

储能测试与评价



基于集成学习和分位数回归的锂离子电池寿命预测方法

郑立涵¹, 林俊楠¹, 陈 平^{2,3}, 施志聪¹

(¹广东工业大学材料与能源学院, 广东 广州 510006; ²电科电源股份有限公司, 广东 深圳 518000; ³衡阳电科电源股份有限公司, 湖南 衡阳 421000)

摘 要: 锂离子电池寿命的精准预测是保障电池系统安全的关键。针对传统方法依赖复杂特征工程且难以量化预测不确定性的问题, 本研究提出一种融合集成学习与分位数回归的锂离子电池寿命预测框架。该框架以搭载了注意力机制的门控循环单元为基学习器, 结合引导聚集策略与分位数回归机制, 仅需输入经滑动窗口处理的电池容量序列即可完成预测, 避免了复杂的特征提取。通过五种不同容量规格电池退化数据验证表明, 该框架在不同预测步长下均能保持较高的预测准确性, 在 300 次循环的预测步长下, 预测结果的均方根误差、平均绝对百分比误差和平均绝对误差分别低至 0.4097%、0.3246% 和 0.1104%, 显著优于传统点预测模型。与单一模型和基础门控循环单元模型相比, 该模型在所有测试电池上均取得了最优且最稳定的预测性能, 这得益于集成学习策略有效提升了模型的稳定性与泛化能力。在不确定性量化方面, 所提框架生成的预测区间对测试电池的真实容量值均实现了有效覆盖, 覆盖率显著高于对比模型, 证明了其在预测不确定性评估方面的优势。本研究创新性地将集成学习与分位数回归相结合, 在实现高精度点预测的同时输出具有 95% 置信度的预测区间, 从而显著提升了锂离子电池寿命预测的准确性与不确定性量化能力。

关键词: 锂离子电池; 集成学习; 分位数回归; 剩余寿命预测; 门控循环单元

doi: 10.19799/j.cnki.2095-4239.2026.0054

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (2026) 06-2380-12

A framework fusing ensemble learning and quantile regression for lithium-ion battery life prediction

ZHENG Lihan¹, LIN Junnan¹, CHEN Ping^{2,3}, SHI Zhicong¹

(¹Institute of Batteries, School of Materials and Energy, Guangdong University of Technology, Guangzhou 510006, Guangdong, China; ²BST Power (Shenzhen) Limited, Shenzhen 518000, Guangdong, China;

³Hengyang BST Power Limited, Hengyang 421000, Hunan, China)

Abstract: Accurate prediction of lithium-ion battery life is imperative for ensuring the safety of battery systems. Traditional methods rely on complex feature engineering and struggle to quantify prediction uncertainty. To address these limitations, this paper proposes a lithium-ion battery life prediction framework integrating ensemble learning and quantile regression. The proposed framework utilizes a Gated Recurrent Unit (GRU) augmented with an attention mechanism as the fundamental learner. Incorporating a Bootstrap Aggregating strategy and quantile regression, the approach necessitates only battery capacity sequences processed via

收稿日期: 2026-01-19; 修改稿日期: 2026-01-29。

基金项目: 广东省基础与应用基础研究基金联合基金 (2023A1515110792)。

第一作者: 郑立涵 (2000—), 男, 硕士研究生, 研究方向为基于机器学习的锂离子电池寿命预测, E-mail: 15560520693@163.com; 通信作者: 施志聪, 教授, 研究方向为锂离子电池、钠离子电池、金属空气电池等化学电源, E-mail: zhicong@gdut.edu.cn。

引用本文: 郑立涵, 林俊楠, 陈平, 等. 基于集成学习和分位数回归的锂离子电池寿命预测方法[J]. 储能科学与技术, 2026, 15(6): 2380-2391.

Citation: ZHENG Lihan, LIN Junnan, CHEN Ping, et al. A framework fusing ensemble learning and quantile regression for lithium-ion battery life prediction[J]. Energy Storage Science and Technology, 2026, 15(6): 2380-2391.

a sliding window for prediction, thereby eliminating the requirement for complex feature extraction. Validation on degradation data from five lithium-ion batteries with varying capacity specifications demonstrates that the proposed framework maintains high prediction accuracy across different prediction horizons. At a prediction horizon of 300 cycles, the Root Mean Square Error, Mean Absolute Percentage Error, and Mean Absolute Error are as low as 0.4097%, 0.3246%, and 0.1104%, respectively, significantly outperforming traditional point prediction models. A comparison of the proposed framework with single models and the standard GRU model reveals that the former attains superior and more stable prediction performance across all tested batteries. This enhancement can be attributed to the ensemble learning strategy, which augments model robustness and generalization. In the context of uncertainty quantification, the prediction intervals generated by the framework effectively encompass the actual capacity values of the test batteries. Furthermore, the coverage rates of the framework are notably higher than those of comparative models, underscoring its superiority in uncertainty assessment. This study innovatively combines ensemble learning with quantile regression, enabling high-precision point predictions while generating 95% confidence prediction intervals. Consequently, this combination significantly improves the accuracy and uncertainty quantification capability of lithium-ion battery life prediction.

Keywords: lithium-ion battery; ensemble learning; quantile regression; remaining useful life prediction; gated recurrent unit

随着全球能源转型与可持续发展战略的推进, 锂离子电池在电动汽车、便携式电子设备和储能系统等领域得到了广泛应用^[1-2]。然而, 随着使用时间的增长, 锂离子电池内部复杂的电化学环境会发生变化, 如活性材料损失、固体电解质界面膜(solid electrolyte interface, SEI)增厚、内阻增大等^[3-4]。这些变化可能增加充放电过程中的热失控风险, 甚至引发起火、爆炸等安全事故, 危及人的生命财产安全^[5-6]。锂离子电池的剩余使用寿命(remain useful life, RUL)是指电池在特定使用条件下, 从当前状态到电池失效阈值所剩余的时间或充放电循环次数。剩余使用寿命越低, 电池内部的电化学变化越复杂, 发生安全风险的概率也就越大^[7-8]。如果电池的实际RUL已经很短, 但用户或管理系统未能及时发现并采取相应措施, 那么电池在继续使用过程中发生安全事故的概率将大大增加^[9]。因此, 对锂离子电池寿命进行准确预测, 不仅有助于了解电池当前的性能状态, 还能为电池的安全管理提供重要依据^[10-11]。

目前主要有两种锂离子电池寿命预测方法, 即基于模型的方法和基于数据驱动的方法。近年来, 随着人工智能技术的快速发展和数据友好的大环境

下, 数据驱动的锂离子电池寿命预测方法逐渐成为中坚力量^[12]。这些方法能够自动地从大量数据中提取特征并构建预测模型, 无需人工设计复杂的物理模型^[13-14]。与传统的模型预测方法相比, 数据驱动方法具有更高的适应性和预测精度, 可以节省大量的时间和金钱成本, 受到了广泛的关注和应用^[15-16]。基于数据驱动的锂离子电池寿命预测方法主要依赖于众多经典机器学习模型, 包括支持向量回归、高斯过程回归和神经网络等。Chen等^[17]提出了一种混合数据驱动的锂离子电池寿命预测方法, 利用容量和等时间间隔的放电电压差作为健康指标, 通过集成经验模态分解进行信号预处理和特征提取, 同时利用遗传算法对支持向量回归的关键参数进行优化, 实现了准确的RUL预测。Jia等^[18]从锂离子电池充放电过程中提取了间接健康指标, 以反映电池容量的下降过程。通过灰色关联分析法选择了相关性高的指标作为预测输入, 通过高斯过程回归与概率预测相结合的方法实现了短期寿命预测。Gomez等^[19]提出了一个基于双向长短期记忆编码-解码层的transformer模型, 通过应用树结构贝叶斯优化算法对模型的超参数进行调优, 采用双重膝点概念来确定训练起始点, 从而提高了预测准确性

和稳定性。实验使用了九个锂离子电池验证所提模型在寿命预测方面的有效性和鲁棒性。

尽管数据驱动方法在锂离子电池寿命预测方面取得了显著进展，但目前大部分锂离子电池寿命预测结果通常是单一点预测，难以量化预测结果的置信度。而在区间预测研究方面，传统机器学习模型如高斯过程回归虽能提供概率输出，但依赖严格的数据假设，且对数据噪声和稀疏性敏感，导致在实际应用中不确定性量化不足^[20]。监督学习模型易受数据稀缺影响，出现性能下降或过拟合问题，限制了预测区间的可靠性^[21]。而集成学习通过构建多模型聚合机制，有效提升预测鲁棒性和泛化能力，恰好弥补了传统单模型对数据质量的过度依赖^[22]，分位数回归能够直接输出不同置信水平下的预测区间，无需对数据分布进行强假设，特别适合处理电池退化数据中的稀疏性问题。基于此，本研究提出一种新颖的锂离子电池寿命预测框架，该框架融合了集成学习与分位数回归的优势。框架选用搭载了注意力机制的门控循环单元（attention-gated recurrent unit, Attention-GRU）作为基学习器。该框架仅需输入经滑动窗口算法预处理的电池容量退化时序数据，从而避免了复杂的人工特征提取。模型训练采用引导聚集算法（Bagging），通过对数据集进行自助采样生成若干子数据集，并行训练多个 Attention-GRU 基学习器后使用加权平均对各基学习器的预测结果进行融合，增强模型的泛化性能。模型的输出层使用分位数回归算法，配置了 3 个独立的输出头，分别对应低分位数（ $\tau=0.025$ ）、中位数（ $\tau=0.5$ ）和高分位数（ $\tau=0.975$ ），以输出预测区间。模型的最终输出包括 95% 置信度的预测区间和中位数点预测。模型的预测精确性在五个不同额定容量的锂离子电池数据集上得到了验证，结果表明所提框架能够实现准确的锂离子电池寿命区间预测。

1 数据处理

1.1 锂离子电池数据集介绍

本研究采用的锂离子电池数据集包含 56 节电池的充放电循环数据。电池的详细规格参数见表 1。所用电池为湖南衡阳电科电源有限公司提供的商用 26650 圆柱形磷酸铁锂电池，正极为磷酸铁锂，负极为石墨，额定容量分别为 3.0、3.4、3.6、3.8 和

4.0 Ah，平均循环寿命分别为 3048、2738、3676、3468 和 1957 次，工作电压范围为 2.0~3.6 V。其中，3.0 Ah 的电池数据暂未循环至寿命终点，目的是检验模型在寿命中期的预测精度。

表 1 五种不同额定容量的锂离子电池详细规格参数
Table 1 Detailed specifications of the five tested lithium-ion batteries with different rated capacities

额定容量/Ah	数量/个	平均循环圈数
3.0	7	3048
3.4	9	2738
3.6	15	3676
3.8	11	3468
4.0	14	1957

锂离子电池的寿命通常由其在当前循环下的现存容量来衡量，因此要重点关注锂离子电池的容量衰减趋势。五种电池的容量衰减趋势如图 1 所示，可以观察到，随着循环次数增加电池容量呈现复杂的非线性变化，五种电池在循环初期均表现出容量上升现象。这主要是因为石墨负极在深度放电条件下层间距扩大，有利于锂离子扩散，暂时提升了电池容量^[23]。在循环中期，电池的容量衰减趋势都相对接近且稳定。在寿命后期，SEI 膜增厚导致电池内阻增加，以及更多的活性锂损失引发电池容量快速衰减，这种显著的非线性变化增大了准确预测寿命的难度。




图 1 五种不同额定容量的锂离子电池容量衰减趋势图
Fig. 1 Capacity degradation trends of the five lithium-ion batteries with different rated capacities

1.2 滑动窗口算法

滑动窗口算法是时序预测中常用的一种数据处理算法，其核心思想是将连续的时间序列数据转化为模型可学习的历史样本-未来标签对，动态截取局部时序片段捕捉数据的短期依赖关系，为后续模

型训练和预测提供结构化输入^[24]。

本研究采用滑动窗口算法分别对每个电池的容量退化序列进行处理,构建监督学习任务的训练样本与标签,算法原理如图2所示。电池容量退化数据为随充放电循环递推的时间序列 $\{C_1, C_2, C_3 \dots C_{n-1}, C_n\}$,其中 C_i 对应第 i 个循环结束后电池的容量。设定滑动窗口大小为 W (图中以 $W=6$ 为例),沿容量序列逐次平移截取连续子序列,每个样本由窗口内 W 个连续历史容量 $[C_i, C_{i+1} \dots C_{i+W-2}, C_{i+W-1}]$ 构成输入特征,窗口右侧相邻的下一个循环容量 C_{i+W} 作为预测目标标签。通过上述滑动窗口遍历容量序列,共生成 $N-W$ 组样本-标签对,实现了长时序数据到监督学习短序列预测任务的转化,为模型训练提供输入。预测阶段可采用窗口递归预测策略:以当前窗口内最新 W 个容量值为

输入,预测下一循环容量,随后用预测值更新窗口,剔除最旧数据,逐步外推至失效阈值。

本研究在对五种不同额定容量规格的电池退化数据完成数据清洗的基础上,仅采用滑动窗口算法进行样本-标签对划分,简化了烦琐的数据特征处理流程。对于锂离子电池容量退化数据,较小的滑动窗口设置有助于模型精确地捕捉容量点之间的关系,但在反映长期退化趋势方面可能信息不足,较大的窗口能够使模型学习到更长的容量退化依赖关系,但容易引入噪声或导致过拟合^[25]。因此,窗口大小的选择需在局部敏感性与长期趋势学习之间取得平衡,通常作为超参数,依据验证集的性能表现进行优化确定。各电池的容量退化数据独立执行窗口划分操作,以规避不同电池个体间时序特征的交叉混叠风险,确保时序模式挖掘的准确性。




图2 滑动窗口算法示意图

Fig. 2 Schematic diagram of the sliding window algorithm

2 模型构建

2.1 Attention-GRU 基学习器

2.1.1 门控循环单元

门控循环单元(gated recurrent unit, GRU)可通过重置门与更新门两个核心门控机制,在降低模型复杂度的同时保持对时序特征的记忆能力,其单元结构如图3所示。主要的计算过程如下:接收 h_{t-1} (历史信息)和 x_t (当前输入);通过重置门判断是否重置历史信息,生成 r_t ;通过更新门判断新

旧信息的权重分配,生成 z_t ;基于重置后的历史信息 and 当前输入,生成候选新状态 $\tilde{h}_t$;用更新门融合旧状态和候选新状态,得到当前隐藏状态 h_t ,传递给下一层或用于序列预测。

电池性能衰退是一个随时间逐渐累积的过程。其容量不仅受当前运行条件影响,也与先前的使用历史密切相关。GRU能够从输入的容量序列中,学习并记忆退化轨迹中的有效历史信息,为模型后续的关键特征筛选提供坚实的基础。因此,本框架选用GRU作为时序特征提取的核心组件。




图3 GRU的单元结构

Fig. 3 Schematic diagram of gated recurrent unit

2.1.2 注意力机制

注意力机制的基本思想是为输入数据中的每个部分分配一个权重，表示其对当前任务的重要程度，模型据此加权整合信息，使得模型可以聚焦于与当前预测任务更相关的信息^[26]。

注意力机制可以描述为将查询向量和一系列键向量映射到输出的过程，输出向量是根据查询和键计算的权重值乘上值向量得到。注意力的计算如式(1)所示。首先，将查询(Query, Q)向量和键(Key, K)向量相乘以获得表示不同位置之间相关性的分数。为了获得更稳定的梯度，将其除以 $\sqrt{d}$ ， d 为键的维度。最后在经过softmax函数处理后，乘以值(Value, V)获得最终值。其优点是能够找到不同序列位置之间的依赖关系，这意味着捕获长期数据之间的交互关系的能力更强。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right) \quad (1)$$

其中，查询 $Q \in R^{n \times d}$ 、键 $K \in R^{m \times d}$ 、值 $V \in R^{m \times v}$ 表示查询、键、值的矩阵； d 表示键的维度。

在电池容量衰减的过程中，某些循环周期往往包含更强的预测信号。在框架中引入注意力机制能自适应地赋予这些关键阶段更高的权重，使模型更敏锐地捕捉与寿命终结密切相关的退化特征，从而增强预测的准确性与泛化能力。

2.1.3 分位数回归

分位数回归是一种统计建模技术，用于估计条件分位数函数。分位数回归能够全面描述因变量条件分布的全貌，特别适用于估计时间序列预测的不确定性^[27]。对于给定的分位数 τ ($0 < \tau < 1$)，分位数回归模型旨在最小化损失函数，如式(2)所示：

$$L_\tau(y, \hat{y}) = \sum_{i: y_i \geq \hat{y}_i} \tau |y_i - \hat{y}_i| + \sum_{i: y_i < \hat{y}_i} (1 - \tau) |y_i - \hat{y}_i| \quad (2)$$

其中， y_i 为真实值， $\hat{y}_i$ 为预测值。当 $\tau=0.5$ 时，分位数回归退化为中位数回归，对异常值具有强鲁棒性；而当 τ 取极端值时，可捕获分布尾部的特性，为区间预测提供理论基础。

锂离子电池容量退化过程受工作温度、充放电速率等多因素影响，呈现显著的不确定性和非线性特征^[28]。传统点预测方法仅输出单一寿命估计值，无法量化预测结果的可信度。本框架使用的分位数回归通过同时估计多个条件分位数（本研究 τ 取 0.025、0.5 和 0.975），构建具有置信水平的预测区间，可直观反映锂离子电池容量预测的不确定性。

本研究的模型采用融合注意力机制的门控循环单元，并在其输出端嵌入分位数回归机制，构建多输出头预测架构，以此构成 Attention-GRU 基学习器，模型结构如图4所示。首先在输入层对滑动窗口截取的锂离子电池容量退化数据进行标准化预处理，使用 GRU 进行初步时序特征提取后经过 Dropout 层降低模型过拟合风险，随后输入至注意力机制层，在该层中，时序特征序列被用作注意力计算的基础，通过三个独立的线性变换层，将该特征序列分别映射为 Q 、 K 与 V 矩阵，继而通过缩放点积注意力公式计算上下文权重，聚焦容量退化的关键阶段，生成加权的特征表示。该加权序列随后通过第二层 GRU，以进一步整合加权后的时序依赖关系，完成深层时序特征提取。最后，基学习器输出的高维特征通过三个独立的分位数回归输出层并行计算低分位数 ($\tau=0.025$)、中位数 ($\tau=0.5$) 和高分位数 ($\tau=0.975$) 对应的预测值后输出 95% 置信水平的预测区间和点预测结果。

2.2 集成学习

传统单一模型易受容量数据中噪声干扰或局部突变的影响，而集成学习通过协同整合多个基学习器的预测结果，能够有效提升模型的泛化性能与稳定性，是一种适用于复杂预测任务的机器学习算法。其核心优势在于通过群体决策机制降低单一模型的不确定性，尤其适用于锂离子电池寿命预测这类受多因素耦合影响、具有显著非线性特征的应用场景^[29-30]。

集成学习主要有三种经典实现方式，包括引导聚集 (Bagging)、提升 (Boosting) 和堆叠 (Stacking) 等^[31]。本研究采用 Bagging 算法作为集成学习的具体实现方法。Bagging 算法通过自助采




图4 Attention-GRU基学习器的模型结构
Fig. 4 Model structure of the Attention-GRU base learner

样技术从原始数据集中生成多个训练子集，并基于每个子集独立训练基学习器，最终通过加权平均策略融合各模型的输出，算法示意图见图5。针对锂离子电池容量数据的时序特性，本框架创新性地以单个电池的容量退化数据作为自助采样的基本单元。这种设计充分考虑了电池数据的时序连续性特征，避免了因跨电池抽样可能引起的时序模式破坏问题。具体而言，对每节电池经过滑动窗口提取的容量序列独立进行有放回抽样，生成多个训练子集，每个子集用于训练一个Attention-GRU基学习器。在预测阶段，基学习器对同一输入样本分别输出三个分位数的预测值，通过加权平均法融合得到最终的预测结果，集成学习与分位数回归的结合，能够更全面地捕捉电池退化过程中的多样化模式，通过群体决策机制有效提升了预测区间的稳定性和准确性。




图5 Bagging算法示意图
Fig. 5 Schematic diagram of Bagging algorithm

2.3 模型参数

本研究通过设置验证集进行超参数优化后确定了最终模型参数配置。现有的锂离子电池寿命预测研究的滑动窗口大小设置范围大多在12~50，因此将12~50设置为超参数优化的搜索区间^[32-33]。五种不同额定容量电池的最佳滑动窗口大小设置如表2所示。在模型结构方面，GRU每层隐藏单元维度设置为64，注意力机制维度为64，Dropout层丢弃率为0.2。训练策略采用Adam优化器，初始学习率设置为0.001，配合学习率调度策略动态优化训练过程，批次大小设置为64，最大训练轮数100，并引入早停机制防止过拟合。集成学习训练的子模型数量设置为10。该模型架构基于PyTorch框架构建，损失函数采用分位数损失函数 L_τ 。

表2 五种不同额定容量电池的最佳滑动窗口大小设置
Table 2 The optimal sliding window size settings for five batteries with different rated capacities

容量规格/Ah	预测步数	窗口大小
3.0	300	16
	200	12
	100	32
3.4	300	16
	200	12
	100	12
3.6	300	16
	200	16
	100	16
3.8	300	20
	200	20
	100	24
4.0	300	20
	200	12
	100	16

3 结果与分析

3.1 预测性能评价指标

为评估模型对锂离子电池寿命的预测精度，采用平均绝对误差（mean absolute error, MAE）、平均绝对百分比误差（mean absolute percentage error, MAPE）和均方根误差（root mean square error, RMSE）作为评估指标。这三个指标的计算公式如下：

$$\text{MAPE} = 100\% \times \frac{1}{N} \sum_{i=1}^N \left| \frac{\tilde{C}_i - C_i}{C_i} \right| \quad (3)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\tilde{C}_i - C_i| \quad (4)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\tilde{C}_i - C_i)^2} \quad (5)$$

其中, N 代表模型的预测步长, $\tilde{C}_i$ 和 C_i 分别表示锂离子电池容量的预测值和实际值。

3.2 锂离子电池容量预测结果与分析

锂离子电池在接近失效阈值(通常为额定容量的80%)时,热失控风险会显著增加。因此,模型预测需重点关注阈值前的容量变化趋势,以实现有效的安全预警。在实验设计方面,从五种不同容量的电池数据中分别选取其中一个电池的循环末段数据作为测试集,其余数据作为训练集。模型通过学习训练样本-标签对的映射规律后,采用滑动窗口递推机制实现多步未知预测:以当前窗口内最新的 W 个历史容量为输入预测下一个循环容量,再将预测值替换窗口中最旧的容量数据以更新滑动窗口,重复此过程直至预测容量降至电池容量失效阈值时结束预测。

图6展示了五种不同容量规格的锂离子电池在循环末期300次循环的容量预测结果,其中(a)~(e)分别对应额定容量为3.0、3.4、3.6、3.8和4.0 Ah的电池样本。模型输出的点预测曲线与真实容量值呈现出高度一致性,准确建模了不同规格电池的容量衰减轨迹。而分位数回归生成的95%置信度预测区间代表了未来容量值可能出现的范围,有效覆盖了绝大多数真实值,弥补了点预测可能存在的偏差。同时,本研究专门采用未循环至寿命终点的3.0 Ah电池数据验证模型在电池寿命中期的预测能力,模拟了实际应用中常面临的数据不完整场景,即电池尚未完成全生命循环测试。从图6(a)可以发现,即使电池处于寿命中期,模型仍能很好地对容量衰减趋势进行精确预测,点预测结果与真实值高度吻合,预测区间保持对真实数据的有效覆盖。这表明该模型能够捕捉不同衰减阶段的容量退化规律,具备从局部数据中提取普遍特征的能力,降低了模型对完整电池循环数据的依赖,具有较好的模型泛化能力。分析结果表明,该方法不仅适用于寿命末期的剧烈衰减阶段,在电池健康管理的早期阶段同样具有较高的预测精度,泛化性能好。




图6 五种容量规格锂离子电池末尾300次循环的容量预测结果 (a) 3.0 Ah; (b) 3.4 Ah; (c) 3.6 Ah; (d) 3.8 Ah; (e) 4.0 Ah
Fig. 6 Capacity prediction results for the last 300 cycles of the five lithium-ion batteries with different capacity specifications: (a) 3.0 Ah; (b) 3.4 Ah; (c) 3.6 Ah; (d) 3.8 Ah; (e) 4.0 Ah

为充分验证本研究提出的分位数回归的优越性, 本工作设计了对比实验, 保持 Attention-GRU 基学习器的整体结构不变, 将分位数回归输出层替换为相同结构的线性回归层, 损失函数由分位数损失函数替换为均方误差损失函数, 构建经典点预测模型作为对照。实验结果如图 7 所示, 可以看出, 点预测模型虽然能够捕捉容量退化的下降趋势, 但其预测结果存在明显局限性。首先, 点预测仅提供单一的容量估计值, 无法量化预测不确定性。其次, 在预测准确性方面, 点预测结果与真实值的偏

差大于分位数回归模型的中位数点预测, 特别是在容量衰减速率增大的阶段。这种性能差异可能源于两方面机制, 一方面, 分位数回归采用的分位数损失函数对异常值具有更强的鲁棒性, 而点预测采用的均方误差损失易受极端值影响; 另一方面, 分位数回归通过同时优化多个分位数目标, 使模型能够学习更丰富的条件分布信息, 从而提升中点预测的稳定性。相比之下, 分位数回归模型通过预测区间有效捕捉了真实值的波动范围, 展现出更全面的预测效能。




图7 五种容量规格锂离子电池的末尾300次循环容量的点预测结果 (a) 3.0 Ah; (b) 3.4 Ah; (c) 3.6 Ah; (d) 3.8 Ah; (e) 4.0Ah

Fig. 7 Point prediction results of the capacity for the last 300 cycles of the five lithium-ion batteries with different capacity specifications: (a) 3.0 Ah; (b) 3.4 Ah; (c) 3.6 Ah; (d) 3.8 Ah; (e) 4.0 Ah

表3展示了五种不同容量锂离子电池在不同预测步长下的预测误差对比结果。结果表明, 五种容量规格电池的预测误差均维持在较低水平, 验证了所提框架在不同容量电池类型上的良好泛化能力。从整体趋势看, 随着预测步长从300次循环缩短至100次循环, 大多数电池的预测精度显著提升, 符合时序预测的基本规律。3.6 Ah电池在200步预测时出现误差略高于300步的情况, 这可能是由于电池在该循环区间的容量波动大, 影响模型预测结

果。随着预测步长缩短至100步, RMSE由0.4588%迅速回落至0.3621%, 表明模型可通过近期数据有效修正预测偏差。电池个体衰减特性对模型预测性能影响也存在明显差异。3.6 Ah电池因具有最长的循环寿命, 容量衰减较为平缓, 在各个步长下均表现出精确的预测精度; 而4.0 Ah电池由于循环寿命最短, 容量衰减最为剧烈, 其预测误差相对较高。这些结果充分证明了本研究提出的预测框架不仅在点预测精度上显著优于传统方法, 同时展

现出良好的预测步长适应能力。

3.3 不同模型的容量预测结果与分析

为全面评估本研究使用的集成学习框架性能优势，选取了三种典型模型进行对比分析：集成学习 Attention-GRU 模型（ensemble attention-GRU）、Attention-GRU 单模型和标准 GRU 模型。为确保结论的可靠性，在控制其他参数一致的条件下，每种模型均进行了 5 次独立重复实验，预测步长选择为 300 步，预测结果评价指标取五次重复实验结果的平均值。图 8 和表 4 展示了三种模型的预测结果对比。结合图 3 分析，从稳定性看 Ensemble Attention-GRU 模型在各项对比中均表现最优。模型的五次重复预测误差均接近 0 误差线，且实验结果波动最小。观察各个模型的预测误差变化趋势可以发现，预测初期的误差较小，随后逐渐增大并在预测中期时误差达到峰值后出现回落。该趋势形成的原因可能是预测前期采用基于真实值的窗口递归预测，且容量衰减相对平缓，模型能够保持高预测精度；进入预测中期，容量衰减加快且训练数据未覆盖该阶段，导致预测误差增大；而在预测后期，模型适应了中期经历的快速容量变化，同时注意力

表 3 不同预测步数下的容量预测结果评价指标
Table 3 Evaluation metrics for capacity prediction results under different prediction steps

容量规格	预测步数	RMSE/%	MAE/%	MAPE/%
3.0 Ah	300	0.2232	0.1454	0.0565
	200	0.2133	0.2054	0.0797
	100	0.1481	0.1299	0.0505
	300（点预测）	0.7148	0.6773	0.2624
3.4 Ah	300	0.4389	0.3543	0.1287
	200	0.4175	0.3936	0.1431
	100	0.3867	0.3505	0.1284
	300（点预测）	1.1970	1.0133	0.3684
3.6 Ah	300	0.4097	0.3246	0.1104
	200	0.4588	0.3703	0.1265
	100	0.3621	0.2686	0.0922
	300（点预测）	1.4759	1.2883	0.4364
3.8 Ah	300	1.6849	1.4379	0.4689
	200	1.0053	0.8894	0.2902
	100	0.8333	0.6242	0.2066
	300（点预测）	2.1528	1.8822	0.5271
4.0 Ah	300	2.7344	2.3550	0.7018
	200	1.5142	1.3633	0.4109
	100	0.9617	0.8055	0.2494
	300（点预测）	4.9236	3.6905	1.1215




图 8 三种模型的锂离子电池容量预测误差对比图 (a) 3.0 Ah; (b) 3.4 Ah; (c) 3.6 Ah; (d) 3.8 Ah; (e) 4.0 Ah
Fig. 8 Comparison of capacity prediction errors of the three models for lithium-ion batteries: (a) 3.0 Ah; (b) 3.4 Ah; (c) 3.6 Ah; (d) 3.8 Ah; (e) 4.0 Ah

机制对容量急剧衰减趋势具有更好的捕捉能力，因此预测精度有所回升。标准 GRU 模型因为没有具备注意力机制导致误差变化幅度大且不具备规律性，侧面印证了注意力机制在捕捉强非线性衰减动态中的关键作用。模型在 4.0 Ah 测试集的预测误差变化趋势则明显不同，呈现出逐渐增大趋势，这主要是由于该电池循环寿命相对较短，容量拐点出现较早且下降率快，模型在进行预测时误差逐渐累积导致误差持续增大。从预测精度看，由表 4 可得，该模型在五种不同电池容量规格下的 RMSE、MAE 和 MAPE 指标均显著优于其他两种对照模型。这得益于集成学习通过 Bagging 策略降低了模型方差，多个基学习器的预测平均有效提升了稳定性和精确度。Attention-GRU 单模型虽然引入了注意力机制以聚焦关键退化阶段，在多数情况下其预测结果评价指标优于标准 GRU，但其预测结果在不同次实验间波动较大。这主要源于其作为单一模型，易收敛至不同的局部最优解，导致预测性能不稳定。标准 GRU 模型的预测误差普遍较高，且在长期预测中呈现明显的误差累积趋势，这反映了其长期预测能力不足。

表 4 不同模型的容量预测结果评价指标				
Table 4 Evaluation metrics of capacity prediction results for different models.				
容量规格	模型	RMSE	MAE	MAPE
3.0 Ah	Ensemble Attention-GRU	0.4304%	0.3580%	0.1350%
	Attention-GRU	0.6173%	0.5797%	0.2023%
	GRU	0.6437%	0.5929%	0.2299%
3.4 Ah	Ensemble Attention-GRU	0.9572%	0.8040%	0.2914%
	Attention-GRU	2.0195%	1.7758%	0.6434%
	GRU	2.0372%	1.8420%	0.6682%
3.6 Ah	Ensemble Attention-GRU	0.8026%	0.6617%	0.2250%
	Attention-GRU	3.0603%	2.5845%	0.8792%
	GRU	2.1034%	1.8470%	0.6286%
3.8 Ah	Ensemble Attention-GRU	1.9866%	1.7452%	0.5670%
	Attention-GRU	2.3166%	2.0281%	0.6601%
	GRU	3.2249%	2.8704%	0.9367%
4.0 Ah	Ensemble Attention-GRU	5.3816%	4.0879%	1.2401%
	Attention-GRU	7.3177%	5.5163%	1.6764%
	GRU	7.6175%	6.0890%	1.8430%

为深入评估模型在量化预测不确定性方面的性能，图9对比了三种模型所输出的95%置信度预测区间的覆盖率。覆盖率反映了模型预测区间对真实容量值的实际覆盖能力，是衡量分位数回归框架有效性的核心指标。从图9可以直观看出，Ensemble Attention-GRU 模型在所有电池容量下均取得了最高的预测区间覆盖率，表明所构建的预测区间能够很好地覆盖真实容量的波动范围。Attention-GRU 单模型的覆盖率次之，这是因为其单模型估计的方差较高，导致覆盖率不及集成模型。相比之下，标准 GRU 模型的覆盖率表现最不理想，普遍较低，无法有效对容量预测的不确定性进行量化。综合分析表明，本研究提出的集成框架通过注意力机制与集成学习的协同作用，在保持预测精度的同时显著提升了模型稳定性。




图9 三种模型的预测区间覆盖率对比图
Fig. 9 Comparison of prediction interval coverage rates by the three models

4 结 论

本研究提出了一种基于集成学习与分位数回归的锂离子电池寿命预测框架。该框架以 Attention-GRU 作为基学习器，结合 Bagging 集成策略与分位数回归机制，创新性地通过分位数回归生成 95% 置信度的预测区间量化不确定性，同时实现准确的电池容量点预测。模型输入仅需经滑动窗口算法预处理的电池容量退化数据，简化了特征提取流程。在五种不同容量规格锂离子电池上的测试结果表明，所提框架在不同预测步长下均保持较高的预测准确性，且点预测精度和区间预测可靠性均优于传统方法。该框架为电池安全预警与寿命评估提供了有效的技术支撑，未来的研究工作将重点探索框架

在动态工况下的适应性,并拓展至电池全生命周期容量衰减监测应用。

参考文献

- [1] HUANG J Q, SHEN Z C, ROBERTSON S J, et al. Fluorine grafted gel polymer electrolyte by *in situ* construction for high-voltage lithium metal batteries[J]. Chemical Engineering Journal, 2023, 475: 145802. DOI:10.1016/j.cej.2023.145802.
- [2] XIE X T, CHEN J B, CHEN X Y, et al. Exploring the effect of lithium halide artificial SEI on the electrochemical performance of lithium metal batteries[J]. Journal of Electroanalytical Chemistry, 2023, 949: 117862. DOI:10.1016/j.jelechem.2023.117862.
- [3] LIN Y H, CHEN J H, ZHU J L, et al. *In-situ* construction of tetraethylene glycol diacrylate based gel polymer electrolyte for long lifespan lithium metal batteries[J]. Surfaces and Interfaces, 2023, 37: 102737. DOI:10.1016/j.surfin.2023.102737.
- [4] SHEN Z C, ZHONG J W, JIANG S Y, et al. Polyacrylonitrile porous membrane-based gel polymer electrolyte by *in situ* free-radical polymerization for stable Li metal batteries[J]. ACS Applied Materials & Interfaces, 2022, 14(36): 41022-41036. DOI: 10.1021/acsami.2c11397.
- [5] CHEN J B, LI D D, LIN K J, et al. Building a stable artificial solid electrolyte interphase on lithium metal anodes toward long-life Li-O₂ batteries[J]. Journal of Power Sources, 2022, 540: 231603. DOI:10.1016/j.jpowsour.2022.231603.
- [6] SHEN Z C, HUANG J Q, XIE Y, et al. Solid electrolyte interphase on lithium metal anodes[J]. ChemSusChem, 2024, 17(11): e202301777. DOI:10.1002/cssc.202301777.
- [7] PANG X X, ZHONG S, WANG Y L, et al. A review on the prediction of health state and serving life of lithium-ion batteries [J]. The Chemical Record, 2022, 22(10): e202200131. DOI: 10.1002/tcr.202200131.
- [8] CHEN D Q, ZHOU X Z. AttMoE: Attention with Mixture of Experts for remaining useful life prediction of lithium-ion batteries[J]. Journal of Energy Storage, 2024, 84: 110780. DOI: 10.1016/j.est.2024.110780.
- [9] CAI N, QUE X P, ZHANG X, et al. A deep learning framework for the joint prediction of the SOH and RUL of lithium-ion batteries based on bimodal images[J]. Energy, 2024, 302: 131700. DOI: 10.1016/j.energy.2024.131700.
- [10] EKBERG J, SRIDHARAN N V, KARIM R, et al. State estimation and remaining useful life prediction for lithium-ion batteries[J]. Cell Reports Physical Science, 2025, 6(10): 102854. DOI: 10.1016/j.xcrp.2025.102854.
- [11] SHI Z L, IBRAHIM A W, XU J Z, et al. Enhanced remaining useful life prediction of lithium-ion battery based on a dual attention hybrid data-driven method[J]. Scientific Reports, 2026, 16: 1303. DOI:10.1038/s41598-025-30849-x.
- [12] LUO K, CHEN X, ZHENG H R, et al. A review of deep learning approach to predicting the state of health and state of charge of lithium-ion batteries[J]. Journal of Energy Chemistry, 2022, 74: 159-173. DOI:10.1016/j.jechem.2022.06.049.
- [13] XIE Y, LUO K, ZHENG L H, et al. A state of health estimation method for lithium-ion batteries based on initial charging segment and Gated Recurrent Unit neural network[J]. Journal of Power Sources, 2025, 638: 236607. DOI:10.1016/j.jpowsour.2025.236607.
- [14] ALSUWIAN T, ANSARI S, AMMIRUL ATIQI MOHD ZAINURI M, et al. A review of expert hybrid and co-estimation techniques for SOH and RUL estimation in battery management system with electric vehicle application[J]. Expert Systems with Applications, 2024, 246: 123123. DOI:10.1016/j.eswa.2023.123123.
- [15] LI X J, YU D, SØREN BYG V, et al. The development of machine learning-based remaining useful life prediction for lithium-ion batteries[J]. Journal of Energy Chemistry, 2023, 82: 103-121. DOI:10.1016/j.jechem.2023.03.026.
- [16] LI C F, YANG L, LI Q, et al. SOH estimation method for lithium-ion batteries based on an improved equivalent circuit model *via* electrochemical impedance spectroscopy[J]. Journal of Energy Storage, 2024, 86: 111167. DOI:10.1016/j.est.2024.111167.
- [17] CHEN L, 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. DOI:10.1016/j.neucom.2020.07.081.
- [18] JIA J F, LIANG J Y, SHI Y H, et al. SOH and RUL prediction of lithium-ion batteries based on Gaussian process regression with indirect health indicators[J]. Energies, 2020, 13(2): 1-20.
- [19] GOMEZ W, WANG F K, CHOU J H. Li-ion battery capacity prediction using improved temporal fusion transformer model[J]. Energy, 2024, 296: 131114. DOI:10.1016/j.energy.2024.131114.
- [20] WANG L, QIU Y, YUAN W C, et al. Next-generation battery safety management: Machine learning assisted life-time prediction and performance enhancement[J]. Journal of Energy Chemistry, 2025, 109: 726-739. DOI:10.1016/j.jechem.2025.05.065.
- [21] QIU Y, ZHANG X, TIAN Y, et al. Machine learning promotes the development of all-solid-state batteries[J]. Chinese Journal of Structural Chemistry, 2023, 42(9): 100118. DOI: 10.1016/j.cjsc.2023.100118.
- [22] CHEN K, LUO Y, LONG Z, et al. Battery state of health estimation using deep transfer learning on short-term charging data[J]. Measurement, 2025, 256: 118233. DOI: 10.1016/j.measurement.2025.118233.
- [23] GUO J, LI Y Q, MENG J H, et al. Understanding the mechanism of capacity increase during early cycling of commercial NMC/graphite lithium-ion batteries[J]. Journal of Energy Chemistry, 2022, 74: 34-44. DOI:10.1016/j.jechem.2022.07.005.
- [24] ANSARI S, AYOB A, HOSSAIN LIPU M S, et al. Optimized data-driven approach for remaining useful life prediction of Lithium-ion batteries based on sliding window and systematic sampling[J]. Journal of Energy Storage, 2023, 73: 109198. DOI: 10.1016/j.est.2023.109198.
- [25] WANG F K, AMOGNE Z E, CHOU J H, et al. Online remaining useful life prediction of lithium-ion batteries using bidirectional long short-term memory with attention mechanism[J]. Energy,

- 2022, 254: 124344. DOI:10.1016/j.energy.2022.124344.
- [26] LUO K, ZHENG H R, SHI Z C. A simple feature extraction method for estimating the whole life cycle state of health of lithium-ion batteries using transformer-based neural network[J]. Journal of Power Sources, 2023, 576: 233139. DOI: 10.1016/j.jpowsour.2023.233139.
- [27] HU J M, TANG J W, LIU Z. A novel time series probabilistic prediction approach based on the monotone quantile regression neural network[J]. Information Sciences, 2024, 654: 119844. DOI: 10.1016/j.ins.2023.119844.
- [28] TIAN Y, DONG Q Y, TIAN J D, et al. Capacity estimation of lithium-ion batteries based on optimized charging voltage section and virtual sample generation[J]. Applied Energy, 2023, 332: 120516. DOI:10.1016/j.apenergy.2022.120516.
- [29] TONG Z M, MIAO J Z, MAO J L, et al. Prediction of Li-ion battery capacity degradation considering polarization recovery with a hybrid ensemble learning model[J]. Energy Storage Materials, 2022, 50: 533-542. DOI:10.1016/j.ensm.2022.05.026.
- [30] LIN M Q, KE L S, MENG J H, et al. Health status estimation of lithium-ion battery under arbitrary charging voltage information using ensemble learning framework[J]. Reliability Engineering & System Safety, 2025, 256: 110782. DOI: 10.1016/j.res. 2024. 110782.
- [31] GANAIE M A, HU M H, MALIK A K, et al. Ensemble deep learning: A review[J]. Engineering Applications of Artificial Intelligence, 2022, 115: 105151. DOI: 10.1016/j. engappai. 2022. 105151.
- [32] LUO T T, BAO Z Y, HE Z W, et al. A fusion extended long short-term memory learning architecture for capacity trajectory prediction of Li-ion battery[J]. Journal of Energy Storage, 2025, 128: 116994. DOI:10.1016/j.est.2025.116994.
- [33] YAO L, YU C, XIAO Y Q, et al. An improved variational mode decomposition neural network intelligent diagnosis method for battery connection faults based on real vehicle data[J]. Journal of Energy Storage, 2025, 139: 118791. DOI: 10.1016/j. est. 2025. 118791.