将计算时间缩短至 23.68 s,单次预测耗时分别提升 55.2%和 22.8%,实现了预测精度与计算效率的优化平衡。

参考文献:

- [1] Yao F, He W X, Wu Y X, et al. Remaining useful life prediction of lithium-ion batteries using a hybrid model[J]. *Energy*, 2022, 248: 123622.
- [2] 姚芳, 张楠, 黄凯. 锂离子电池状态估算与寿命预测综述[J]. *电源学报*, 2020, 18(3): 175-183.
Yao Fang, Zhang Nan, Huang Kai. Review of state estimation and life prediction for lithiumion batteries[J]. *Journal of Power Supply*, 2020, 18(3): 175-183(in Chinese).
- [3] Li M, Xu W T, Zhang S W, et al. State of health estimation and battery management: A review of health indicators, models and machine learning[J]. *Materials*, 2025, 18(1): 145-145.
- [4] Fei Z C, Yang F F, Tsui K L, et al. Early prediction of battery lifetime via a machine learning based framework[J]. *Energy*, 2021, 225: 120205.
- [5] 戴俊彦, 夏明超, 陈奇芳. 基于双重注意力机制的电池 SOH 估计和 RUL 预测编解码模型[J]. *电力系统自动化*, 2023, 47(6): 168-177.
- [6] Dai Junyan, Xia Mingchao, Chen Qifang. Encoding and decoding model of state of health estimation and remaining useful life prediction for batteries based on dual-stage attention mechanism[J]. *Automation of Electric Power Systems*, 2023, 47(6): 168-177(in Chinese).
- [7] Wu L F, Fu X H, Guan Y. Review of the remaining useful life prognostics of vehicle lithium-ion batteries using data-driven methodologies[J]. *Applied Sciences*, 2016, 6(6): 166.
- [8] Lui Y H, Li M, Downey A, et al. Physics-based prognostics of implantable-grade lithium-ion battery for remaining useful life prediction[J]. *Journal of Power Sources*, 2021, 485: 229327.
- [9] 戴海峰, 张艳伟, 魏学哲, 等. 锂离子电池剩余寿命预测研究[J]. *电源技术*, 2019, 43(12): 2029-2035.
Dai Haifeng, Zhang Yanwei, Wei Xuezhe, et al. Review of remaining useful life prediction for lithium ion battery[J]. *Chinese Journal of Power Sources*, 2019, 43(12): 2029-2035(in Chinese).
- [10] 范立明, 王崑声, 钱诚. 故障物理与粒子滤波融合的锂离子电池寿命预测方法[J]. *兵器装备工程学报*, 2020, 41(9): 171-175.
Fan Liming, Wang Kunsheng, Qian Cheng. Remaining useful life prediction of lithium battery based on physics of failure and particle filtering[J]. *Journal of Ordnance Equipment Engineering*, 2020, 41(9): 171-175(in Chinese).
- [11] 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 Zhengguo, Ji Shengchang. Review on health state estimation and life prediction of lithium-ion batteries[J]. *High Voltage Engineering*, 2024, 50(3): 1182-1195(in Chinese).
- [12] 孙冬, 许爽. 梯次利用锂离子电池健康状态预测[J]. *电工技术学报*, 2018, 33(9): 2121-2129.
Sun Dong, Xu Shuang. State of health prediction of second-use lithium-ion battery[J]. *Transactions of China Electrotechnical Society*, 2018, 33(9): 2121-2129(in Chinese).
- [13] Sultan A Y, Eladl A A, Hassan A M, et al. Enhancing electric vehicle battery lifespan: Integrating active balancing and machine learning for precise RUL estimation[J]. *Scientific Reports*, 2025, 15(1): 777.
- [14] Ahwiadi M, Wang W. Battery health monitoring and remaining useful life prediction techniques: A review of technologies[J]. *Batteries*, 2025, 11(1): 31.

- [14] Li L, Saldivar A A F, Bai Y, et al. Battery remaining useful life prediction with inheritance particle filtering[J]. *Energies*, 2019, 12(14): 2784.
- [15] 吴诗淼, 王文波, 朱 婷, 等. 基于跳跃连接多尺度 CNN 的锂离子电池剩余寿命预测[J]. *太阳能学报*, 2024, 45(7): 199-208.
Wu Shimiao, Wang Wenbo, Zhu Ting, et al. Prediction of residual life of lithium ion battery based on multi-scale CNN with jump connection[J]. *Acta Energetica Sinica*, 2024, 45(7): 199-208(in Chinese).
- [16] Chen Z W, Shi N, Ji Y F, et al. Lithium-ion batteries remaining useful life prediction based on BLS-RVM[J]. *Energy*, 2021, 234: 121269.
- [17] Chen L G H, Zhang Y, Zheng Y, et al. Remaining useful life prediction of lithium-ion battery with optimal input sequence selection and error compensation[J]. *Neurocomputing*, 2020, 414: 245-254.
- [18] Wang S L, Fernandez C, Cao W, et al. An adaptive working state iterative calculation method of the power battery by using the improved Kalman filtering algorithm and considering the relaxation effect[J]. *Journal of Power Sources*, 2019, 428: 67-75.
- [19] Pang X Q, Liu X Y, Jia J F, et al. A lithium-ion battery remaining useful life prediction method based on the incremental capacity analysis and Gaussian process regression[J]. *Microelectronics Reliability*, 2021, 127: 114405.
- [20] Liu L, Sun W, Yue C X, et al. Remaining useful life estimation of lithium-ion batteries based on small sample models[J]. *Energies*, 2024, 17(19): 4932.
- [21] 方斯頓, 刘龙真, 孔赖强. 基于双向长短期记忆网络含间接健康指标的锂电池 SOH 估计[J]. *电力系统自动化*, 2024, 48(4): 160-168.
Fang Sidun, Liu Longzhen, Kong Laiqiang. State-of-health estimation for lithium-ion batteries incorporating indirect health indicators based on bi-directional long short-term memory networks[J]. *Automation of Electric Power Systems*, 2024, 48(4): 160-168(in Chinese).
- [22] Saleem U, Liu W J, Riaz S, et al. TransRUL: A transformer-based multihead attention model for enhanced prediction of battery remaining useful life[J]. *Energies*, 2024, 17(16): 3976.
- [23] Xie Y X, Wang S L, Zhang G X, et al. A review of data-driven whole-life state of health prediction for lithium-ion batteries: Data preprocessing, aging characteristics, algorithms, and future challenges[J]. *Journal of Energy Chemistry*, 2024, 97: 630-649.
- [24] Alipour M, Ziebert C, Conte V F, et al. A review on temperature-dependent electrochemical properties, aging, and performance of lithium-ion cells[J]. *Batteries*, 2020, 6(3): 35.
- [25] Wang Z, Zhao Q J, Wang S J, et al. Aging and post-aging thermal safety of lithium-ion batteries under complex operating conditions: A comprehensive review[J]. *Journal of Power Sources*, 2024, 623: 235453.
- [26] Lyu R F, Pang J L, Zhang J M, et al. The impacts of disturbances on mountain ecosystem services: Insights from BEAST and Bayesian network[J]. *Applied Geography*, 2024, 162: 103143.
- [27] Hu Y F, Wang S L, Huang J H, et al. A novel seasonal autoregressive integrated moving average method for the accurate lithium-ion battery residual life prediction[J]. *International Journal of Electrochemical Science*, 2022, 17(5): 220555.
- [28] Zhang W Q, Lin Z, Liu X L. Short-term offshore wind power forecasting—A hybrid model based on discrete wavelet transform(DWT), seasonal autoregressive integrated moving average(SARIMA), and deep-learning-based long short-term memory(LSTM)[J]. *Renewable Energy*, 2022, 185: 611-628.
- [29] Sayah M, Guebli D, Al Masry Z, et al. Robustness testing framework for RUL prediction deep LSTM networks[J]. *ISA Transactions*, 2021, 113: 28-38.
- [30] Li X, Ma Y, Zhu J J. An online dual filters RUL prediction method of lithium-ion battery based on unscented particle filter and least squares support vector machine[J]. *Measurement*, 2021, 184: 109935.

(责任编辑: 孙立华)