

DOI: 10.13382/j.jemi.B2508875

# 基于 Arrhenius-LSTM 的电池容量损失预测方法\*

黄荣<sup>1</sup> 王预夫<sup>2</sup> 周硕<sup>1</sup> 唐荻音<sup>2</sup> 马永乐<sup>1</sup> 郭宇芳<sup>1</sup>

(1. 北京汽车研究总院 北京 101300; 2. 北京航空航天大学 北京 100191)

**摘要:**随着电动汽车的规模化应用,电池剩余容量的精准预测成为保障车辆续航里程、安全性和经济性的核心需求。传统电池容量损失预测方法主要依赖老化实验标定或大量数据学习,难以适应复杂的实际运行工况。针对这一问题,提出了一种机理-数据混合驱动的电池容量损失预测方法,一方面通过阿伦尼乌斯(Arrhenius)模型从机理层面量化温度、累积安时容量衰减的长期主导效应,另一方面通过长短期记忆网络(long short-term memory, LSTM)捕捉容量损失在复杂实际工况下的动态扰动。最后得到电池容量损失的预测值与置信区间。采用电动汽车在自然驾驶条件下采集的充电数据验证动力电池在真实用车场景下的容量损失。实验结果表明,在仅利用容量衰减前30%历史数据进行训练的条件下,该方法在后续容量损失预测中的平均绝对误差(mean average error, MAE)为0.73%,均方根误差(root mean square error, RMSE)为0.96%,最大误差控制在2.18%以内,整体预测性能优于单一 Arrhenius 模型和纯 LSTM 模型。结果表明,所提出的机理-数据混合预测方法能够在真实车载复杂工况下实现高精度、稳定的容量损失预测,为动力电池健康状态评估与寿命管理提供了一种具有工程应用潜力的解决方案。

**关键词:** 电池容量预测;机理-数据混合驱动;阿伦尼乌斯模型;LSTM

**中图分类号:** TN911.7 **文献标识码:** A **国家标准学科分类代码:** 520.2060

## Battery capacity loss prediction method based on Arrhenius-LSTM

Huang Rong<sup>1</sup> Wang Yufu<sup>2</sup> Zhou Shuo<sup>1</sup> Tang Diyin<sup>2</sup> Ma Yongle<sup>1</sup> Guo Yufang<sup>1</sup>

(1. Beijing Automotive Technology and Research Institute Co, Beijing 101300, China; 2. Beihang University, Beijing 100191, China)

**Abstract:** With the large-scale application of electric vehicles, accurate prediction of battery remaining capacity has become a core requirement to ensure driving range, safety, and economic efficiency. Traditional battery capacity degradation prediction methods mainly rely on aging experiment calibration or large-scale data-driven learning, making them difficult to adapt to complex real-world operating conditions. To address this issue, this paper proposes a mechanism-data hybrid-driven method for battery capacity loss prediction. On one hand, the Arrhenius model is employed to quantitatively describe the long-term dominant effects of temperature and cumulative ampere-hour throughput on capacity degradation from a mechanistic perspective. On the other hand, an LSTM network is used to capture dynamic perturbations in capacity loss under complex real-world operating conditions. Finally, the predicted battery capacity loss and its confidence interval are obtained. The proposed method is validated using charging data collected from electric vehicles under natural driving conditions, demonstrating its effectiveness in predicting capacity degradation in practical scenarios. Experimental results show that under the condition of training using only the first 30% of historical capacity degradation data, the method achieved a mean absolute error (MAE) of 0.73% and a root mean square error (RMSE) of 0.96% for subsequent capacity loss prediction, with the maximum error controlled within 2.18%. Overall, the prediction performance is superior to that of a standalone Arrhenius model and a pure LSTM model. The results indicate that the proposed mechanism-data hybrid prediction method can achieve high-precision and stable capacity loss predictions under real-world, complex onboard conditions, providing an engineering-applicable solution for assessing the health status and managing the lifespan of power batteries.

**Keywords:** battery capacity prediction; mechanism-data hybrid-driven; Arrhenius model; LSTM

收稿日期: 2025-11-11 Received Date: 2025-11-11

\* 基金项目: 国家自然科学基金(62373029)、中央高校基本科研业务(501XYGG2025103013)资助项目

## 0 引言

锂离子电池因其高能量密度、长循环寿命和快速充放电特性,已成为推动能源转型的核心技术之一。在新能源汽车、消费电子和储能系统等领域,锂离子电池的应用日益广泛。然而,随着使用时间的延长,电池不可避免地面临老化问题,主要表现为容量衰减、内阻上升和热稳定性下降等现象<sup>[1]</sup>。这些老化效应不仅影响电池的性能,还可能降低电池组的一致性,进而影响系统的安全性和可靠性。因此,准确预测电池的老化过程,成为构建可持续电池生态系统的核心挑战之一<sup>[2]</sup>。

近年来,研究者在锂离子电池老化机制的理解和预测方法方面取得了显著进展。例如,Attia 等<sup>[3]</sup>提出了锂离子电池老化轨迹中的“膝点”概念,揭示了电池在使用过程中可能出现的非线性衰退特征,并讨论了多种导致“膝点”出现的机制,如锂沉积、电极饱和、内阻增长等。此外,随着数据驱动方法的发展,基于机器学习的模型被广泛应用于电池健康状态(state of health, SOH)的估计和剩余使用寿命(remaining useful life, RUL)的预测,为电池管理系统的优化提供了新的思路 and 工具<sup>[4]</sup>。然而,尽管取得了一定进展,如何在复杂的使用环境和多变的工况下,准确预测电池的老化行为,仍然是一个亟待解决的科学和工程问题。

电池容量损失预测方法通常可分为物理模型驱动方法与数据驱动方法两大类<sup>[5-7]</sup>。其中,物理模型驱动方法基于电池内部机理的可解析描述,通过建立反映电化学反应动力学、材料扩散、界面副反应等特性的模型,来推断容量衰减的物理本质。此类方法通常需要在多种环境和工作条件下进行大量老化实验,以获取足够的实验数据用于参数辨识与模型验证。例如,Han 等<sup>[8]</sup>利用 IC-DV(incremental capacity-differential voltage)测试分析技术,通过峰值位置与幅度的变化规律识别不同材料体系电芯的老化机理,从而揭示容量损失与锂沉积、副反应生成等因素之间的关系。Guha 等<sup>[9]</sup>建立了电芯容量衰减与电池内阻增长的数学模型,构建容量退化与内阻之间的关系,将容量衰减和内阻增长模型相结合设计了锂电池剩余使用寿命估计方法;Dong 等<sup>[10]</sup>建立了一个基于物理机制的锂离子电池老化模型,将化学与机械降解机理进行耦合,以刻画电池在循环过程中容量衰减与内阻增加的演化规律,为基于模型的 SOH 估计提供了理论基础。这类物理模型具有较强的可解释性,能够在一定程度上揭示容量损失的机理来源,并为后续机理约束的混合模型提供理论支撑。然而,物理模型方法依赖于大量高质量的实验标定与复杂的参数识别过程,难以直接迁移至不同的电池化学体系或个体差异条件中。此外,当

电池处于动态复杂工况时,模型精度与计算复杂度之间难以兼顾,导致其在工程实践中的实时性与通用性受到限制。

近年来,随着人工智能与机器学习技术的迅速发展,基于数据驱动的方法已成为电池容量衰减与健康状态预测的重要研究方向<sup>[11]</sup>。数据驱动方法能够直接从循环实验与运行数据中提取复杂的非线性退化规律,避免对高维机理参数的依赖,在预测精度与适应性方面展现出明显优势。研究者普遍采用深度学习模型对容量变化的时序特征进行建模与学习,其中,Cheng 等<sup>[12]</sup>利用长短期记忆网络(long short-term memory, LSTM)结合经验模态分解(empirical mode decomposition, EMD)以削弱容量自恢复效应的干扰,实现高精度的容量预测;Li 等<sup>[13]</sup>提出了引入恒定误差循环机制的改进型 LSTM(constant error carousel LSTM),在保持记忆稳定性的同时显著降低了估计误差;彭自然等<sup>[14]</sup>提出一种循环门控模型,用于精确荷电状态(state of charge, SOC)和健康状态预测。Wang 等<sup>[15]</sup>引入注意力机制构建双向 LSTM 模型,有效强化了关键时间特征的捕获能力。随着序列建模技术的发展,Transformer 架构及其变体也被引入电池容量预测任务中,用以同时提取全局趋势与局部特征,提升了模型在多工况下的泛化能力<sup>[16]</sup>。尽管数据驱动方法在精度与灵活性方面取得了显著进展,但其在鲁棒性与可迁移性上仍存在局限。由于训练样本分布依赖性强、对噪声和实验条件差异敏感,模型在迁移至不同电池化学体系或运行场景时常出现偏离点和预测波动,导致性能不稳定。此外,纯数据驱动模型缺乏物理可解释性,难以揭示容量衰减的内在机理,限制了其在工程实践中的可应用性。为此,近年来的研究逐渐转向物理与数据融合的混合式框架,通过在深度学习模型中引入电化学约束或机理先验,以提升预测的稳定性、解释性与工程可行性。

近年来,随着物理信息神经网络(physics-informed neural networks, PINNs)和机理约束深度学习方法的发展,研究者开始尝试将电化学机理方程、老化动力学约束或物理一致性条件直接引入神经网络的训练过程中,以提升模型在小样本条件下的泛化能力和物理可解释性。例如,通过将电池老化微分方程或容量演化约束嵌入损失函数,实现对容量衰减过程的联合建模。该类方法在实验室受控条件下取得了一定成效,能够有效缓解纯数据驱动模型对训练数据分布的依赖问题。然而,这类方法通常依赖可解析的物理方程形式,并要求较高的数据完整性和连续性,在车载应用场景中面临两方面挑战:1)车载电池管理数据(batter management system, BMS)数据往往具有采样稀疏、噪声较大及工况非平稳等特点,难以直接满足物理信息神经网络对可微约束的建模假设;2)将复杂电化学模型强耦合至神经网络训练过程,往往

带来较高的计算复杂度,限制其在实际在线预测场景中的应用。

相比之下,另一类研究工作采用松耦合的机理-数据融合策略,即利用简化物理模型刻画电池老化的长期演化趋势,并通过数据驱动模型对未建模的动态扰动进行补偿修正。这类方法在保持物理一致性的同时,降低了模型构建与训练难度,更符合车载数据条件下的工程应用需求。基于上述研究背景,本文采用阿伦尼乌斯(Arrhenius)模型作为容量衰减的物理趋势先验,并引入 LSTM 对复杂工况下的残差动态进行学习,实现对车用锂电池容量损失的高精度预测。针对传统电池容量损失预测方法依赖大量老化实验或大规模数据训练、难以适应复杂动态运行工况等问题,本文提出了一种机理-数据双驱动的电池容量损失预测方法。该方法以融合物理机理可解释性与数据驱动自适应性为目标,通过“Arrhenius 物理模型+LSTM 残差修正网络”的协同架构,实现对动态工况下容量衰减的高精度建模与预测。首先,基于 Arrhenius 方程构建电化学机理导向的容量衰减基线模型,从锂离子扩散动力学与温度敏感性出发,量化温度与循环应力对容量衰退的确定性影响,揭示长期老化的主导规律。随后,设计双层 LSTM 网络对物理模型的残差序列进行时序建模,通过多源动态特征(如电压弛豫斜率、SOC 变化率、循环应力累积量、温度波动统计量等)的融合,捕捉快充扰动、材料相变和界面演化等未建模非线性效应。最后,通过机理模型预测结果与 LSTM 动态修正量的叠加,形成兼具电化学机理一致性与数据驱动自适应能力的混合预测框架。该方法在理论上实现了物理约束下的残差学习机制,在实践中能够应对多温度、多倍率、非平稳工况下的容量退化预测。基于真实电动汽车充电数据的实验结果表明,该方法在保持物理一致性的同时显著提升了预测精度与鲁棒性,为车载电池健康管理提供了一种可扩展的预测解决方案。

## 1 方法

本文提出的算法框架如图 1 所示。首先构建基于 Arrhenius 方程的容量衰减物理趋势模型,用于描述容量衰减的物理机理;而后基于 LSTM 构建残差动态修正模型,对电池时序数据进行建模、捕捉其动态变化;最终将二者叠加,实现电池容量损失预测。

### 1.1 基于 Arrhenius 方程的容量衰减物理趋势模型

锂电池容量衰减的方式一般可分为日历衰减和循环衰减。由于循环衰减占主要地位,因此本文以循环衰减方式的容量估计为主要研究目标进行研究。

本文采用 Arrhenius 方程构建容量损失的物理趋势模型<sup>[17]</sup>,其表达式为:

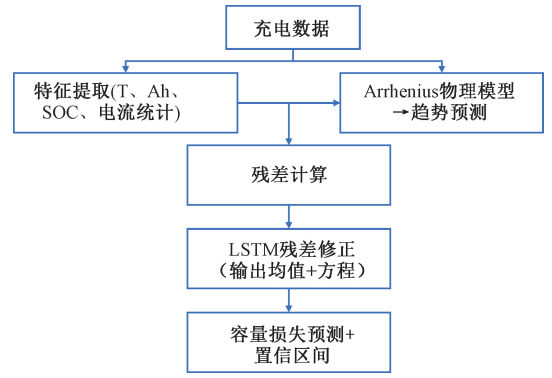


图 1 算法流程

Fig. 1 Algorithm flowchart

$$Q_{loss,cycle} = A_{cycle} \cdot \exp\left(\frac{-E_a}{RT_k}\right) \cdot Ah^{z_{cycle}} \quad (1)$$

式中:  $A_{cycle}$  表示循环老化的指前因子;  $E_a$  表示活化能;  $R$  表示气体常数;  $T_k$  为第  $k$  个充电时间的电池平均温度;  $z_{cycle}$  表示循环老化的幂律因子;  $Ah$  表示循环累计计时。

锂离子电池容量损失的本质源于锂离子不可逆损耗的持续累积,其演化过程受固体电解质界面膜(solid electrolyte interphase, SEI)扩散动力学能垒、材料相变及温度依赖性的多物理场耦合作用。本文基于 Arrhenius 模型构建了机理驱动的容量衰减基线模型,通过引入活化能参数与温度指数项,显式量化了锂离子扩散速率与温度的非线性关系,并建立 SEI 膜生长速率与循环应力之间的半经验关联。

采用分段离散化的策略处理 Arrhenius 公式中的温度参数,即在每个充电过程内计算温度均值以降低瞬态波动和测量噪声的影响;再将该温度代入 Arrhenius 模型,得到相应的老化速率。

### 1.2 容量衰减模型的参数估计方法

为了从实验/车载工况数据中得到可靠的电池衰退速率模型中的温度相关参数,基于实验数据对不同温度下的循环容量损失进行参数识别和关联建模。

首先,对单一温度条件下的容量损失进行经验拟合。依据关系式:

$$Q_{loss,cycle} = A_{cycle} \cdot \exp\left(\frac{-E_a}{RT_k}\right) \cdot Ah^{z_{cycle}} \quad (2)$$

取对数后可转化为线性形式:

$$\ln Q_{loss,cycle} = z_{cycle} \ln Ah + \ln A_{cycle} - \frac{E_a}{RT} \quad (3)$$

问题转化为线性拟合:

$$\ln Q_{loss,cycle} = z_{cycle} \ln Ah + b \quad (4)$$

式中:  $b = \ln A_{cycle} - \frac{E_a}{RT}$

在固定温度下,可采用最小二乘拟合得到  $z_{cycle}$  和  $b$ :

$$(\ln Q_{loss,cycle}^i - z_{cycle} \ln Ah - b)。$$

$$\hat{z}_{cycle}, \hat{b} = \operatorname{argmin} \sum_{i=1}^n (\ln Q_{loss,cycle}^i - z_{cycle} \ln Ah - b)^2 \quad (5)$$

针对衰退模型中存在的参数温度敏感问题,首先将各个温度下的拟合结果进行汇总。经验表明,循环衰退模型中的指数项  $z_{cycle}$  对温度变化不敏感,其主要影响因素来自循环深度和倍率等操作条件,因此在后续建模中假设  $z_{cycle}$  在不同温度下保持恒定<sup>[18]</sup>,而截距项  $b$  为温度依赖项。为得到参数  $b$  随温度变化的趋势,对已估计的截距点  $\hat{b}_j$  与对应的逆温度  $x_j$  (记  $x_j = 1/T_j$ ) 做线性回归<sup>[19]</sup>:

$$\hat{b}_j \approx \beta_0 + \beta_1 \cdot \frac{1}{T} + \eta_j, \quad j = 1, \dots, m \quad (6)$$

式中:  $\beta_0 = \ln A_{cycle}$ ;  $\beta_1 = -\frac{E_a}{R}$ ;  $\eta_j$  为残差项,并假设  $\eta_j$  独立同分布且  $E(\eta_j) = 0, \operatorname{Var}(\eta_j) = \sigma_j^2$ 。

令:

$$X = \begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_m \end{bmatrix}, b = \begin{bmatrix} \hat{b}_1 \\ \vdots \\ \hat{b}_m \end{bmatrix} \quad (7)$$

则最小二乘解为:

$$\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1)^T = (X^T X)^{-1} X^T b \quad (8)$$

从而反算得到活化能和指前因子:

$$\hat{E}_a = -\hat{\beta}_1 R, \hat{A}_{cycle} = \hat{\beta}_0 \quad (9)$$

式中:  $R$  为气体常数 ( $R \approx 8.31446 \text{ J/mol} \cdot \text{K}$ )。

然而,单一的 Arrhenius 模型在真实运行工况下存在一定局限性。首先,该模型往往假设电池处于恒定或平均温度环境,而实际电池在  $25^\circ\text{C} \sim 45^\circ\text{C}$  随环境与充放电倍率发生快速波动,局部升温和瞬态峰值会显著影响副反应速率,但模型难以刻画这类复杂温度动态。其次,Arrhenius 模型中的活化能与指前因子通常被视为固定常数,但电池在循环老化过程中,电极/电解液界面状态会随固体电解质界面 SEI 膜增厚、材料相变与电解液分解逐渐演变,导致参数实际存在漂移。第三,该模型仅考虑温度驱动因素,未能覆盖电流速率、SOC 区间、休息时间等非温度主导的应力源,也忽略了电芯内部非均匀分布(如局部热点与电流密度集中)带来的加速老化效应。因此,本文构建协同框架:Arrhenius 模型提供机理基线,LSTM 通过残差时序特征修正参数漂移与瞬态扰动,实现动态工况下的自适应预测。

### 1.3 残差动态修正模型

在获得基于 Arrhenius 模型的容量衰减先验估计后,为进一步提升预测的精度与适应性,本文引入数据驱动

的时序学习模块。在该阶段中,通过对物理模型的残差进行降噪与归一化处理,提取多种机理相关时序特征(包括残差、累积安时数、时间索引及当前容量),并将其输入多层 LSTM,以捕获物理模型未能充分刻画的动态非线性特征。LSTM 网络输出容量损失的高斯分布参数,利用负对数似然(negative log-likelihood, NLL)准则进行训练,从而同时实现容量点预测与不确定性量化。最终,模型将 LSTM 预测的残差均值与物理模型输出进行加和,得到修正后的容量衰减结果,并给出相应的 95% 置信区间。

定义残差序列为:

$$\epsilon_t = \Delta Q_{loss,true} - \Delta Q_{loss,Arrhenius} \quad (10)$$

式中:  $\Delta Q_{loss,true}$  表示累积容量损失的真实值。

残差序列包含温度波动、工况波动等实际扰动信号,以及传感器噪声和测量误差。为避免模型过拟合,采用小波变换对残差序列进行去噪处理:使用 Daubechies-4(db4)小波进行二级分解,并对高频系数实施软阈值处理。重构后的去噪信号  $\tilde{\epsilon}_t$  作为 LSTM 网络的训练目标,有效降低了噪声干扰。

LSTM 的核心是通过门控机制(遗忘门  $f_t$ 、输入门  $i_t$ 、输出门  $o_t$ )动态控制信息流。

$$f_t = \sigma(W_f \cdot [x_t, h_{t-1}] + b_f) \quad (11)$$

$$i_t = \sigma(W_i \cdot [x_t, h_{t-1}] + b_i) \quad (12)$$

$$O_t = \sigma(W_o \cdot [x_t, h_{t-1}] + b_o) \quad (13)$$

$$h_t = O_t \tanh \odot (C_t) \quad (14)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tanh(W_c \cdot [x_t, h_{t-1}] + b_c) \quad (15)$$

式中:  $W_f, W_i$  和  $W_o$  和  $b_f, b_i$  和  $b_o$  分别为遗忘门、输入门和输出门的系数和偏置;  $C_t$  和  $C_{t-1}$  分别为  $t$  时刻和  $t-1$  时刻的细胞状态,  $W_c$  和  $b_c$  分别表示存储单元的权重和偏置;  $\odot$  表示逐元素乘法。

使用双层 LSTM 网络可自适应选择历史残差信息的记忆权重,捕捉温度变化、负载工况等因素的动态影响,对容量损失残差的非平稳时序特征进行编码,弥补物理模型对局部扰动建模不足的缺陷。

残差修正网络采用物理信息引导的 LSTM 架构,其输入为包含以下要素的多元时序特征矩阵:运行参数(电流/电压曲线)、热力学统计量(平均温度  $\pm$  标准差)、SOC 微分项、Arrhenius 模型残差及累积安时吞吐量。该网络通过双层堆叠拓扑结构(128  $\rightarrow$  64 节点),动态解析瞬态运行模式与容量衰减之间的非线性耦合关系,并生成非负修正因子以补偿物理模型在捕捉快充扰动和材料退化瞬态时的固有缺陷。

在残差修正网络设计中,LSTM 以多源时序特征矩阵为输入(包含电流、电压、温度均值/标准差、SOC 变化率、Arrhenius 模型历史残差及累积循环安时),通过双层堆叠结构(128  $\rightarrow$  64 节点)提取动态工况与容量损失的隐含关联,并输出非负残差修正项以补偿物理模型的未建模

误差。网络训练采用物理引导的两阶段策略:首先冻结 Arrhenius 参数,基于滑动窗口切片数据与 Min-Max 归一化特征,以混合损失函数(MAE、L2 正则化)优化 LSTM 权重;随后联合微调物理模型温度敏感系数与网络参数。核心 LSTM 参数如表 1 所示。

表 1 LSTM 网络训练参数

Table 1 Training hyperparameters of LSTM network

超参数	值
隐藏层(神经元数量)	128
最大训练轮数	400
学习率	0.000 1
批量大小	128
优化器	Adam
激活函数	tanh

双层 LSTM 网络源时序特征矩阵输入,通过多层隐状态提取非线性偏差信息,最后通过双头输出得到残差的均值  $\mu$  和方差  $\sigma^2$ ,方差经过 Softplus 变换保证非负性。假设残差服从条件高斯分布:  $y|x \sim \mathcal{N}(\mu(x), \sigma^2(x))$ , 设置训练目标为最小化 NLL:

$$C_i = f_i \odot C_{i-1} + i_i \odot \tanh(W_C \cdot [x_i, h_{i-1}] + b_c) \quad (16)$$

式中:  $B$  为批量大小。

对最后  $L$  步特征输入 LSTM,得到残差预测均值和方差,并反归一化。最终得到容量损失预测为:

$$\hat{C}_{loss} = C_{loss,phys} + \hat{\mu}_{res} \quad (17)$$

式中:95% 置信区间计算为  $[\hat{C}_{loss} - 1.96 \hat{\sigma}_{res}, \hat{C}_{loss} + 1.96 \hat{\sigma}_{res}]$ 。

## 2 结果

### 2.1 验证数据集

本文参考文献[20]公开发布的车载电池充电数据集(battery-charging-data-of-on-road-electric-vehicles)进行算法验证。该数据集包含 20 辆商用电动汽车在真实道路运行条件下采集的电池组充电数据,时间跨度超过 29 个月,覆盖了长期自然老化过程。所有车辆均为北汽新能源 BAIC EU500 车型,搭载宁德时代(CATL) NCM 三元锂电池,电池组标称容量为 145 Ah,由 90 节电芯串联组成,并在电池包内部布置 e,能够反映电池在实际运行中的热行为特征。

数据记录频率约为 8 s,采集参数包括电池组电流、电压、SOC、单体最大/最小电压以及多点温度信息。相较于实验室循环老化数据,该数据集具有 e 等典型车载 BMS 数据特征,更符合工程应用场景下电池健康状态预测的实际需求。

使用基于改进的安时积分公式标记稀疏月度容量

变化。

$$C_a = \frac{\int_{t_1}^{t_2} I(t) dt}{SOC(t_2) - SOC(t_1)} \quad (18)$$

式中:电流积分区间为单次充电过程的起止时间( $t_1, t_2$ ),SOC 由车载 BMS 提供。

### 2.2 容量损失预测结果

基于自然驾驶场景下 20 辆电动汽车的充电数据,本文对所提出的机理-数据混合预测框架进行了系统验证。实验中,仅使用每辆车容量衰减数据的前 30% 作为训练集,以模型学习容量衰减的趋势与动态特征;剩余 70% 的数据则用于预测验证,以评估模型在有限样本条件下的泛化能力和对未来容量演变的外推能力。

为直观展示所提方法在不同容量衰减形态和运行特征下的预测性能,从 20 辆车中选取了 4 辆具有代表性的车辆进行结果展示。具体而言,所选车辆在容量衰减速率、波动特征及运行稳定性方面存在明显差异:其中,车辆 1 的容量衰减过程较为平稳,呈现近似单调下降趋势;车辆 2 和 3 在长期衰减过程中伴随较为明显的短期容量波动与回弹现象;车辆 4 则表现出相对较慢的容量衰减速率。通过对上述不同类型车辆的对比分析,可更全面地评估模型在复杂工况和多样化老化行为下的预测能力。

图 2 为部分车辆在整个循环过程中容量预测的结果,图中同时标注了实测容量损失的均值及 95% 置信区间。实验结果显示,本文所提出的混合预测框架能够准确捕捉容量衰减的整体趋势和动态变化特征,预测曲线平滑且无明显漂移,且置信区间覆盖了绝大多数真实数据点。需要指出的是,在车辆 2 和 3 的容量衰减过程中,实测容量曲线中出现了较为明显的短期波动和阶段性回弹现象(如图 2(b)、(c)所示)。该类现象在实际车载数据中较为常见,通常与充电策略调整、环境温度突变、使用工况变化或 BMS 对容量的重新标定等因素有关,其变化具有一定的非物理性和突发性。本文提出的方法主要侧重于刻画容量衰减的长期演化趋势及其动态扰动特征,对上述非平稳、非单调的容量回弹现象未进行显式建模,因此在个别波动区间存在一定的跟踪偏差。然而,从整体趋势和长期预测效果来看,模型仍能够较好地捕捉容量衰减的主导演化规律,且预测结果保持稳定,无明显发散或漂移。这表明模型不仅具有较高的预测精度,同时能够有效量化预测不确定性,提高了结果的可靠性与可信度。此外,模型在不同车辆与不同使用工况下均表现出稳定性,验证了其在实际应用中对于多样化自然驾驶数据的适应能力。

与传统的纯物理模型及纯数据驱动模型相比,混合预测框架在多车辆、多工况下展现出更强的鲁棒性与一




图2 混合模型预测结果

Fig. 2 Hybrid model prediction results

致性。基于 Arrhenius 模型的纯物理方法能够较好地描述容量衰减的整体趋势,但在复杂运行环境下,其参数对温度、倍率及休眠时长等因素敏感,易导致预测偏差累积;而基于 LSTM 的纯数据驱动方法虽具备较强的时序建模能力,但对训练样本量依赖较大,在样本有限或工况变化剧烈时容易发生过拟合。本文提出的混合模型通过将 Arrhenius 模型输出作为容量衰减的物理先验,并利用 LSTM 网络对其残差进行动态修正,实现了机理约束下的

自适应学习,使模型能够在捕捉长期衰退趋势的同时,对短期波动与瞬态扰动进行有效修正。

表2对比了不同方法在全部20辆电动汽车上的容量损失预测误差。从结果可以看出,基于 Arrhenius 模型的纯物理方法在动态工况下的平均绝对误差(mean average error, MAE)为0.9370%,均方根误差(root mean square error, RMSE)为1.0741%,能够较好地刻画容量衰减的整体趋势,但在复杂运行条件下仍存在一定的偏差累积。基于 LSTM 的纯数据驱动方法在样本数量有限和工况变化较大的情况下预测误差较为明显,其 MAE 和 RMSE 分别达到2.2459%和2.6813%,表明模型对训练数据分布具有较强依赖性。

表2 动态工况下容量衰减预测误差比较

Table 2 Comparison of capacity fade prediction errors under dynamic conditions (%)

方法	RMSE	MAE	最大误差
Arrhenius	1.074 1	0.937 0	2.503 4
LSTM	2.681 3	2.245 9	3.713 4
混合模型	0.963 4	0.730 7	2.177 9

相比之下,本文提出的机理-数据混合预测方法在3种评价指标上均表现出更优性能,其 MAE 和 RMSE 分别降低至0.7307%和0.9634%,最大误差控制在2.1779%以内。与单一物理模型和纯数据驱动模型相比,混合模型在平均误差和最大误差方面均实现了显著改善,验证了通过引入物理趋势先验并对残差进行动态修正,能够有效提升模型在复杂工况下的预测精度与稳定性。此外,从不同车辆间预测曲线的一致性可观察到,混合模型能够自动适应不同驾驶风格、气候条件及充电习惯带来的数据差异,体现出良好的跨个体适应性与模型迁移潜力。这为模型在更大规模车队及车云平台中的部署应用奠定了基础。总体而言,实验结果验证了本文所提出的混合预测框架在自然动态工况下对电池容量衰减的准确建模能力与优越的泛化表现。

### 3 结论

针对车载动力电池容量衰减预测中工况复杂、数据稀疏的工程难题,本文提出一种融合物理机理与数据驱动的混合建模方法。通过优化 Arrhenius 方程构建温度-循环应力耦合的容量衰减趋势基模型,显式量化温度对长期老化的主导效应;同时设计 LSTM 残差修正模块,自适应补偿动态工况引发的未建模扰动(如锂沉积、机械应力)。基于20辆商用电动汽车29个月的真实充电数据(采样间隔8s)验证表明:在仅需前15个月历史数据预测后续14个月容量衰减的场景下,混合模型的 MAE

与 RMSE 分别达到 0.73% 和 0.96%, 较单一物理模型提升明显。该框架通过机理约束与数据驱动的协同优化, 为动态工况下的电池健康管理提供了高精度、低成本的解决方案。

## 参考文献

- [ 1 ] REN Z, DU C. A review of machine learning state-of-charge and state-of-health estimation algorithms for lithium-ion batteries [J]. *Energy Reports*, 2023, 9: 2993-3021.
- [ 2 ] GUO W, TAN A H, ONG D S. Optimized prediction of remaining useful life of lithium-ion batteries: A voltage-current behavior analysis for enhanced health monitoring[J]. *Journal of Energy Storage*, 2025, 134: 118138.
- [ 3 ] ATTIA P M, BILLS A, PLANELLA F B, et al. “Knees” in lithium-ion battery aging trajectories [J]. *Journal of The Electrochemical Society*, 2022, 169(6): 060517.
- [ 4 ] MBAGAYA L, REDDY K, BOTES A. Machine learning techniques for battery state of health prediction: A comparative review[J]. *World Electric Vehicle Journal*, 2025, 16(11): 594.
- [ 5 ] VETTER J, NOVÁK P, WAGNER M R, et al. Ageing mechanisms in lithium-ion batteries[J]. *Journal of Power Sources*, 2005, 147(1-2): 269-281.
- [ 6 ] CARELLI S, BESSLER W G. Coupling lithium plating with SEI formation in a pseudo-3D model: A comprehensive approach to describe aging in lithium-ion cells[J]. *Journal of The Electrochemical Society*, 2022, 169(5): 050539.
- [ 7 ] XU B, GE X, JI S, et al. Data-driven RUL prediction for lithium-ion batteries based on multilayer optimized fusion deep network[J]. *Ionics*, 2025, 31(2): 1779-1795.
- [ 8 ] HAN X, OUYANG M, LU L, et al. A comparative study of commercial lithium ion battery cycle life in electric vehicle: Capacity loss estimation[J]. *Journal of Power Sources*, 2014, 268: 658-669.
- [ 9 ] GUHA A, PATRA A. State of health estimation of lithium-ion batteries using capacity fade and internal resistance growth models [J]. *IEEE Transactions on Transportation Electrification*, 2017, 4(1): 135-146.
- [ 10 ] DONG G, WEI J. A physics-based aging model for lithium-ion battery with coupled chemical/mechanical degradation mechanisms [J]. *Electrochimica Acta*, 2021, 395: 139133.
- [ 11 ] 郭忠义, 李永华, 李关辉, 等. 装备系统剩余使用寿命预测技术研究进展[J]. *南京航空航天大学学报*, 2022, 54(3): 341-364.
- [ 12 ] CHENG G, WANG X, HE Y. Remaining useful life and state of health prediction for lithium batteries based on empirical mode decomposition and a long and short memory neural network [J]. *Energy*, 2021, 232: 121022.
- [ 13 ] LI P, ZHANG Z, XIONG Q, et al. State-of-health estimation and remaining useful life prediction for the lithium-ion battery based on a variant long short term memory neural network[J]. *Journal of Power Sources*, 2020, 459: 228069.
- [ 14 ] 彭自然, 王顺豪, 肖伸平, 等. 一种精确估算电动汽车动力电池 SOC&SOH 的循环门控模型[J]. *电子测量与仪器学报*, 2024, 38(9): 11-23.
- [ 15 ] PENG Z R, WANG SH H, XIAO SH P, et al. A cyclic gating model for accurate estimation of SOC and SOH of electric vehicle power batteries[J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(9): 11-23.
- [ 16 ] WANG Z, LIU Y, WANG F, et al. Capacity and remaining useful life prediction for lithium-ion batteries based on sequence decomposition and a deep-learning network [J]. *Journal of Energy Storage*, 2023, 72: 108085.
- [ 17 ] FAN Y, LIN Z, WANG F, et al. A hybrid approach for lithium-ion battery remaining useful life prediction using signal decomposition and machine learning[J]. *Scientific Reports*, 2025, 15(1): 8161.
- [ 18 ] LAM V N, CUI X, STROEBL F, et al. A decade of insights: Delving into calendar aging trends and implications[J]. *Joule*, 2025, 9(1): 101796.
- [ 19 ] BIRKL C R, ROBERTS M R, MCTURK E, et al. Degradation diagnostics for lithium ion cells[J]. *Journal of Power Sources*, 2017, 341: 373-386.
- [ 20 ] ZENG L, HU Y, LU C, et al. Arrhenius equation-based model to predict lithium-ions batteries' performance[J]. *Journal of Marine Science and Engineering*, 2022, 10(10): 1553.
- [ 21 ] DENG Z, XU L, LIU H, et al. Prognostics of battery capacity based on charging data and data-driven methods for on-road vehicles [J]. *Applied Energy*, 2023, 339: 120954.

## 作者简介



**黄荣**, 2010 年于西安工程大学获得学士学位, 2016 年于北京理工大学获得博士学位, 现为北京汽车研究总院有限公司电池工程部部长, 主要研究方向为动力电池系统集成与性能开发。

E-mail: huangrong@bjev.com.cn

**Huang Rong** received her B. Sc. degree from Xi'an Polytechnic University in 2010 and Ph. D. degree from Beijing Institute of Technology in 2016, respectively. Now she is a director of Battery Engineering Department in Beijing Automotive Technology and Research Institute. Her main research interests include battery system integration and performance optimization.



**周硕**, 2014 年于四川大学获得学士学位, 2019 年于四川大学获得博士学位, 现为北京汽车研究总院有限公司高级主任工程师, 主要研究方向为动力电池系统集成与性能开发。

E-mail: zhoushuo@bjev.com.cn

**Zhou Shuo** received his B. Sc. degree from Sichuan university in 2014 and Ph. D. degree from Sichuan university in 2019, respectively. Now he is a Senior Engineer in Beijing Automotive Technology and Research Institute. His main research interests include battery system integration and performance optimization.



**唐荻音**(通信作者), 2008 年于北京航空航天大学获得学士学位, 2015 年于北京航空航天大学获得博士学位, 现为北京航空航天大学副教授, 主要研究方向为自动测试技术、预测与健康管理工作。

E-mail: tangdiyin@buaa.edu.cn

**Tang Diyin** (Corresponding author) received her B. Sc. degree and Ph. D. degree from Beihang university in 2008 and in 2019, respectively. Now she is an Associate Professor at Beihang University. Her main research interests include automatic testing technology, prognostics and health management.