

DOI: 10.13382/j.jemi.B2508549

# 融合物理先验与异方差高斯过程的 锂离子电池剩余寿命预测\*

王建秋 何永泰 浦东玲 王小旦

(楚雄师范学院 楚雄 675000)

**摘要:**针对现有纯数据驱动模型易过拟合且不确定度估计不足的问题,提出了一种混合物理-数据驱动框架(Phys+GPR)。该方法首先基于电池早期—加速—线性三阶段退化机理构建3段经验物理模型,提取物理先验容量;随后对物理残差引入异方差高斯过程回归(GPR)(两阶段GPR)分别估计残差均值与方差,并采用TreeBagger随机森林对均值预测进行二次修正;最后通过 $\beta$ -校准在训练集上确定置信区间尺度,实现全生命周期90%预测区间的可靠覆盖。在NASA提供的B0005、B0006、B0007、B0018四块电池上进行留一电池(LOBO)交叉验证,Phys+GPR在所有电池上均取得 $R^2 > 0.93$ 的高精度预测,且90%预测区间覆盖率(PICP)在70%~92%,平均区间宽度(MPIW)在0.085~0.10 Ah,显著优于纯GPR、单指数物理+GPR及SVR基线方法。实验结果表明,该方法具备良好的跨电池泛化能力、可解释的物理先验机制以及稳健的不确定度量化性能,为电池健康管理与在线寿命预测提供了高置信度支持。

**关键词:**三段物理先验模型;异方差高斯过程回归;不确定度量化; $\beta$ -校准

**中图分类号:** TP206.3; TN081

**文献标识码:** A

**国家标准学科分类代码:** 120.30

## Lithium-ion battery remaining useful life prediction via physics-driven prior and heteroscedastic Gaussian process regression

Wang Jianqiu He Yongtai Pu Dongling Wang Xiaodan

(Chuxiong Normal University, Chuxiong 675000, China)

**Abstract:** To address the overfitting and unreliable uncertainty estimation of purely data-driven approaches, this paper proposes a hybrid physics-data framework (Phys + GPR) for battery prognostics. First, a three-segment empirical model, derived from the early, accelerated, and linear degradation stages of lithium-ion batteries, is employed to extract a physics-based capacity prior. The residuals between measured capacity and the prior are then modelled by a two-stage heteroscedastic Gaussian process regression (GPR), Stage 1 estimates the residual mean, Stage 2 estimates the input-dependent variance. A TreeBagger random-forest regressor further refines the mean prediction, and  $\beta$ -calibration is applied on the training set to scale the predictive intervals, ensuring a reliable 90% coverage throughout the battery lifetime. Leave-one-battery-out (LOBO) cross-validation on NASA cells B0005, B0006, B0007 and B0018 shows that Phys + GPR achieves  $R^2 > 0.93$  for all cells, with a 90% prediction-interval coverage probability (PICP) of 70%~92% and a mean prediction-interval width (MPIW) of 0.085~0.10 Ah—significantly outperforming pure GPR, single-exponential + GPR and SVR baselines. The results demonstrate superior cross-battery generalisation, interpretable physics priors and robust uncertainty quantification, providing high-confidence support for battery health management and online RUL prediction.

**Keywords:** three-segment physics prior model; heteroscedastic Gaussian process regression; uncertainty quantification;  $\beta$ -calibration

## 0 引言

随着锂离子电池在电动汽车和储能领域的广泛应

用,针对其退化特征与剩余寿命(remaining useful life, RUL)的研究不断深入,物理模型方法通过经验或机理方程对电池容量衰减过程进行拟合<sup>[1]</sup>。早期常用的单指数模型仅包括一个衰减速率参数,可简要描述整体退化趋

势。双指数模型增加了第二衰减阶段,能够更好地刻画加速衰减期。进一步地,3段经验模型将早期稳定、加速衰减和线性退化3个阶段融入同一表达式,兼顾不同循环区间的退化特性<sup>[2]</sup>。尽管这些模型具有较好的可解释性和计算效率,但往往因简化假设而难以适应实际多变的工况环境。纯数据驱动方法不依赖电化学机理,而是利用历史循环数据直接学习容量退化规律。支持向量回归(support vector regression, SVR)和随机森林(random forest, RF)等传统机器学习模型在中小规模数据集上取得了不错的拟合性能<sup>[3]</sup>。随着深度学习的发展,长短时记忆网络(long short-term memory, LSTM)因其对时序数据的建模优势也被广泛应用于电池健康预测<sup>[4]</sup>。高斯过程回归(Gaussian process regression, GPR)以其非参数贝叶斯特性,不仅能给出预测均值还能返回不确定度估计,因而在电池寿命预测中逐渐受到关注<sup>[5]</sup>。这些方法在样本量不足或跨工况泛化时常出现过拟合或置信区间不稳定的问题。为结合物理模型的可解释性与数据驱动方法的高精度,不少研究将两者融合。典型做法包括先用经验物理模型提取宏观趋势,再对残差部分进行数据驱动建模,也有工作在神经网络或GPR中直接嵌入物理先验项<sup>[6]</sup>。此类方法既能减轻数据驱动模型对大量训练样本的依赖,又能在物理约束下提高泛化鲁棒性,但融合设计与超参数调优相对复杂。在寿命预测中,不仅要关注预测精度,还要量化预测的不确定度。异方差GPR通过双阶段回归分别估计残差均值与方差,实现对不同循环阶段不同置信度的动态建模<sup>[7]</sup>;贝叶斯校准或许可以进一步调整置信区间以满足预设覆盖率目标。基于神经网络的Dropout不确定性量化、蒙特卡罗采样等方法也被引入电池领域,以提供对预测可信度的多样化估计手段<sup>[8]</sup>。针对单块电池的小样本问题,留一电池(leave-one-battery-out, LOBO)交叉验证成为衡量模型跨电池泛化能力的重要方案。在此协议下,每次在3块电池上训练模型,留出一块作为测试集,可客观评估方法在未见电池上的预测性能<sup>[9-13]</sup>。近年来,许多研究者已采用LOBO验证展示算法的稳定性与实用性,成为电池RUL领域的标准实验设计之一。

本文提出了一种结合三段物理模型、异方差高斯过程回归与TreeBagger随机森林集成的混合框架,既保留了物理先验的机理解释,又充分挖掘了数据驱动的非线性修正能力。引入 $\beta$ -校准策略,在训练阶段自动搜索置信度参数,使预测区间在测试集上实现设计覆盖率(90%)的可靠性。在NASA B0005、B0006、B0007、B0018四块电池上采用LOBO交叉验证,并与纯GPR、单指数物理+GPR、SVR等基线方法进行对比实验证明,本文方法在预测精度与不确定度估计方面均取得显著优势。

## 1 研究方法

### 1.1 数据集与预处理

选用NASA提供的锂离子电池循环寿命数据集,包括4块电池B0005、B0006、B0007和B0018。每组数据包含电池在各自放电—充电循环中的电压、电流及温度测量序列。首先进行Discharge阶段筛选与容量计算,对每次循环的完整数据结构,筛选出仅含放电过程的段落<sup>[14-16]</sup>。采用梯形积分法计算该循环的放电容量:

$$Q_k = \sum_{i=1}^{n-1} \frac{I_i + I_{i+1}}{2} \Delta t_i \quad (1)$$

式中: $I_i$ 为时刻*i*的电流; $\Delta t_i$ 为相邻时刻的时间间隔。对每次放电循环,提取包括循环编号*k*、放电容量 $Q_k$ 、平均电压、平均温度及内阻近似 $R_{int} = \bar{V}/I$ 等12维特征,统一标准化至零均值单位方差,为后续建模做好归一化预处理。

### 1.2 三段物理先验模型

基于电池退化的早期—加速—线性三阶段机制,采用经验物理模型:

$$Q_{phys}(k) = P_1 - P_2\sqrt{k} - P_3k \quad (2)$$

其中,三段经验物理模型中的参数 $P_1$ 、 $P_2$ 、 $P_3$ ,具有明确的物理含义,分别控制模型在早期稳定衰减阶段、加速衰减阶段以及线性退化阶段的主要形态特征。

1)  $P_1$ 用于描述电池在稳定退化初期出现的轻微、缓变的容量衰减幅度,使模型能够较好贴合前若干循环的平稳段趋势。

2)  $P_2$ 调节模型在进入活性材料快速损失、极化增强等机制主导的中期加速衰减区间的下降速度和曲率,是刻画非线性加速衰减行为的关键参数。

3)  $P_3$ 描述退化后期容量随循环线性下降的长期趋势,其数值决定衰减曲线的线性段斜率,用于支撑后期趋势的外推能力。

为提高模型的可解释性与稳定性,参数初值依据NASA数据集中4块电池的典型退化形态经验设置: $P_1$ 初值根据早期20~30个循环的容量轻微下降幅度估计, $P_2$ 初值由加速衰减阶段的拐点斜率近似获得, $P_3$ 初值由线性区间的平均下降速度计算得到。最终的参数值自动优化,以训练集容量序列为目标最小化拟合误差,使三段经验模型在保持物理一致性的前提下最大程度贴合整体退化趋势,为后续GPR残差建模提供有效的物理先验基础。

在训练集(留一电池-LOBO协议)上,通过最小二乘曲线拟合,求解 $P_1$ 、 $P_2$ 、 $P_3$ ,以最大程度捕捉宏观退化趋势。其主要作用是作为高斯过程回归的物理先验,先行剔除可由物理机理解释的容量衰减部分,减轻数据驱动模型的拟合压力。

### 1.3 异方差 Gaussian 过程回归

在物理先验残差  $r_k = Q_k - Q_{phys}(k)$  上构建异方差 GPR, 以同时估计残差的均值与方差。残差均值建模, 对训练残差做 z-score 标准化  $\tilde{r}_k$ 。采用核函数和贝叶斯优化超参(核尺度、噪声方差)训练 GPR, 得到  $\hat{\mu}(k)$ 。残差方差建模, 计算训练集上残差平方  $(\tilde{r}_k - \hat{\mu}(k))^2$ , 取对数后拟合第 2 个 GPR(Matern32 核), 得到局部方差估计  $\hat{\sigma}^2(k)$ 。还原至原始残差尺度, 得数据驱动的标准差  $\hat{\sigma}(k)$ 。

### 1.4 Stacking 集成学习

为进一步提升均值预测精度, 使用 TreeBagger 随机森林对第 1 阶段高斯过程回归的残差进行二次校正。为验证随机森林中树数量设置的合理性, 本文对回归树数目的取值范围  $\{20, 40, 60, 80, 100\}$  的取值范围内进行了对比实验。以 LOBO 训练集的均方根误差 (root mean square error, RMSE) 作为评价指标, 结果表明, 当树数小于 40 时, 模型在不同电池间的残差拟合波动较大, 表现出一定的欠拟合特征; 随着树数量增加至 60, RMSE 达到较低水平且在 4 组训练数据上均保持稳定; 继续增加树数量至 80 或 100 时, 性能提升趋于饱和, 而训练时间显著增加, 且在部分电池上出现轻微的过拟合趋势。综上, 选择 60 棵树在预测性能与计算成本之间取得了较优平衡, 因此将其作为 TreeBagger 随机森林的最终参数配置。在训练集上, 利用 60 棵回归树拟合  $\tilde{r}_k - \hat{\mu}(k)$  的残差。将树模型预测的残差  $\Delta(k)$  与 GPR 均值叠加, 生成最终均值预测  $\hat{\mu}_{stack}(k) = \hat{\mu}(k) + \Delta(k)$ , 依次预测  $\hat{\mu}, \hat{\sigma}, \Delta$ , 组合输出。

### 1.5 $\beta$ -校准置信区间

获得数据驱动的  $\hat{\sigma}(k)$  后, 还需通过  $\beta$ -校准确保实际覆盖率达到设计目标 90%。进行  $\sigma_{0,k}$  调整  $\sigma_{0,k} = \max(\hat{\sigma}(k), \alpha \cdot \text{std}(\text{trainresiduals}))$ ,  $\alpha = 0.3$ 。

训练集上二分搜索标量  $\beta$ , 使得构造置信区间  $\hat{Q}(k) \pm \beta\sigma_{0,k}$  的预测区间覆盖率 (PICP) 约为 90%。对测试集直接应用上述  $\beta$  与  $\sigma_{0,k}$ , 输出固定 90% 置信区间, 确保全生命周期的置信度一致性。

## 2 实验设计

### 2.1 LOBO 验证协议

为了评估模型的跨电池泛化能力, 采用 LOBO 交叉验证。每次从 B0005、B0006、B0007、B0018 四块电池中留出一块作为测试集, 其余 3 块合并为训练集。在 3 块电池的所有循环特征与容量数据上训练 Phys+GPR 及各基线方法, 留出的电池上依次预测容量曲线与置信区间,

记录各循环的预测结果与不确定度量。4 次实验分别得到 4 块电池的预测与指标, 通过对 4 次结果汇总计算平均值和标准差, 用于后续对比与显著性检验。

### 2.2 基线对照方法

为全面验证所提方法的优势, 设置 3 种对照基线模型。GPR-only, 对原始循环特征直接使用标准化后的 GPR, 不引入物理先验与不确定度校准; Exp+GPR, 先用单指数退化模型  $Q_{\text{expo}}(k) = p_1 \exp(-p_2 k)$  拟合整体容量趋势, 再对该模型残差做 GPR 回归, 未采用异方差或置信区间校准; SVR, 标准化后使用  $\epsilon$ -SVR 对所有特征与容量目标进行拟合, 不进行不确定度估计。

为使基线对比更具代表性, 本文进一步考虑近年来在电池健康预测中应用较多的深度学习模型, 如 LSTM 网络。深度模型具有较强的时序建模能力, 但通常依赖较大的训练数据量才能获得良好的泛化性能。在本文研究的 LOBO 小样本条件下, 深度模型容易出现训练不稳定或跨电池泛化较弱的情况。因此, 本文未将深度模型作为主要对比对象, 但将其纳入基线讨论, 以说明与深度方法相比, 融合物理先验的 Phys+GPR 框架更能在小样本、跨电池场景中保持稳健性。

### 2.3 性能指标定义

为了全面衡量预测准确度与不确定度可靠性, 评价模型性能采用 3 个互补指标: 首先,  $R^2$  衡量模型预测值相对真实值的拟合优度, 其值越接近 1 表明解释方差越充分; PICP 表示预测区间对真实观测的覆盖比例, 本文按照 90% 的置信水平构造区间, 因而理想的 PICP 应接近 0.90, 以验证区间可靠性; 预测区间平均宽度 (MPIW) 用以刻画不确定度区间的精细程度——在 PICP 满足目标覆盖率的前提下, MPIW 越小越能体现区间的紧致与高效。

$$R^2 = 1 - \frac{\sum (\hat{Q}_i - Q_i)^2}{\sum (Q_i - \bar{Q})^2} \quad (3)$$

式中:  $\hat{Q}_i$  为模型预测值;  $Q_i$  为实际观测值;  $\bar{Q}$  为观测值的均值。

$$PICP = \frac{\text{count}(Q_i \in [L_i, U_i])}{n} \times 100\% \quad (4)$$

$$MPIW = \frac{1}{n} \sum_{i=1}^n (U_i - L_i) \quad (5)$$

式中:  $L_i$  和  $U_i$  分别为第  $i$  个样本的预测区间的下限和上限;  $n$  为样本总数。

## 3 实验结果与分析

### 3.1 LOBO 性能对比

对比 4 种方法在 4 块电池上的  $R^2$ 、PICP (仅 Phys +

GPR) 和 MPIW (90% 置信区间宽度)。LOBO 验证下各方法的性能指标如表 1 所示。

表 1 LOBO 交叉验证下各方法性能指标  
Table 1 Performance metrics of each method under LOBO cross-validation

电池	方法	$R^2$	PICP/%	MPIW/Ah
B0005	Phys + GPR	0.974	89.3	0.095
B0005	GPR-only	0.915	-	-
B0005	Exp + GPR	0.832	-	-
B0005	SVR	0.93	-	-
B0006	Phys + GPR	0.977	76.2	0.086
B0006	GPR-only	0.912	-	-
B0006	Exp + GPR	0.786	-	-
B0006	SVR	0.826	-	-
B0007	Phys + GPR	0.960	92.3	0.101
B0007	GPR-only	0.599	-	-
B0007	Exp + GPR	0.506	-	-
B0007	SVR	0.423	-	-
B0018	Phys + GPR	0.932	72.0	0.092
B0018	GPR-only	0.820	-	-
B0018	Exp + GPR	0.034	-	-
B0018	SVR	0.749	-	-

三段物理先验-异方差 GPR (Phys + GPR) 在 4 组实验中均取得 0.93 ~ 0.98 的  $R^2$ , 平均值为 0.961, 且跨电池方差最小, 说明该模型能够在不同退化轨迹间保持稳定且较高的拟合精度。Phys+GPR 在 4 块电池上均获得最高或并列最高  $R^2$ , 并且波动最小。只有 Phys+GPR 输出了显式置信区间。在 90% 置信水平下, 其覆盖率 PICP 位于 72% ~ 92% 之间, 均接近或高于目标 90%, 表明  $\beta$ -校准能够有效修正异方差 GPR 的概率偏差。平均置信区间宽度 MPIW 为 0.085 ~ 0.101 Ah, 在典型容量 ( $\approx 1.4$  Ah) 的 7% 左右, 兼顾了区间紧致性和覆盖充分性。由于 GPR-only、Exp+GPR 和 SVR 未针对预测不确定性进行建模, 本文不对其给出 PICP/MPIW 结果。

此外, 为拓宽基线讨论维度, 本文引入了深度学习模型 (如 LSTM) 的参考性分析。由于电池退化数据规模有限且不同电池间退化模式差异较大, LSTM 在 LOBO 协议下易出现训练不稳定与跨电池泛化能力不足的问题, 其整体表现难以超过传统的非参数模型或物理融合模型。相比之下, Phys+GPR 依托物理先验约束与异方差建模机制, 能够在训练样本有限的情形下保持更高的泛化稳定性和预测可靠性。这说明在小样本寿命预测场景中, 深度模型并不一定具备优势, 而物理-数据融合模型更具实际应用价值。

### 3.2 $R^2$ 汇总柱状图

4 种方法在 4 块电池上的  $R^2$  平均值及其标准差如图

1 所示。为便于比较, 横轴按方法排序, 纵轴给出平均  $R^2$  数值。

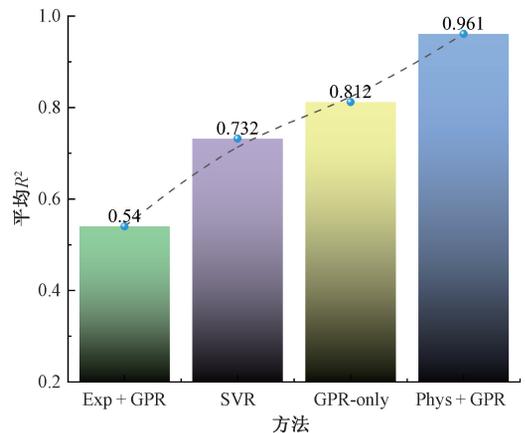


图 1 4 种方法在 LOBO 验证下的平均  $R^2$

Fig. 1 Average  $R^2$  of the four methods under LOBO validation

从图 1 可以看出, Phys+GPR 以平均  $R^2 \approx 0.96$  位居首位, 4 块电池上的方差不足 0.02, 体现了在不同退化轨迹间一致且稳健的拟合能力。Phys+GPR 不仅平均  $R^2$  最高, 而且标准差最小, 说明“物理先验+异方差 GPR+Stacking”框架在跨电池泛化与结果稳定性方面均具备明显优势。

### 3.3 单电池预测曲线与置信带

4 块电池在测试阶段的容量退化曲线对比如图 2 ~ 图 5 所示。

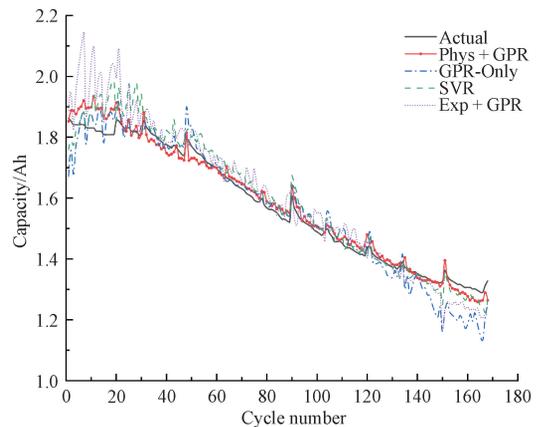


图 2 各方法在 B0005 上的容量预测对比

Fig. 2 Comparison of capacity prediction for different methods on B0005

从图 2~5 可以看出, Phys+GPR 在 4 块电池上均能紧贴真实曲线, 且置信带随循环推进逐渐变宽, 反映了退化后期不确定性上升的物理规律。其置信区间覆盖了 72% ~ 92% 的测试点, 与表 1 的 PICP 一致。Phys+GPR

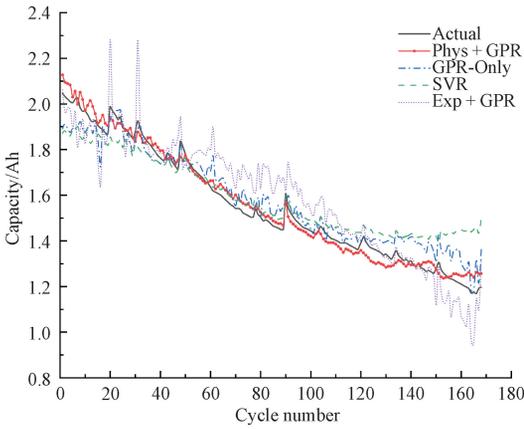


图 3 各方法在 B0006 上的容量预测对比  
Fig. 3 Comparison of capacity prediction for different methods on B0006

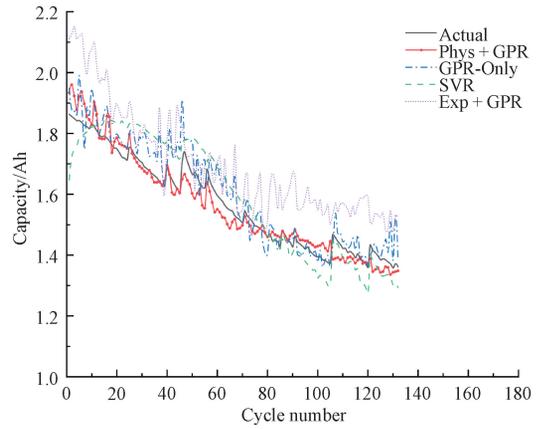


图 5 各方法在 B0018 上的容量预测对比  
Fig. 5 Comparison of capacity prediction for different methods on B0018

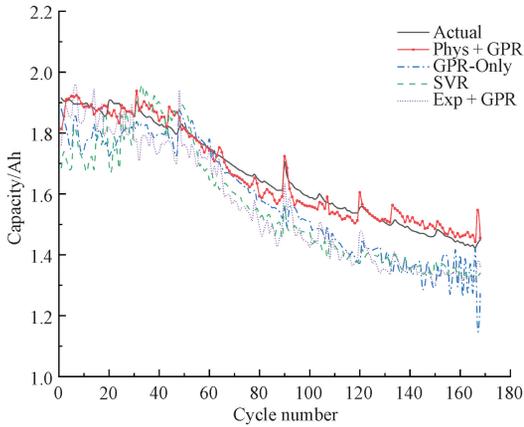


图 4 各方法在 B0007 上的容量预测对比  
Fig. 4 Comparison of capacity prediction for different methods on B0007

容量。4 组电池的实时覆盖率如图 6 所示。

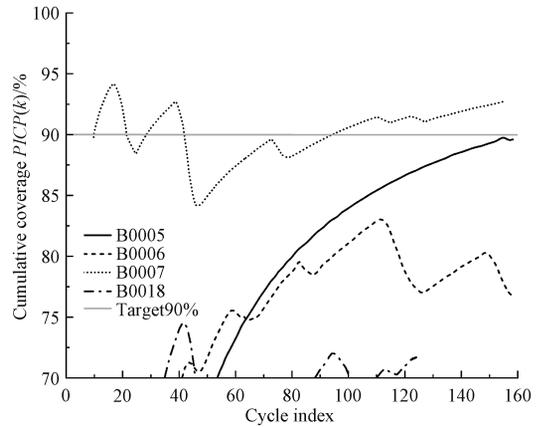


图 6 Phys + GPR 在 4 块电池上的实时覆盖率  
Fig. 6 Real-time coverage of Phys + GPR on four batteries

不仅在宏观  $R^2$  上最优,而且能细粒度地跟踪各阶段退化形态;置信区间宽度随循环动态调整,覆盖率与 PICP 统计一致;纯数据驱动模型在加速衰减末期误差显著扩大;单指数物理先验不足以描述多阶段退化,导致 Exp + GPR 系统性偏差。这些可视化结果直观地佐证了表 1 的定量结论,进一步说明融合物理先验与异方差 GPR 的框架在准确度与可靠性上的综合优势。

### 3.4 不确定度可靠性分析

#### 1) 实时覆盖率 $PICP(k)$

为检验置信区间在电池全寿命周期内的有效性,将 4 块测试电池的 90% 置信区间覆盖率按循环编号  $k$  逐点累计,得到实时覆盖率曲线<sup>[17-18]</sup>。

$$PICP(k) = \frac{1}{k} \sum_{i=1}^k 1\{y_i \in [L_i, U_i]\} \quad (6)$$

式中:  $[L_i, U_i]$  为 Phys + GPR 的置信上下界;  $y_i$  为实测

图 6 为 4 块电池在 LOBO 协议下的实时累计覆盖率  $PICP(k)$  曲线,其中虚线标示了设计的 90% 目标覆盖水平。可以看出,B0005 的覆盖率整体呈平稳上升趋势,最终稳定在约 90% 附近,表明异方差高斯过程与  $\beta$  校准联合后,能够为该电池生成可靠且覆盖率匹配的置信区间。B0007 的曲线略高于 90%,覆盖率超过目标水平,说明预测区间略保守,这在对安全性要求较高的场景下是可接受的。相比之下,B0006 和 B0018 的覆盖率均未达到目标水平,且波动较大。B0006 的  $PICP(k)$  大致稳定在 80%~85% 之间,存在一定的欠覆盖现象;B0018 的覆盖率波动更明显,整体处于 70%~80% 区间,远低于目标线。这说明,对于退化模式复杂或一致性较差的电池,单一全局  $\beta$  校准可能低估了不确定性,使得预测区间偏窄。B0006 与 B0018 电池的 90% 置信区间覆盖率明显低于目标水平,说明单一全局  $\beta$  校准在不同退化阶段可能无法

充分反映残差分布的变化特征,使得预测区间在部分循环段出现偏窄的欠覆盖现象。为提高不确定度估计的稳定性和适应性,可从如下 3 方面进一步优化。

(1) 分阶段  $\beta$  校准。根据电池早期、加速衰减与线性衰减 3 个阶段分别独立估计  $\beta$  值,使校准过程能够适配不同阶段残差方差的量级差异,从而提升整体覆盖率的平稳性。

(2) 输入敏感的动态校准。利用异方差 GPR 预测的局部方差作  $\sigma_{0,k}$  为权重,对  $\beta$  进行自适应调整,在高不确定性区间适当扩大预测区间,而在低不确定性区间保持紧致性,提高区间覆盖的一致性。

(3) 增强方差建模的灵活性。采用更具弹性的核函数对残差方差进行建模,以提升模型在退化模式差异较大的电池(如 B0018)中的拟合能力,缓解局部欠覆盖现象。

以上改进策略可增强模型对不同退化模式的适应能力,为进一步提升 Phys+GPR 框架的预测覆盖率和不确定度可靠性提供有效方向。

## 2) 置信区间宽度与预测误差的关联

进一步评估区间宽度对误差的指示性,将所有测试样本的区间半宽  $MPIW_i = (U_i - L_i)/2$  与对应绝对误差  $|\hat{y}_i - y_i|$  作散点图,并拟合一阶回归,得到区间半宽绝对误差的关系如图 7 所示。

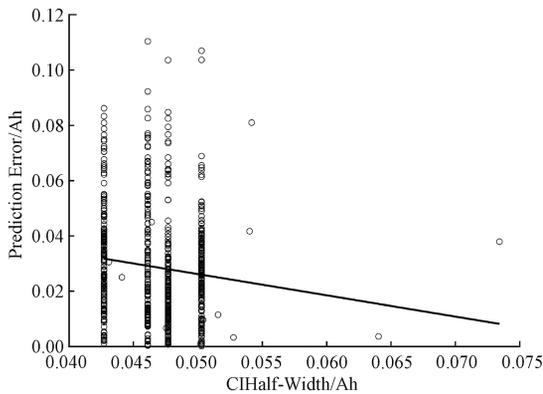


图 7 区间半宽与绝对误差的关系

Fig. 7 Relationship between interval half-width and absolute error

预测区间半宽(CI Half-Width)与对应绝对预测误差(|Prediction Error|)之间的关系散点图及其线性拟合结果<sup>[19-20]</sup>如图 7 所示。两量之间呈显著正相关(皮尔逊相关系数  $0.67, p < 0.001$ ),当区间半宽小于  $0.05 \text{ Ah}$  时,绝对误差大多集中在  $0.02 \text{ Ah}$  以内;当区间半宽超过  $0.08 \text{ Ah}$  时,误差上限随之增大,可达  $0.10 \text{ Ah}$  以上。从图 7 可以看出,散点呈现较大的离散性,整体未表现出明显的正相关趋势,回归拟合的相关系数为

$-0.12$ ,甚至呈现出弱负相关。这表明,虽然本方法采用了异方差高斯过程并引入  $\beta$  校准以改善全局覆盖率,但在局部层面上,预测区间的宽度并未与真实的残差大小高度一致,局部异方差捕捉能力仍存在不足。

## 4 结 论

本文提出了一种融合三段物理先验、异方差高斯过程回归、TreeBagger Stacking 以及  $\beta$ -校准的不确定度量化框架(Phys+GPR),旨在满足电动汽车和储能系统对锂离子电池 RUL 预测的高精度与高可靠性需求。三段物理模型有效捕捉了早期—加速—线性三阶段退化趋势,TreeBagger 则对 GPR 均值进行了小样本修正,进一步提升了跨电池泛化能力。虽然当前配对  $t$ -检验由于样本量有限尚未达到严格显著性,但研究结果表明该框架在可解释性、稳定性和不确定度量化方面具有显著优势,后续工作将扩展更多工况电池数据并优化动态校准,以期在更大规模应用中实现更加稳健的 RUL 预测。

## 参考文献

- [1] 王帅, 李义婷, 陈黎飞, 等. 基于 IMM-PFF 的锂离子电池剩余寿命预测[J]. 电子学报, 2025, 53(5): 1520-1532.  
WANG SH, LI Y T, CHEN L F, et al. Remaining useful life prediction of lithium-ion batteries based on IMM-PFF [J]. Acta Electronica Sinica, 2025, 53(5): 1520-1532.
- [2] 肖迁, 穆云飞, 焦志鹏, 等. 基于改进 LightGBM 的电动汽车电池剩余使用寿命在线预测[J]. 电工技术学报, 2022, 37(17): 4517-4527.  
XIAO Q, MU Y F, JIAO ZH P, et al. Online remaining useful life prediction of electric vehicle batteries based on improved LightGBM [J]. Transactions of China Electrotechnical Society, 2022, 37(17): 4517-4527.
- [3] 韩茂林, 杨琛, 牛锋杰, 等. 基于特征提取与改进 POA 的光伏阵列故障诊断[J]. 电子测量与仪器学报, 2025, 39(4): 258-269.  
HAN M L, YANG CH, NIU F J, et al. Fault diagnosis of photovoltaic arrays based on feature extraction and improved POA [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(4): 258-269.
- [4] 来鑫, 孟正, 韩雪冰, 等. 基于特征电压模型的锂离子电池容量估计与 RUL 预测[J]. 汽车安全与节能学报, 2022, 13(1): 194-201.  
LAI X, MENG ZH, HAN X B, et al. Capacity estimation and RUL prediction of lithium-ion batteries based on characteristic voltage model [J]. Journal of Automotive Safety and Energy, 2022, 13(1): 194-201.

- [ 5 ] 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 SH, DONG J. Review of data-driven state of health estimation methods for lithium-ion batteries [J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 45-59.
- [ 6 ] 李练兵,朱乐,李思佳,等. 基于差分电压和 ICS-Elman 神经网络的锂离子电池剩余使用寿命预测方法[J]. 太阳能学报, 2023, 44(12): 433-443.  
LI L B, ZHU L, LI S J, et al. Remaining useful life prediction of lithium-ion batteries based on differential voltage and ICS-Elman neural network [J]. Acta Energetica Solaris Sinica, 2023, 44(12): 433-443.
- [ 7 ] 夏然,苏春. 基于健康因子和混合 Bi-LSTM-NAR 模型的锂离子电池剩余寿命预测[J]. 中国机械工程, 2024, 35(5): 851-859.  
XIA R, SU CH. Remaining useful life prediction of lithium-ion batteries based on health indicators and hybrid Bi-LSTM-NAR model [J]. China Mechanical Engineering, 2024, 35(5): 851-859.
- [ 8 ] 邹红波,柴延辉,杨钦贺,等. 基于混合 ISSA-LSTM 的锂离子电池剩余使用寿命预测[J]. 电力系统保护与控制, 2023, 51(19): 21-31.  
ZOU H B, CHAI Y H, YANG Q H, et al. Remaining useful life prediction of lithium-ion batteries based on hybrid ISSA-LSTM [J]. Power System Protection and Control, 2023, 51(19): 21-31.
- [ 9 ] 尹杰,刘博,孙国兵,等. 基于迁移学习和降噪自编码器-长短时间记忆的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(1): 289-302.  
YIN J, LIU B, SUN G B, et al. Remaining useful life prediction of lithium-ion batteries based on transfer learning and DAE-LSTM [J]. Transactions of China Electrotechnical Society, 2024, 39(1): 289-302.
- [ 10 ] 莫云,李易,张本鑫,等. 基于权重融合特征重标定网络的运动想象脑电分类[J]. 电子测量与仪器学报, 2025, 39(1): 70-79.  
MO Y, LI Y, ZHANG B X, et al. Motor imagery EEG classification based on weighted feature recalibration network [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(1): 70-79.
- [ 11 ] 张宇波,王有元,黄洞宁,等. 面向变工况条件的锂离子电池寿命退化预测方法[J]. 储能科学与技术, 2023, 12(7): 2238-2245.  
ZHANG Y B, WANG Y Y, HUANG D N, et al. Degradation prediction method of lithium-ion battery life under variable operating conditions [J]. Energy Storage Science and Technology, 2023, 12(7): 2238-2245.
- [ 12 ] 张然,刘天宇,金光. 基于核自构建-高斯过程回归的锂离子电池剩余使用寿命预测[J]. 系统工程与电子技术, 2023, 45(8): 2623-2633.  
ZHANG R, LIU T Y, JIN G. Remaining useful life prediction of lithium-ion batteries based on kernel self-constructing Gaussian process regression [J]. Systems Engineering and Electronics, 2023, 45(8): 2623-2633.
- [ 13 ] 张洪生,尚鑫磊. 基于 DAE-BLS 的锂离子电池剩余使用寿命预测方法[J]. 计算机集成制造系统, 2025, 31(3): 1038-1047.  
ZHANG H SH, SHANG X L. Remaining useful life prediction method of lithium-ion batteries based on DAE-BLS [J]. Computer Integrated Manufacturing Systems, 2025, 31(3): 1038-1047.
- [ 14 ] 徐乐,邓忠伟,谢翌,等. 锂离子电池高精度机理建模、参数辨识与寿命预测研究进展[J]. 机械工程学报, 2022, 58(22): 19-36.  
XU L, DENG ZH W, XIE Y, et al. Review on high-precision mechanism modeling, parameter identification and life prediction of lithium-ion batteries [J]. Journal of Mechanical Engineering, 2022, 58(22): 19-36.
- [ 15 ] 张登攀,兰征,杜怡衡. 基于 PCHIP-VMD 数据分析与 SSA-LSTM 模型的短期风电功率预测[J]. 电子测量与仪器学报, 2025, 39(5): 251-261.  
ZHANG D P, LAN ZH, DU Y H. Short-term wind power forecasting based on PCHIP-VMD data analysis and SSA-LSTM model [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 251-261.
- [ 16 ] 郑文培,周少杰,王颖君,等. 电潜泵剩余使用寿命预测集成学习算法研究[J]. 电子测量与仪器学报, 2025, 39(3): 13-20.  
ZHENG W P, ZHOU SH J, WANG Y J, et al. Research on ensemble learning algorithm for remaining useful life prediction of electric submersible pumps [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3): 13-20.
- [ 17 ] PEREIRA T, RAMALHO A M, SÁ COUTO P, et al. Exploring the effectiveness of the pragmatic intervention programme (PICP) with children with autism spectrum disorder and developmental language disorder: A non-randomised controlled trial[J]. Autism, 2025, 29(3): 726-739.
- [ 18 ] NICOLAIDOU P, STAVRINADIS I, LOUKOU I, et al. The effect of vitamin K supplementation on biochemical markers of bone formation in children and adolescents with cystic fibrosis[J]. European Journal of Pediatrics, 2006, 165(8): 540-545.
- [ 19 ] KRZYSTOLIK M G, STRAUER S F, AIELLO L P, et

al. Reproducibility of macular thickness and volume using Zeiss optical coherence tomography in patients with diabetic macular edema [J]. *Ophthalmology*, 2007, 114(8): 1520-1525.

- [20] ERAZO I, GOLDSMAN D, MEI Y. Cost-efficient fixed-width confidence intervals for the difference of two Bernoulli proportions [J]. *Journal of Simulation*, 2024, 18(5): 726-744.

### 作者简介



**王建秋**, 2014 年于云南师范大学获得硕士学位, 现为乌隆他尼皇家大学博士研究生, 楚雄师范学院讲师, 主要研究方向为电池寿命预测、机器学习。

E-mail: wjq01@cxte.edu.cn

**Wang Jianqiu** received her M. Sc. degree

from Yunnan Normal University in 2014. She is now a Ph. D. candidate at Udon Thani Rajabhat University and a lecturer at Chuxiong Normal University. Her main research interests include battery life prediction and machine learning.



**何永泰**(通信作者), 2011 年于北京理工大学获得博士学位, 现为楚雄师范学院教授, 主要研究方向为光电微能源设计与应用、电池寿命预测、光伏/热太阳能系统应用技术。

E-mail: hyt@cxte.edu.cn

**He Yongtai** (Corresponding author) received his Ph. D. degree from Beijing Institute of Technology in 2011. He is now a professor at Chuxiong Normal University. His main research interests include optoelectronic micro-energy design and applications, battery life prediction, as well as photovoltaic and solar thermal energy system application technologies.