

储能测试与评价



融合 REMD-NHITS 与 KDE 的锂离子电池健康状态退化预测

姬钰培¹, 吴康佳¹, 袁泽宇², 闫俊义¹, 崔方舒¹, 乔钢柱¹

(¹中北大学计算机科学与技术学院, 山西 太原 030051; ²中北大学极限环境光电动态测试技术与仪器全国重点实验室, 山西 太原 030051)

摘 要: 锂离子电池健康状态 (state of health, SOH) 的准确预测对于保障储能系统安全稳定运行具有重要意义。为突破现有锂离子电池 SOH 预测方法在精度上的局限, 提出一种融合鲁棒经验模态分解 (robust empirical mode decomposition, REMD)、时间序列神经层次插值 (neural hierarchical interpolation for time series, NHITS) 模型与核密度估计 (kernel density estimation, KDE) 的锂离子电池 SOH 退化预测模型。该方法从锂离子电池退化数据中提取可有效表征电池 SOH 退化规律的健康因子 (health indicator, HI), 采用 REMD 对 HI 实施自适应分解以获取多个分量; 在各分量上分别构建 NHITS 预测模型进行独立预测, 最终通过分量重构得到电池 SOH 点预测结果。在此基础上, 引入 KDE 对点预测误差分布进行概率建模, 建立 REMD-NHITS-KDE 区间预测框架, 实现 SOH 预测不确定性的量化表征与区间估计。以 CALCE 数据集电池和 NASA 数据集电池为实验对象, 实验结果表明所提方法在点预测任务中优于 NHITS、NBEATS 和 REMD-NBEATS 等模型, 平均绝对误差低至 0.0047, 决定系数提高至 99.98%; 在区间预测中兼顾了覆盖率与区间宽度, 表现出较好的可靠性与实用性。

关键词: 锂离子电池; 健康状态; NHITS 模型; 鲁棒经验模态分解; 核密度估计; 区间预测

doi: 10.19799/j.cnki.2095-4239.2026.0340

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (2026) 08-3324-17

Prediction of lithium-ion battery state of health degradation by integrating REMD-NHITS and KDE

Ji Yupei¹, Wu Kangjia¹, Yuan Zeyu², Yan Junyi¹, Cui Fangshu¹, Qiao Gangzhu¹

(¹School of Computer Science and Technology, North University of China, Taiyuan 030051, Shanxi, China;

²State Key Laboratory of Extreme Environment Optoelectronic Dynamic Measurement Technology and Instrument, North University of China, Taiyuan 030051, Shanxi, China)

Abstract: To overcome the accuracy limitations of existing state-of-health (SOH) prediction methods for lithium-ion batteries, a lithium-ion battery SOH degradation prediction model integrating robust empirical mode decomposition (REMD), neural hierarchical interpolation for time series (NHITS), and kernel density estimation (KDE) is proposed. The method extracts health indicators (HIs) that effectively represent SOH degradation from lithium-ion battery data and uses REMD to adaptively decompose these HIs into multiple components. NHITS models are constructed for independent prediction on each component, and SOH point predictions are obtained through component reconstruction. Based on this, KDE probabilistically models

收稿日期: 2026-04-17; 修改稿日期: 2026-06-19。

基金项目: 山西省基础研究计划 (202303021222084, 202303021222120)。

第一作者: 姬钰培 (2002—), 女, 硕士研究生, 研究方向为储能电池健康管理, E-mail: jyupeia@163.com; 通信作者: 乔钢柱, 教授, 研究方向为物联网技术及应用、大数据处理技术等, E-mail: qiaogz@nuc.edu.cn。

引用本文: 姬钰培, 吴康佳, 袁泽宇, 等. 融合 REMD-NHITS 与 KDE 的锂离子电池健康状态退化预测[J]. 储能科学与技术, 2026, 15(8): 3324-3340.

Citation: Ji Yupei, Wu Kangjia, Yuan Zeyu, et al. Prediction of lithium-ion battery state of health degradation by integrating REMD-NHITS and KDE[J]. Energy Storage Science and Technology, 2026, 15(8): 3324-3340.

the distribution of point prediction errors, establishing an REMD-NHITS-KDE interval-prediction framework that quantitatively characterizes and estimates SOH prediction uncertainty. Using batteries from the CALCE and NASA datasets, the experimental results show that the proposed method outperforms models such as NHITS, NBEATS, and REMD-NBEATS in point prediction, achieving a mean absolute error of 0.0047 and a coefficient of determination of 99.98%. In interval prediction, it considers coverage and interval width, demonstrating strong reliability and practicality.

Keywords: lithium-ion battery; state of health; NHITS model; robust empirical mode decomposition; kernel density estimation; interval prediction

随着环境污染与能源危机的日益加剧, 锂离子电池凭借其高能量密度、长循环寿命、低自放电率和环境友好等优点, 被广泛应用于电动汽车、大型储能系统、移动通信基站、航空等诸多领域^[1-3]。然而, 由于锂离子电池内部反应的复杂性和工作环境的多样性, 对其 SOH 的准确预测对避免安全事故的发生具有重要意义。

目前, 锂离子电池 SOH 估计包括基于机理模型^[4]与基于数据驱动的方法。基于机理模型法从电池内部材料出发, 依据电池的物理化学原理构建模型, 结构复杂且计算成本高^[5]。随着机器学习和深度学习的发展, 基于数据驱动的 SOH 估计方法因仅依赖电池性能退化数据、无需刻画内部复杂机理而得到广泛应用^[6-7]。目前常见的数据驱动方法有长短期记忆网络 (long short-term memory network, LSTM)、卷积神经网络 (convolutional neural networks, CNN)、门控循环单元网络 (gated recurrent unit, GRU) 等。这类模型虽能在一定程度上提升预测性能, 但存在结构复杂、参数量大、可解释性不足等问题, 制约了 SOH 估计精度的进一步提升^[8-10]。Oreshkin 等^[11-12]提出的神经基扩展分析 (neural basis expansion analysis, NBEATS) 模型通过神经网络块堆叠和基函数展开实现时间序列分解与重构, 具有较强的预测能力和一定的可解释性。然而, NBEATS 的采样机制与特征选择方式在处理兼具复杂周期性与趋势变化的序列时, 难以充分兼顾多尺度时序信息。为此, Oreshkin 等^[13]在 NBEATS 的基础上提出了时间序列神经层次插值模型 (neural hierarchical interpolation for time series, NHITS)。该模型通过引入分层插值机制和多速率信号采样策略, 在保留 NBEATS 可解释性优势的同时, 增强了对多尺度特征和复杂动态变化的表征能

力, 显著提高了模型的计算效率与预测性能。

此外, 在锂离子电池 SOH 预测研究中, 阻抗、容量等直接健康因子 (health indicator, HI) 难以直接获取, 因此研究者通常从充放电循环曲线中提取与 SOH 密切相关的间接 HI 作为表征特征^[14]。此类 HI 数据通常具有非线性特征, 若直接用于模型训练, 难以达到理想的预测效果。为提升预测性能, 研究者常采用经验模态分解 (empirical mode decomposition, EMD)^[15]、集合经验模态分解 (ensemble empirical mode decomposition, EEMD)^[16]、完全自适应噪声集合经验模态分解 (complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)^[17]等信号分解方法对原始序列进行分解, 并针对不同子序列分别建模预测。尽管上述方法已被证实具有一定有效性, 但仍具有局限性: EMD 在处理复杂电池老化信号时易出现端点效应与模态混叠问题; EEMD 虽通过叠加高斯白噪声抑制模态混叠, 但噪声残留问题无法根除, 分解后本征模态函数 (intrinsic mode function, IMF) 分量会引入残留噪声干扰; CEEMDAN 虽进一步改进了分解效果, 但其产生的 IMF 分量数量较多, 显著增加了模型训练的计算开销。针对上述不足, 本研究引入鲁棒经验模态分解 (robust empirical mode decomposition, REMD) 方法, REMD 重新设计筛分停止准则与极值包络拟合规则, 从算法底层抑制端点效应、弱化模态混叠, 以提高信号分解的鲁棒性和适用性。例如, 乔松博等^[18]用 REMD 将原始数据分解为多个 IMF, 并为每个 IMF 构建独立的混合神经网络进行训练, 有效提升了预测精度。

尽管基于信号分解与深度学习的方法能够有效提升锂离子电池 SOH 的点预测精度, 但点预测仅给出单一估计值, 难以表征预测结果的不确定性

其可信程度。相比之下,区间预测能够在给定置信水平下提供预测结果的上下界,从而更全面地刻画SOH退化过程中的不确定性。区间预测方法主要分为参数法和非参数法两大类^[19-20]。参数法需预先假定预测误差服从特定分布,但实际误差分布复杂,区间预测结果可靠性较低。非参数法无需预设分布假设,适用性更强,其主要包括蒙特卡洛模拟、分位数回归和核密度估计(kernel density estimation, KDE)等。KDE能够无需预设分布形式,直接基于预测误差样本估计其概率密度,更适用于SOH预测的不确定性量化。因此,如何在提高SOH点预测精度的同时,利用KDE方法实现对预测结果不确定性的量化,仍是当前研究亟待解决的问题^[21-22]。

综上,本研究提出一种融合REMD-NHITS与KDE的锂离子电池SOH预测模型及不确定性分析方法,首先从锂离子电池的退化数据中提取与SOH相关性较高的HI,采用REMD方法将其分解为多个子序列,分别构建子序列的NHITS模型进行预测,并将预测结果进行累加重构获得电池SOH的点预测值。在此基础上,利用KDE对预测误差的概率密度分布进行非参数估计,依据给定的置信水平构建预测区间,实现对锂离子电池SOH预测结果的不确定性量化。最后,通过CALCE和NASA数据集上的实验验证所提方法在点预测精度和区间预测方面均具有较好的有效性。

1 实验数据及特征提取

1.1 数据集介绍

本实验选取马里兰大学先进生命周期工程中心(Center for Advanced Life Cycle Engineering, CALCE)和美国航空航天局(National Aeronautics and Space Administration, NASA)的锂离子电池数据集作为研究对象,型号分别为CS2_35、CS2_36、CS2_37和B06、B07。其中CALCE数据集中电池的标称容量为1.1 Ah,充电以1.5 A的恒定电流进行;NASA数据集中电池的标称容量为2 Ah,同样以1.5 A的恒定电流进行充电。其容量衰退曲线如图1所示。

锂离子电池SOH是表征电池老化程度的关键参数,通常定义为电池当前最大可用容量与初始额定容量的比值。其数学表达式为




图1 不同型号电池容量衰退曲线: (a) CALCE电池容量衰退曲线; (b) NASA电池容量衰退曲线

Fig. 1 Capacity fade curves of different battery models: (a) CALCE battery capacity fade curve; (b) NASA battery capacity fade curve

$$\text{SOH} = \frac{C_{\text{aged}}}{C_{\text{rated}}} \times 100\% \quad (1)$$

式中, C_{aged} 和 C_{rated} 分别表示锂电池当前实际可用容量和出厂额定容量。

1.2 特征提取

容量虽可直接反映电池老化程度,但在实际应用中难以直接测量。因此,研究者通常从锂离子电池充放电循环过程中提取与电池退化密切相关的间接HI,以表征其健康状态。以CS2_35电池为例,其单次循环中的充放电曲线如图2所示,完整循环由恒流充电、恒压充电和恒流放电3个阶段构成。图3表明,随着循环次数的增加,电池充放电持续时间呈逐渐缩短趋势。据此,从CALCE的充电和放电过程中提取恒流充电时间(constant current




图 2 CS2_35 单次循环充放电电压曲线

Fig. 2 Voltage curve of single cycle charge and discharge of CS2_35





图 3 CS2_35 不同周期充放电电压曲线


Fig. 3 Voltage curves of CS2_35 at different charge and discharge cycles

charging time, CCCT)、恒压充电时间 (constant voltage charging time, CVCT)、恒流放电时间 (constant current discharging time, CCDT) 和充电等压升时间 (charging isobaric rise time, CIRT) 作为健康指标。


以 B06 电池为例, 其充放电过程中的电压、电流和温度曲线如图 4 所示。由图中曲线特征可知, 随着循环次数增加, 放电过程中相同电压区间对应的持续时间逐渐缩短, 提取 3.5~4.0 V 区间的放电等压降时间 (discharging isobaric drop time, DIDD)、整个放电循环的平均电压 (discharging cycle average voltage, DCAV) 定义为健康指标; 在温度变化方面, 放电过程中温度随时间升高, 且温度达到峰值所需时间逐渐减小, 据此提取放电过程温度达到峰值的时间 (discharging peak temperature



(a)



(b)



(c)

图 4 B06 充放电过程中的电流、电压、温度曲线: (a) 不同周期的放电电流曲线; (b) 不同周期的放电电压曲线; (c) 不同周期的放电温度曲线

Fig. 4 Current, voltage and temperature curves during the charge and discharge process of B06: (a) Discharge current curves of different cycles; (b) Discharge voltage curves of different cycles; (c) Discharge temperature curves of different cycles

time, DPTT) 和放电过程最大温度 (maximum temperature during discharge, MTDD)。

1.3 相关性分析

图5为上述CS2_35号和B06号电池的4种HI和SOH的对比曲线。由图可知,与其他3个HI相比,CCDT和DPTT更符合锂离子电池SOH退化过程。




图5 CS2_35和B06的HI和SOH趋势图: (a) CS2_35; (b) B06

Fig. 5 Trends of HI and SOH of CS2_35 and B06: (a) CS2_35; (b) B06

利用Pearson及Spearman相关系数来验证所提取的健康因子的合理性,分析结果如表1、表2所示。Pearson和Spearman的计算公式分别如下:

$$\text{Pearson} = \frac{E(\alpha\beta) - E(\alpha)E(\beta)}{\sqrt{E(\alpha^2) - [E(\alpha)]^2} \sqrt{E(\beta^2) - [E(\beta)]^2}} \quad (2)$$

$$\text{Spearman} = \frac{\sum_i (\alpha_i - \bar{\alpha})(\beta_i - \bar{\beta})}{\sqrt{\sum_i (\alpha_i - \bar{\alpha})^2} \sqrt{\sum_i (\beta_i - \bar{\beta})^2}} \quad (3)$$

式中, α 和 β 分别表示HI和SOH值。

当Pearson、Spearman相关系数的取值范围在0.8~1.0之间时,表明两个变量之间存在极强的相关性。由表1、表2分析可见,CCDT和DPTT

与SOH的相关性相较于其他HI更接近1,因此它们可分别用于表征CALCE和NASA数据集中电池样本的SOH,以便于后续的退化预测研究。

表1 CALCE电池HI与SOH的相关性系数

Table 1 Correlation coefficient between HI and SOH of CALCE battery

HI	CS2_35		CS2_36		CS2_37	
	Pearson	Spearman	Pearson	Spearman	Pearson	Spearman
CCCT	0.9959	0.9921	0.9977	0.9974	0.9973	0.9957
CVCT	-0.8587	-0.9389	-0.7383	-0.8745	-0.8663	-0.9460
CCDT	0.9937	0.9953	0.9990	0.9989	0.9988	0.9986
CIRT	0.9925	0.9931	0.9907	0.9969	0.9939	0.9937

表2 NASA电池HI与SOH的相关性系数

Table 2 Correlation coefficient between HI and SOH of NASA battery

HI	B06		B07	
	Pearson	Spearman	Pearson	Spearman
DIDT	0.9939	0.9992	0.9980	0.9935
DCAV	0.9652	0.9507	0.9611	0.9407
DPTT	0.9999	0.9998	0.9992	0.9986
MTDD	-0.8504	-0.8185	-0.7495	-0.7087

2 理论方法

2.1 鲁棒经验模态分解

EMD作为一种自适应信号分解方法,处理非线性、非平稳信号时具有优势,但易受端点效应和模态混叠的困扰,进而制约分解结果的鲁棒性与准确性。REMD方法通过改进筛分停止准则,能够抑制端点效应带来的信号失真,缓解模态混叠现象,提高信号分解的稳定性与合理性,更适用于复杂非平稳信号的处理场景^[17]。

REMD的筛分停止准则为使 $f(k)$ 尽可能小。

$$\text{RMS}_{j,k} = \sqrt{\frac{1}{N_s} \sum_{n=1}^{N_s} m_{j,k}^2[n]} \quad (4)$$

$$\text{EK}_{j,k} = \frac{\frac{1}{N_s} \sum_{n=1}^{N_s} (m_{j,k}[n] - \bar{m}_{j,k})^4}{\left[\frac{1}{N_s} \sum_{n=1}^{N_s} (m_{j,k}[n] - \bar{m}_{j,k})^2 \right]^2} - 3 \quad (5)$$

$$f_j(k) = \text{RMS}_{j,k} + |\text{EK}_{j,k}| \quad (6)$$

式中, n 为样本点索引, N_s 为样本总数; $m_{j,k}[n]$ 为第 k 次筛分所得的均值包络序列, $\bar{m}_{j,k}$ 为 $m_{j,k}[n]$ 的样本均值, $\text{RMS}_{j,k}$ 为 $m_{j,k}[n]$ 的均方根, $\text{EK}_{j,k}$ 为包络均值序列的超额峰值值。

REMD 停止条件判断：

(1) IMF 条件：零点数与极值点相等或相差不能超过 1。

(2) 目标函数趋势：满足 $f(k-2) < f(k-1)$ 且 $f(k-1) < f(k)$ 。

若满足上述条件，停止筛分并输出第 $k-2$ 个分解结果。如果不满足上述条件，继续进行分解，直至达到最大迭代次数 $l_{\max}$ 。

REMD 分解的步骤如下：为待分解的原始 HI 数据，令初始残差为 $r_0[n] = x[n]$ 。其中， $j = 1, 2, \dots, J$ 表示 IMF 分量序号， $k = 1, 2, \dots, l_{\max}$ 表示提取当前分量时的筛分次数。

(1) 初始化当前筛分序列。提取第 j 个 IMF 时，令

$$h_{j,0}[n] = r_{j-1}[n] \quad (7)$$

(2) 构造上下包络及均值包络。识别 $h_{j,k-1}[n]$ 的所有局部极大值点和局部极小值点，并采用三次样条插值分别构造上包络 $u_{j,k}[n]$ 和下包络 $l_{j,k}[n]$ 。均值包络为

$$m_{j,k}[n] = \frac{u_{j,k}[n] + l_{j,k}[n]}{2} \quad (8)$$

(3) 计算软筛分目标函数。根据式 (4) 至式 (6)，由均值包络 $m_{j,k}[n]$ 计算 $RMS_{j,k}$ ， $EK_{j,k}$ ， $f_j(k)$ 。

(4) 更新候选分量。从当前筛分序列中减去均值包络，得到第 k 次筛分后的候选分量：

$$h_{j,k}[n] = h_{j,k-1}[n] - m_{j,k}[n] \quad (9)$$

(5) 根据 REMD 停止条件判断是否停止当前筛分。若满足，将第 $k-2$ 次筛分结果确定为第 j 个 IMF。

$$R_{IMF_j}[n] = h_{j,k-2}[n] \quad (10)$$

若尚未满足停止条件且 $k < l_{\max}$ ，则令 $k \leftarrow k + 1$ ，重复步骤 (2) 至步骤 (5)。若达到最大筛分次数 $l_{\max}$ 后仍未满足上述趋势条件，则强制停止筛分，并取

$$R_{IMF_j}[n] = h_{j,l_{\max}}[n] \quad (11)$$

(6) 更新残差并判断是否继续分解。提取第 j 个 IMF 后，更新残差

$$r_j[n] = x[n] - \sum_{i=1}^j R_{IMF_i}[n] \quad (12)$$

若 $r_j[n]$ 仍包含不少于两个极值点且不是单调序列，则令 $j \leftarrow j + 1$ ，并将 $r_j[n]$ 作为下一轮分解的输入，继续提取新的 IMF。当残差已经成为单调

序列，或无法继续构造有效的上下包络时，终止整个分解过程。设最终提取的 IMF 总数为 J ，则最终残差为

$$RS[n] = r_J[n] \quad (13)$$

最终，原始 HI 数据可表示为

$$x[n] = \sum_{j=1}^J R_{IMF_j}[n] + R_{RS}[n] \quad (14)$$

2.2 NHITS 网络模型

NHITS 模型是 NBEATS 模型的泛化和扩展，其整体架构与 NBEATS 相似，区别在于块的组成：NHITS 以多层感知器 (multi-layer perceptron, MLP) 替代全连接结构，并引入池化层实现下采样，从而增强多尺度特征表征能力。该结构使模型能够分层建模时间序列，在提高预测精度的同时提升计算效率，其网络架构如图 6 所示。

第一部分为池化层。使用下采样将数据序列采样为不同的粒度。通过设置池化核 K 的大小，使 MLP 专注不同尺度的信息。其数学表达式为

$$y_{t-L:t}^{(p)} = \text{MaxPool}(y_{t-L:t}, k_t) \quad (15)$$

式中， $y_{t-L:t}$ 表示第 ℓ 个神经网络模块的输入； k_t 表示池化窗口的大小； $y_{t-L:t}^{(p)}$ 表示池化后得到的序列。

第二部分由具有激活函数的多层感知器层和简单的线性层组成。多层感知器的表达式为

$$h_t = \text{MLP}(y_{t-L:t}^{(p)}) \quad (16)$$

式中， h_t 表示第 ℓ 个神经网络模块输出的隐藏向量。

线性层的计算公式为

$$\theta_t^b = W_t^b h_t \quad (17)$$

$$\theta_t^f = W_t^f h_t \quad (18)$$

式中， θ_t^b 表示第 ℓ 个神经网络模块中用于预测 $\hat{y}_{t-L:t}$ 线性层的插值系数； θ_t^f 表示预测 $\hat{y}_{t+L:t}$ 线性层的插值系数； W_t^b 表示预测 $\hat{x}_t$ 线性层的权重； W_t^f 表示预测 $\hat{y}_t$ 线性层的权重。

第三部分由插值层和残差连接层组成，是 NHITS 模型中生成回溯序列与预测序列的关键模块。该模型引入了分段线性插值函数。该函数的表达式为

$$g(\tau) = \theta[t_1] + \left(\frac{\theta[t_2] - \theta[t_1]}{t_2 - t_1} \right) (\tau - t_1) \quad (19)$$

式中， $\theta[t_1]$ 和 $\theta[t_2]$ 表示相邻的控制点； t_1 和 t_2 表示插值点对应的横轴坐标； τ 为插值点。

插值层的计算公式为




图6 NHITS网络结构图

Fig. 6 Network structure diagram of NHITS

$$\hat{y}_{t-L:t,\ell}^{(b)} = g_b(\theta_t^{(b)}) \quad (20)$$

$$\hat{y}_{t+1:t+H,\ell}^{(f)} = g_f(\theta_t^{(f)}) \quad (21)$$

式中, $\hat{y}_{t-L:t,\ell}^{(b)}$ 表示第 ℓ 个神经网络模块的回溯序列; $\hat{y}_{t+1:t+H,\ell}^{(f)}$ 表示第 ℓ 个神经网络模块的预测序列; $g(r)$ 为插值函数。

回溯序列 $\hat{y}_{t-L:t,\ell}^{(b)}$ 用于解释输入的某一部分时间序列结构, 随后通过残差更新的方式传递给下一层块:

$$y_{t-L:t,\ell+1} = y_{t-L:t,\ell} - \hat{y}_{t-L:t,\ell}^{(b)} \quad (22)$$

式中, $y_{t-L:t,\ell+1}$ 表示第 $\ell+1$ 个神经网络模块的输入。

每个块的预测部分输出 $\hat{y}_{t+1:t+H,\ell}^{(f)}$ 将被累计加和到所在栈的预测输出中, 通过最终的预测加和结果得到该栈的残差。

$$\hat{y}_{t+1:t+H,S}^{(f)} = \sum_{\ell=1}^B \hat{y}_{t+1:t+H,\ell}^{(f)} \quad (23)$$

式中, B 表示每个栈中神经网络模块的数量; $\hat{y}_{t+1:t+H,S}^{(f)}$ 表示该栈的输出序列。

最后, 将所有栈的结果再相加即可得到最终预测。

$$\hat{y}_{t+1:t+H} = \sum_{s=1}^S \hat{y}_{t+1:t+H,S}^{(f)} \quad (24)$$

式中, S 表示栈的数量; $\hat{y}_{t+1:t+H}$ 为最终的预测序列。

2.3 基于核密度估计的区间预测模型

2.3.1 核密度估计

单一的点预测无法反映预测结果的可信程度, 为衡量预测结果的不确定性, 使用 KDE 估计误差的分布。KDE 无需对数据分布进行先验假设, 直接从数据样本出发, 估算概率密度函数, 继而通过概率密度找到总体分布特征。首先建立预测误差的样本集 $\{e_i\}$, $e_i = M_i - \hat{M}_i$, M_i 为真实值, $\hat{M}_i$ 为预测值。训练集预测误差的概率密度函数为

$$f(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - e_i}{h}\right) \quad (25)$$

式中, n 为样本数; h 为窗口宽度; $K(u)$ 为核函数; e_i 为预测误差值。

核函数和窗口宽度是 2 个关键参数。高斯核函数具有良好的鲁棒性和抗噪声干扰能力, 本实验采用该核函数, 其数学表达式如下:

$$K(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) \quad (26)$$

窗口宽度则使用 Silverman 准则, 其数学表达式如下:

$$h = 1.06\sigma_e n^{-\frac{1}{5}} \quad (27)$$

式中, σ_e 表示 $\{e_i\}$ 的标准差。

2.3.2 置信区间计算方法

在通过核密度估计得出预测误差的概率密度函

数后，便可以通过积分得到累积分布函数：

$$F(x) = \int f(x) dx \quad (28)$$

根据累积分布函数，在给定的置信水平 $1 - \alpha$ 下，有

$$P(e_{\text{low}} \leq e \leq e_{\text{up}}) = F(e_{\text{up}}) - F(e_{\text{low}}) = 1 - \alpha \quad (29)$$

式中， α 为显著性水平； e_{up} 、 e_{low} 分别为在置信水平 $1 - \alpha$ 下误差的上界和下界。

通过分析累积分布函数的曲线，能够在给定的置信水平下确定误差的上限和下限：

$$F(e_{\text{up}}) = 1 - \frac{\alpha}{2} \quad (30)$$

$$F(e_{\text{low}}) = \frac{\alpha}{2} \quad (31)$$

结合点预测结果，即可实现对锂离子电池 SOH 的区间预测：

$$P_{\text{low}} = P + e_{\text{low}} \quad (32)$$

$$P_{\text{up}} = P + e_{\text{up}} \quad (33)$$

式中， P_{up} 和 P_{low} 分别为在给定置信水平下预测的上界和下界； P 为点预测值。

2.4 REMD-NHITS-KDE 预测模型搭建

为实现锂离子电池 SOH 的高精度预测及不确定性量化，本研究提出一种融合 REMD-NHITS 与 KDE 的联合预测模型。为缓解复杂退化信号的波动性，该模型利用 REMD 对表征 SOH 的原始 HI 数据

进行自适应分解，提取多尺度特征；随后采用 NHITS 对 REMD 分解后的各分量进行建模预测，进一步增强模型对复杂时序特征的表征能力并提高点预测精度。然而，点预测只能提供单一预测值，难以表征预测结果的不确定性，因此运用 KDE 对点预测误差进行概率密度估计，构建给定置信水平下的预测区间，从而实现从点预测到区间预测的扩展。REMD-NHITS-KDE 预测模型整体流程如图 7 所示，具体步骤如下：

(1) 特征提取与筛选：对 CALCE 与 NASA 锂离子电池数据集分别进行特征提取，并筛选出与 SOH 相关性最强的间接 HI 表征锂离子电池的 SOH。

(2) REMD 分解：采用 REMD 对筛选后的 HI 序列进行自适应分解，将复杂原始序列分解为 K 个不同尺度的子序列，并对每个 IMF 分量分别建模预测。

(3) NHITS 点预测建模：将各 IMF 分量作为独立子序列，分别构建 NHITS 预测模型。对各子序列的预测结果进行累加重构，得到锂离子电池 SOH 的最终点预测值。

(4) KDE 不确定性区间构建：基于点预测误差构建误差样本集，采用高斯核函数与 Silverman 准则确定窗口宽度，利用 KDE 拟合误差的概率密




图 7 REMD-NHITS-KDE 模型整体架构图

Fig. 7 Overall architecture diagram of the REMD-NHITS-KDE model

度函数, 计算累积分布函数。在给定置信水平下, 通过误差上下界与点预测值的叠加, 构建 SOH 的预测区间, 实现对预测结果不确定性的量化表征。

3 实验结果分析

3.1 模型评估指标

为评估所提出的点预测模型的合理性和有效性, 本研究采用平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 和决定系数 (coefficient of determination, R^2) 作为预测模型的性能指标。MAE 和 RMSE 越小, 预测越准确; R^2 越接近 1, 表明模型的拟合程度越好。

各指标计算公式分别为

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (34)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (35)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (36)$$

式中, n 表示样本数量; y_i 表示第 i 个样本的实际值; $\hat{y}_i$ 表示第 i 个样本的预测值; $\bar{y}$ 为样本实际值的均值。

为评估预测区间的质量, 需同时考虑其覆盖性能与区间宽度。为此, 本研究选取预测区间覆盖率 (prediction interval coverage probability, PICP) 和预测区间归一化平均宽度 (prediction interval normalized average width, PINAW) 作为评价指标。PICP 用于衡量预测区间在给定置信水平下对真实值的覆盖能力, PINAW 用于反映预测区间的宽度, 二者能够从可靠性和精度两个方面综合评价预测区间预测性能。PICP 的计算公式如下:

$$PICP = \frac{1}{N} \sum_{i=1}^N C_i \quad (37)$$

式中, N 表示预测样本数; C_i 表示实际值是否位于区间内的布尔参数, $C_i = 0$ 表示第 i 个预测值的真实值位于预测区间之外, 反之, $C_i = 1$ 。PICP 值越大, 表明预测区间的覆盖性能越好。

然而, PICP 仅能反映区间对真实值的覆盖情况, 无法表征区间宽度。当预测区间较宽时, 即使 PICP 较高, 也难以以为调度或决策过程提供有效参

考。因此, 在 PICP 的基础上, 进一步引入 PINAW 评价区间预测精度。其计算公式为

$$PINAW = \frac{1}{NR} \sum_{i=1}^N (U_i - L_i) \quad (38)$$

式中, N 表示预测样本数; R 表示实际值的变化范围; U_i 、 L_i 表示预测区间的上下边界。PINAW 值越小, 表明预测区间越紧凑, 预测精度越高。

3.2 REMD 分解

为提高锂离子电池 SOH 预测精度, 首先采用 REMD 对所选 HI 序列进行分解。REMD 在保留 EMD 自适应分解特性的基础上, 能够有效缓解端点效应和模态混叠问题, 从而将原始 HI 序列分解为若干不同频率特征 IMF 分量, 实现对复杂退化信息的多尺度表征。

REMD 分解效果主要由最大筛分迭代次数与筛分停止准则阈值两个核心参数决定。结合锂离子电池 HI 非线性、低噪声的信号特点, 若迭代次数过低, 信号筛分不充分, 易出现模态混叠; 迭代次数过高则会造成过筛分, 破坏电池固有退化特征并增加计算量。筛分阈值取值过大会导致筛分提前终止, 特征提取不完整; 取值过小易引发数值振荡, 加剧端点效应。以 CALCE 中 CS2_35 电池和 NASA 中 B06 电池为例, 分析最大筛分迭代次数与筛分停止准则阈值对 REMD-NHITS 预测结果中 RMSE 的影响, 实验结果如表 3 所示。

表 3 分解方法参数对比

Table 3 Comparison of decomposition method parameters

数据集名称	参数名称	参数值	RMSE
CS2_35	最大筛分迭代次数	20	0.0208
		30	0.0116
		40	0.0234
	筛分停止准则阈值	0.005	0.0135
		0.01	0.0116
		0.015	0.0121
B06	最大筛分迭代次数	20	0.0136
		30	0.0121
		40	0.0234
	筛分停止准则阈值	0.005	0.0129
		0.01	0.0121
		0.015	0.0135

由表 3 可知, 当最大筛分迭代次数与筛分停止准则阈值分别为 30 和 0.01 时, REMD-NHITS 的预测效果均优于其他方案, 因此选择该组参数作为最

终参数, 以保障在所有电池样本中的分解质量。CS2_35 和 B06 电池表征 SOH 的 HI 经 REMD 分解后的结果如图 8 所示。




图 8 HI 分解图: (a) CS2_35; (b) B06
Fig. 8 Decomposition diagram of HI: (a) CS2_35;
(b) B06

3.3 点预测及结果分析

3.3.1 NHITS 模型参数设置

NHITS 模型的 Stack、Block 数量影响时序多尺度特征提取与残差修正能力, 池化核控制长短时序信息捕捉, MLP 结构决定非线性拟合效果, 参数过大易引发过拟合、提升训练开销。考虑模型对超参数依赖性强, 采用控制变量法对关键参数进行敏感性分析。以 CALCE 中 CS2_35 电池未分解的原始数据为例, 分析 Block 数量、MLP 单元、学习率对 RMSE 的影响, 结果如图 9 所示。

由图 9 可知, MLP 单元不足时, 模型多尺度时序特征提取与非线性拟合能力受限, 退化信息挖掘不充分, 预测误差偏高; 而 Block 数量和 MLP 单元取值过高时, 网络参数量冗余, 训练易拟合样本噪声从而引发过拟合, 泛化性能下降。学习率偏大时损失振荡难收敛, 偏小时损失易陷入局部最优。综上, 模型具体网络参数如表 4 所示。




图 9 关键参数对预测误差的影响分析: (a) Block 数量;
(b) MLP 单元; (c) 学习率

Fig. 9 Analysis of the impact of key parameters on prediction error: (a) Number of Blocks; (b) MLP units; (c) Learning rate

3.3.2 结果分析

为验证本研究所提出的 REMD-NHITS 模型在锂离子电池 SOH 确定性预测中的有效性, 选取 NBEATS、REMD-NBEATS、NHITS 模型作为对比模型。以 CALCE 数据集的 CS2_35、CS2_36、

表4 模型参数设置

Table 4 Model parameter settings

参数名称	参数值
Stack 数量	3
Block 数量	[1, 1, 1]
输入序列长度	10
激活函数	ReLU
MLP 单元	3×[256, 256]
池化窗口大小	[2, 2, 1]
学习率	0.001

CS2_37 和 NASA 数据集的 B06、B07 共 5 种电池的前 60% 循环周期数据作为训练集，其余数据作为模型的测试集用于 SOH 的点预测。各模型的 SOH 预测曲线与评价指标分别如图 10 和表 5 所示。

由图 10 可知，在相同条件下，REMD-NHITS 模型的预测曲线最贴近真实 SOH 退化轨迹，整体预测性能优于其他模型。其中，对比单一 NHITS 与单一 NBEATS 模型的预测曲线可知，NHITS 预测曲线比 NBEATS 预测曲线更贴近真实值，表明基于 NBEATS 架构改进的 NHITS 模型具备更强的时序特征提取能力，可有效提升 SOH 预测性能。在引入 REMD 分解后，REMD-NBEATS 与 REMD-

NHITS 的预测曲线均更贴合真实退化趋势，说明 REMD 可有效降低原始数据的波动性与随机性对模型的影响，从而提升预测准确度。

由表 5 中的模型性能评价指标对比结果可以看出，本研究所提出的 REMD-NHITS 模型具有更优越的预测性能：5 种电池的 R^2 均维持在 98% 以上，且 CS2_37 型号电池的 R^2 高达 99.88%；同时模型最大 MAE、RMSE 分别仅为 0.0082 和 0.0121。加入 REMD 分解后 NBEATS、NHITS 在 3 个指标方面均有提升，验证了 REMD 分解的可行性。在 CALCE 数据集的 CS2_37 电池中，REMD-NHITS 模型的 MAE 为 0.0047，RMSE 为 0.0072， R^2 为 99.88%；相较于预测效果最差的 NBEATS 模型，本研究所提方法的 MAE 和 RMSE 分别优化了 47.78% 和 43.31%；与单一 NHITS 模型相比，上述指标分别优化了 17.54% 和 25.00%。在 NASA 数据集的 B06 电池中，本研究所提模型同样取得了最优预测，其 MAE 为 0.0082，RMSE 为 0.0121， R^2 为 98.20%；相较于单一 NBEATS 模型，MAE、RMSE 优化幅度分别达到 46.75%、33.52%；与未加入 REMD 分解的 NHITS 模型相比，上述指标分别实现了 30.51%、17.69% 的优化。综上，将




图 10 不同型号电池模型预测曲线对比图: (a) CS2_35; (b) CS2_36; (c) CS2_37; (d) B06; (e) B07
Fig. 10 Comparison chart of prediction curves for different battery models: (a) CS2_35; (b) CS2_36; (c) CS2_37; (d) B06; (e) B07

表 5 点预测评价指标				
Table 5 Evaluation indicators for point prediction				
电池型号	预测方法	MAE	RMSE	$R^2/\%$
CS2_35	NBEATS	0.0068	0.01426	99.60
	NHITS	0.0061	0.0136	99.64
	REMD-NBEATS	0.0061	0.0130	99.67
	REMD-NHITS	0.0055	0.0116	99.74
CS2_36	NBEATS	0.0087	0.0121	99.71
	NHITS	0.0066	0.0104	99.78
	REMD-NBEATS	0.0057	0.0100	99.80
	REMD-NHITS	0.0058	0.0090	99.84
CS2_37	NBEATS	0.0090	0.0127	99.61
	NHITS	0.0057	0.0096	99.77
	REMD-NBEATS	0.0051	0.0085	99.82
	REMD-NHITS	0.0047	0.0072	99.88
B06	NBEATS	0.0154	0.0182	95.90
	NHITS	0.0118	0.0147	97.34
	REMD-NBEATS	0.0106	0.0139	97.62
	REMD-NHITS	0.0082	0.0121	98.20
B07	NBEATS	0.0115	0.0169	97.01
	NHITS	0.0101	0.0163	97.21
	REMD-NHITS	0.0073	0.0107	98.79

REMD 分解与 NHITS 模型进行融合，充分发挥了信号分解与深度时序建模的优势，有效提升了预测精度。此外，所提模型在 CALCE 和 NASA 两个数据集上均取得了稳定优化，表明该模型具有良好的泛化能力和鲁棒性。

尽管 REMD-NHITS 模型在锂离子电池 SOH 点预测精度上表现优异，但需指出的是，模型的计算复杂度与推理效率在实际应用中需加以考量。单一 NHITS 模型的时间复杂度主要源于 MLP 与前向传播过程，引入 REMD 分解后，原始 HI 序列被分解为多个 IMF 分量，需对各分量分别构建 NHITS 模型进行训练与预测，时间代价相应增加。以 B06 电池为例，单一 NHITS 模型训练时长为 40 s 左右，REMD-NHITS 的训练时间约为单一 NHITS 模型的 3.9 倍。尽管计算成本有所上升，但 MAE 和 RMSE 分别优化了 30.51%、17.69%。未来的研究将探索轻量化分解策略或并行训练机制，以降低计算开销，满足储能系统对实时性的更高要求。

3.4 对比实验

3.4.1 与不同信号处理方法对比

为进一步验证 REMD 在锂离子电池退化信号处理

中的优势，分别以 CALCE 数据集中 CS2_35 号电池与 NASA 数据集中 B06 号电池为例，将本研究所提出的 REMD-NHITS 方法与 EMD-NHITS 和 EEMD-NHITS 进行对比分析，实验结果如图 11 和表 6 所示。




图 11 不同信号处理方法结果对比图：(a) CS2_35；(b) B06

Fig. 11 Comparison chart of results from different signal processing methods : (a) CS2_35; (b) B06

表 6 不同信号处理方法结果对比

Table 6 Comparison of results from different signal processing methods

电池型号	预测方法	MAE	RMSE	$R^2/\%$
CS2_35	EMD-NHITS	0.0058	0.0134	99.64
	EEMD-NHITS	0.0058	0.0125	99.69
	REMD-NHITS	0.0055	0.0116	99.74
B06	EMD-NHITS	0.0105	0.0135	97.71
	EEMD-NHITS	0.0087	0.0129	97.93
	REMD-NHITS	0.0082	0.0121	98.20

由图 11 和表 6 可知，在相同实验条件和模型下，引入 REMD 分解后的 NHITS 模型预测性能均

优于 EMD-NHITS 和 EEMD-NHITS, 说明 REMD 能够更有效地提取锂离子电池退化信号中的多尺度特征。以 CS2_35 电池为例, 本研究所提 REMD-NHITS 的预测曲线在各退化阶段均与真实值高度贴合, 其 MAE、RMSE 和 R^2 分别为 0.0055、0.0116 和 99.74%。与 EMD-NHITS 相比, REMD-NHITS 的 MAE 和 RMSE 分别降低了 5.17% 和 13.43%, R^2 提高了 0.10 个百分点; 与 EEMD-NHITS 相比, 其 MAE 和 RMSE 分别降低了 5.17% 和 7.20%, R^2 提高了 0.05 个百分点。在 NASA 数据集的 B06 电池中, REMD-NHITS 同样取得了最优预测结果, 其预测曲线相较于 EMD-NHITS 和 EEMD-NHITS 更贴合真实容量衰减轨迹。该模型的 MAE 和 RMSE 较 EMD-NHITS 分别降低了 21.90% 和 10.37%, R^2 提高了 0.49 个百分点; 与 EEMD-NHITS 相比, 上述指标分别降低了 5.75% 和 6.20%, R^2 提高了 0.27 个百分点。综上, REMD-NHITS 在不同数据集上均表现出更低的预测误差和更高的拟合精度, 进一步验证了本研究引入 REMD 进行锂离子电池退化信号分解的有效性。

3.4.2 与主流时序预测模型对比

为进一步验证本研究所提出的 REMD-NHITS 模型的有效性, 分别以 CALCE 数据集中 CS2_35 号电池与 NASA 数据集中 B06 号电池为例, 在相同的初始条件下, 将本研究所提方法的预测结果分别与 LSTM、GRU、TCN 等主流时序预测模型的预测结果进行比较, 结果如图 12 和表 7 所示。

由图 12 可知, LSTM 的预测曲线在后期与真实 SOH 曲线偏离明显; GRU 和 TCN 的拟合效果虽有所提升, 但在局部退化拐点处仍存在偏差; 而本研究提出的 REMD-NHITS 模型的预测曲线最贴合真实 SOH 退化轨迹。量化指标方面, 在 CS2_35 电池中, REMD-NHITS 模型的 MAE、RMSE、 R^2 分别为 0.0055、0.0116、99.74%, 相较于 LSTM、GRU、TCN, MAE 分别降低了 84.15%、77.55%、72.50%, RMSE 分别降低了 75.63%、69.87%、52.46%, R^2 分别提升 5.58、2.63、1.00 个百分点。在 B06 电池中, MAE、RMSE、 R^2 分别达到 0.0082、0.0121、98.20%, 各项指标均显著优于 3 种对比模型。综合表明, REMD-NHITS 模型具备更高的预测精度, 验证了所提方法的优越性。




图 12 与主流时序预测模型结果对比图: (a) CS2_35; (b) B06

Fig. 12 Comparison chart of mainstream time series prediction model results: (a) CS2_35; (b) B06

表 7 与主流时序预测模型结果对比

Table 7 Comparison with mainstream time series prediction model results

电池型号	预测方法	MAE	RMSE	$R^2/\%$
CS2_35	LSTM	0.0347	0.0476	94.16
	GRU	0.0245	0.0385	97.11
	TCN	0.0200	0.0244	98.74
	REMD-NHITS	0.0055	0.0116	99.74
B06	LSTM	0.0487	0.0563	89.96
	GRU	0.0221	0.0251	92.19
	TCN	0.0219	0.0233	92.26
	REMD-NHITS	0.0082	0.0121	98.20

3.5 区间预测及结果分析

在获得高精度点预测的基础上, 进一步采用 KDE 方法对预测误差进行分布建模, 构建 REMD-NHITS-KDE 区间预测模型。在 80%、85% 和 95% 这 3 种置信水平下, 不同型号电池在 REMD-

NHITS-KDE 上的区间预测曲线结果如图 13 所示， REMD-NBEATS 进行对比，具体评价指标见表 8。并将所提方法与应用 KDE 的 NBEATS、NHITS、




图 13 不同型号电池模型区间预测曲线结果图：(a) CS2_35；(b) CS2_36；(c) CS2_37；(d) B06；(e) B07

Fig. 13 Results of interval prediction curves for battery models of different types: (a) CS2_35; (b) CS2_36; (c) CS2_37; (d) B06; (e) B07

图 13 表明，REMD-NHITS-KDE 模型在不同置信水平下生成的预测区间能够有效包裹真实值，且区间宽度随置信水平提高而适度增加，变化趋势合理。在 SOH 退化曲线的拐点区域，预测区间仍保持较好的精确度，未出现明显的过度展宽或局部失效现象，表明该模型对预测不确定性的刻画较为稳健。

定量对比结果进一步验证了 REMD-NHITS-KDE 模型在区间预测可靠性与精确性上的综合优势。以 CS2_37 电池为例，在 80%、85% 和 95% 置信水平下，该模型的 PICP 分别为 83.52%、87.91% 和 96.15%，均满足相应置信水平要求，其对应的 PINAW 分别为 2.03%、2.35% 和 3.69%，在所有对比模型中均为最小值。相较于 NBEATS-KDE 模型，本研究所提方法的 PINAW 在各置信水平下分别优化 44.84%、43.91% 和 40.58%；相较于未加入 REMD 分解的 NHITS-KDE 模型，上述指标分别优化 19.76%、22.70% 和 27.50%。在 NASA 数据集的 B06 电池中，REMD-NHITS-KDE

同样展现出优异性能。在 80%、85% 和 95% 置信水平下，该模型的 PICP 分别为 84.82%、86.76% 和 95.12%，均接近相应置信水平要求，对应的 PINAW 分别为 7.79%、9.73% 和 17.22%。与 NBEATS-KDE 模型相比，本研究所提方法的 PINAW 在各置信水平下优化幅度分别为 22.95%、23.98% 和 25.10%；与 NHITS-KDE 模型相比，上述指标分别实现了 9.52%、11.63% 和 22.0% 的优化。上述结果表明，本研究提出的区间预测模型能够在满足覆盖率要求的前提下显著缩窄预测区间宽度，实现了可靠性与精确性的良好平衡。

为进一步验证 KDE 方法的优越性，将 REMD-NHITS 模型分别与 KDE、蒙特卡洛法及参数法（正态分布）结合，以 CS2_37 电池为例进行对比，结果见表 9。在相同置信水平下，KDE 方法的 PICP 均超过置信水平要求，且其 PINAW 显著小于蒙特卡洛法。具体而言，在 95% 置信水平下，KDE 方法的 PINAW 为 3.69%，而蒙特卡洛法为 6.41%，宽度扩大大约 73.71%。参数法（正态分布）

表8 区间预测评价指标

Table 8 Evaluation indicators for interval prediction

电池型号	预测方法	80%置信度		85%置信度		95%置信度	
		PICP/%	PINAW/%	PICP/%	PINAW/%	PICP/%	PINAW/%
CS2_35	NBEATS-KDE	86.15	2.80	88.62	3.25	96.92	5.09
	NHITS-KDE	86.46	2.77	88.31	3.20	96.92	4.96
	REMD-NBEATS-KDE	84.31	2.89	88.92	3.36	5.30	5.30
	REMD-NHITS-KDE	85.85	2.49	89.23	2.89	95.38	4.85
CS2_36	NBEATS-KDE	83.04	3.39	86.55	4.00	95.61	6.62
	NHITS-KDE	82.75	3.04	86.84	3.67	95.61	6.36
	REMD-NBEATS-KDE	83.33	2.67	86.26	3.30	96.20	6.04
	REMD-NHITS-KDE	82.75	2.69	85.09	3.22	95.32	5.49
CS2_37	NBEATS-KDE	84.89	3.68	87.09	4.19	95.88	6.21
	NHITS-KDE	82.97	2.53	86.54	3.04	95.33	5.09
	REMD-NBEATS-KDE	81.87	2.27	87.64	2.70	95.60	4.50
	REMD-NHITS-KDE	83.52	2.03	87.91	2.35	96.15	3.69
B06	NBEATS-KDE	83.82	10.11	86.76	12.8	95.59	21.13
	NHITS-KDE	85.29	8.61	86.76	11.01	94.12	18.93
	REMD-NBEATS-KDE	85.29	8.92	86.76	10.45	95.59	15.99
	REMD-NHITS-KDE	84.82	7.79	86.76	9.73	95.12	17.22
B07	NBEATS-KDE	85.29	10.50	88.24	12.29	95.59	18.74
	NHITS-KDE	85.29	9.59	88.24	11.6	95.59	17.98
	REMD-NBEATS-KDE	85.29	10.16	89.71	11.72	95.59	18.52
	REMD-NHITS-KDE	82.35	7.84	86.76	9.52	95.59	14.03

虽然PINAW更小，但其PICP仅为81.87%，远低于95%的置信水平要求，覆盖能力不足。综合比较，KDE方法在保证覆盖率的前提下获得最窄的预测区间，验证了本研究所提出的REMD-NHITS-KDE模型在锂离子电池SOH区间预测中的有效性与优越性。

表9 不同区间预测方法评价指标

Table 9 Evaluation indicators of different interval prediction methods

方法	置信度	PICP/%	PINAW/%
REMD-NHITS-KDE	80	83.52	2.03
	85	87.91	2.35
	95	96.15	3.69
REMD-NHITS-蒙特卡洛法	80	87.42	4.04
	85	90.35	4.65
	95	95.90	6.41
REMD-NHITS-正态分布	80	67.84	1.71
	85	73.68	1.92
	95	81.87	2.60

4 结 论

本研究针对锂离子电池健康状态退化过程中非线性强、波动明显以及单一点预测难以表征不确定性的问题，提出了一种融合REMD-NHITS与KDE的SOH预测方法。该方法从锂离子电池充放电循环数据中提取与SOH高度相关的HI，并利用REMD对原始HI序列进行自适应分解，以削弱数据的非平稳性；随后结合NHITS模型对各分量进行建模预测，并通过重构获得SOH点预测结果；在此基础上，进一步利用KDE对预测误差分布进行非参数估计，构建SOH区间预测模型，实现对预测结果不确定性的量化表征。通过在CALCE和NASA数据集上的实验验证可知，所提方法在点预测任务中表现出优越的预测性能。与NBEATS、NHITS及REMD-NBEATS等对比模型相比，所提模型在MAE、RMSE及R²等指标上均具有明显优化效果，预测结果与真实退化轨迹更加接近。区间预测结果进一步表明，REMD-NHITS-KDE能够在保证预测区间覆盖率的前提下有效减小区间宽度，

在可靠性与精确性之间取得较优平衡。

综上, 本研究提出的 REMD-NHITS-KDE 方法能够较为准确地刻画锂离子电池 SOH 的退化趋势及不确定性, 验证了信号分解、深度时序建模与 KDE 相结合的有效性, 可为锂离子电池健康管理、寿命评估及储能系统安全运行提供参考。

参考文献

- [1] 李炳金, 韩晓霞, 张文杰, 等. 锂离子电池剩余使用寿命预测方法综述[J]. 储能科学与技术, 2024, 13(4): 1266-1276.
LI B J, HAN X X, ZHANG W J, et al. Review of the remaining useful life prediction methods for lithium-ion batteries[J]. Energy Storage Science and Technology, 2024, 13(4): 1266-1276.
- [2] 丁赛. 新能源汽车电池盒电泳膜厚仿真研究[J]. 电镀与涂饰, 2024, 43(9): 135-142. DOI:10.19289/j.1004-227x.2024.09.015.
DING S. Simulative study on electrophoretic coating thickness of battery enclosure of new energy car[J]. Electroplating & Finishing, 2024, 43(9): 135-142. DOI:10.19289/j.1004-227x.2024.09.015.
- [3] LI Y, SHI H T, WANG S L, 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, 2026, 112: 384-414. DOI: 10.1016/j.jchem.2025.08.056.
- [4] 李卓昊, 石琼林, 王康丽, 等. 锂离子电池健康状态估计方法研究现状与展望[J]. 电力系统自动化, 2024, 48(20): 109-129. DOI: 10.7500/AEPS20231221006.
LI Z H, SHI Q L, WANG K L, et al. Research status and prospects of state of health estimation methods for lithium-ion batteries[J]. Automation of Electric Power Systems, 2024, 48(20): 109-129. DOI:10.7500/AEPS20231221006.
- [5] AMIR S, GULZAR M, TARAR M O, et al. Dynamic equivalent circuit model to estimate state-of-health of lithium-ion batteries[J]. IEEE Access, 2022, 10: 18279-18288. DOI: 10.1109/ACCESS.2022.3148528.
- [6] 段慧云, 夏威, 邵杰, 等. 基于充电健康因子优化和数据驱动的锂电池剩余使用寿命预测[J]. 汽车技术, 2024(1): 20-26.
DUAN H Y, XIA W, SHAO J, et al. A data-driven remaining useful life prediction approach for lithium-ion batteries based on charging health feature optimization[J]. Automobile Technology, 2024(1): 20-26.
- [7] 董作林, 宋金岩, 孟子迪. 基于模态分解和深度学习的锂离子电池寿命预测[J]. 储能科学与技术, 2025, 14(4): 1645-1653. DOI: 10.19799/j.cnki.2095-4239.2024.0983.
DONG Z L, SONG J Y, MENG Z D. Lithium-ion battery life prediction based on mode decomposition and deep learning[J]. Energy Storage Science and Technology, 2025, 14(4): 1645-1653. DOI:10.19799/j.cnki.2095-4239.2024.0983.
- [8] ZHU G Q, HE C, CHEN Y L, et al. A hybrid parallel informer-LSTM framework based on two-stage decomposition for lithium battery remaining useful life prediction[J]. Energies, 2026, 19(3): 612. DOI:10.3390/en19030612.
- [9] 衣思彤, 刘雅浓, 马耀滢, 等. 基于贝叶斯优化-卷积神经网络-双向长短期记忆神经网络的锂电池健康状态评估[J]. 电气技术, 2024, 25(5): 1-10, 21. DOI:10.3969/j.issn.1673-3800.2024.05.001.
YI S T, LIU Y N, MA Y Y, et al. State of health assessment of lithium battery based on Bayesian optimization-convolution neural network-bi-directional long short term memory neural network[J]. Electrical Engineering, 2024, 25(5): 1-10, 21. DOI: 10.3969/j.issn.1673-3800.2024.05.001.
- [10] 程思涵, 刘思懿, 郭子旭, 等. 基于 CNN-GRU-注意力的锂离子电池 SOC 估计[J]. 电池, 2026, 56(1): 131-135. DOI:10.19535/j.1001-1579.2026.01.019.
CHENG S H, LIU S Y, GUO Z X, et al. SOC estimation for Li-ion battery based on the CNN-GRU-Attention[J]. Battery Bimonthly, 2026, 56(1): 131-135. DOI:10.19535/j.1001-1579.2026.01.019.
- [11] ORESHKIN B N, DUDEK G, PELKA P, et al. N-BEATS neural network for mid-term electricity load forecasting[J]. Applied Energy, 2021, 293: 116918. DOI:10.1016/j.apenergy.2021.116918.
- [12] LEE M, LEE Y, KIM G. Transfer learning based on N-BEATS in forecasting univariate time series[J]. IEEE Access, 2026, 14: 45191-45212. DOI:10.1109/ACCESS.2026.3675559.
- [13] CHALLU C, OLIVARES K G, ORESHKIN B N, et al. NHITS: Neural hierarchical interpolation for time series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(6): 6989-6997. DOI:10.1609/aaai.v37i6.25854.
- [14] 姚芳, 韩永康, 李谦, 等. 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[J]. 天津大学学报(自然科学与工程技术版), 2026, 59(1): 77-89.
YAO F, HAN Y K, LI Q, et al. Remaining useful life prediction of lithium-ion batteries based on combination of multiscale health indicators-BEAST decomposition and SARIMA modeling[J]. Journal of Tianjin University (Science and Technology), 2026, 59(1): 77-89.
- [15] 张俊贤, 周英超, 李波, 等. 融合 EMD 与 GAIPSO-LSTM 算法的锂离子电池 RUL 预测方法研究[J]. 重庆理工大学学报(自然科学), 2025, 39(6): 28-36.
ZHANG J X, ZHOU Y C, LI B, et al. Research on RUL prediction method of lithium-ion batteries based on EMD and GAIPSO-LSTM algorithm[J]. Journal of Chongqing University of Technology (Natural Science), 2025, 39(6): 28-36.
- [16] 依沙克·司马义, 陈昊, 张正强, 等. 基于 NWP 信息的 SSA 优化 EEMD-LSTM 风电超短期功率预测[J]. 太阳能学报, 2025, 46(8): 176-183. DOI:10.19912/j.0254-0096.tynxb.2024-0534.
SIMAYI Y, CHEN H, ZHANG Z Q, et al. Ultra-short-term wind power prediction based on nwp information using ssa optimized eemd-lstm[J]. Acta Energiae Solaris Sinica, 2025, 46(8): 176-183. DOI:10.19912/j.0254-0096.tynxb.2024-0534.
- [17] ZHANG L Y, WANG Z Y, LI L. Bearing fault identification based on CEEMDAN-SVD and CNN[J]. Mechanical Science and Engineering, 2024: DOI:10.57237/j.mse.2024.01.002.
- [18] 乔松博, 孙瑜, 胡海, 等. 基于 REMD-CNN-Transformer-LSTM 组合模型的碳排放交易价格预测[J]. 西安理工大学学报, 2025, 41(2): 186-196. DOI:10.19322/j.cnki.issn.1006-4710.2025.02.004.

- QIAO S B, SUN Y, HU H, et al. Carbon emission trading price prediction based on REMD-CNN-Transformer-LSTM combined model[J]. Journal of Xi'an University of Technology, 2025, 41(2): 186-196. DOI:10.19322/j.cnki.issn.1006-4710.2025.02.004.
- [19] CHEN C, TAO G Y, SHI J T, et al. A lithium-ion battery degradation prediction model with uncertainty quantification for its predictive maintenance[J]. IEEE Transactions on Industrial Electronics, 2024, 71(4): 3650-3659. DOI:10.1109/TIE.2023.3274874.
- [20] ZHANG Y, ZHANG M, LIU C, et al. Reliability enhancement of state of health assessment model of lithium-ion battery considering the uncertainty with quantile distribution of deep features[J]. Reliability Engineering & System Safety, 2024, 245: 110002. DOI:10.1016/j.ress.2024.110002.
- [21] 汤霜霜, 白建波, 侯天才, 等. 基于蒙特卡洛法的光伏系统老化评估及发电量预测方法研究[J]. 太阳能学报, 2025, 46(5): 311-319. DOI: 10.19912/j.0254-0096.tynxb.2024-0089.
- TANG S S, BAI J B, HOU T C, et al. Research on aging assessment and power generation prediction of photovoltaic system based on Monte Carlo method[J]. Acta Energetica Solaris Sinica, 2025, 46(5): 311-319. DOI: 10.19912/j.0254-0096.tynxb.2024-0089.
- [22] LIU Z F, HUANG Y H, ZHANG S R, et al. A collaborative interaction gate-based deep learning model with optimal bandwidth adjustment strategies for lithium-ion battery capacity point-interval forecasting[J]. Applied Energy, 2025, 377: 124741. DOI:10.1016/j.apenergy.2024.124741.