

DOI: 10.19650/j.cnki.cjsi.J2514468

融合时序令牌编码与残差增强的锂离子电池健康状态大模型估计方法*

焦金阳, 黄 珊, 李 豪

(北京航空航天大学可靠性与系统工程学院 北京 100191)

摘 要:面向“十四五”智能制造与全生命周期健康管理的国家战略转型, 高端装备核心能源单元的可靠性与安全性已成为关键瓶颈。锂离子电池作为其中的核心, 其健康状态(SOH)的精准评估对保障系统安全、优化运维策略至关重要。然而, 电池退化过程的强非线性、多因素耦合特性为传统方法带来巨大挑战。为应对此挑战, 提出了一种由大模型驱动的锂离子电池 SOH 估计新范式。该方法通过创新的层次化时序令牌编码机制与残差增强特征映射网络, 深度融合了大模型卓越的长时序推理能力与深度学习的精细化特征解耦优势, 实现了从原始传感数据到 SOH 预测的端到端一体化建模。技术上, 该方法首先将电池多维特征序列转化为大模型可处理的语义令牌, 随后通过深度残差网络提取并强化微弱的退化敏感特征, 最终利用大模型的上下文感知与自注意力机制, 精准捕捉并预测循环的容量衰减轨迹。在 HUST、MIT、XJTU 及 TJU 公开数据集上的综合验证表明, 相较于主流基准模型, 所提方法在均方根误差(RMSE)与平均绝对误差(MAE)指标上均达到最优或近最优水平, 展现出卓越的预测精度、稳定性与泛化能力。研究不仅为锂电池寿命预测提供了理论视角与工程实践方案, 更为大模型技术在高端装备智能运维领域的深化应用提供范例。

关键词: 锂离子电池; 健康状态估计; 大语言模型; 智能运维

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 510.40

A large-model-based estimation method for lithium-ion battery state-of-health integrating temporal token encoding and residual enhancement

Jiao Jinyang, Huang Shan, Li Hao

(School of Reliability and Systems Engineering, Beihang University, Beijing 100191, China)

Abstract: Facing the national strategic transformation of intelligent manufacturing and full-life-cycle health management during the "14th Five-Year Plan" period, the reliability and safety of core energy units in high-end equipment have become a key bottleneck. As the core of these units, the accurate assessment of the state-of-health (SOH) of lithium-ion batteries is crucial for ensuring system safety and optimizing operation and maintenance strategies. However, the strong nonlinearity and multi-factor coupling characteristics of the battery degradation process pose significant challenges to traditional methods. To address this challenge, a new paradigm for lithium-ion battery SOH estimation driven by a foundational large model is proposed. This framework deeply integrates the excellent long-term temporal reasoning capability of the foundational large models with the advantage of fine-grained feature decoupling in deep learning through an innovative hierarchical temporal token encoding mechanism and a residual-enhanced feature mapping network, achieving end-to-end integrated modeling from raw sensing data to SOH prediction. Specifically, the framework first converts multi-dimensional battery feature sequences into semantic tokens processable by the large model. Weak degradation-sensitive features are then extracted and enhanced using a deep residual network. Finally, the context awareness and self-attention mechanism of the large model are leveraged to accurately capture and predict the capacity decay trajectory across hundreds of cycles. Comprehensive evaluations on four public datasets (HUST, MIT, XJTU, and TJU) show that compared with mainstream benchmark models, the proposed method achieves the optimal or near-optimal performance in terms of root mean square error (RMSE) and mean absolute error (MAE), demonstrating excellent prediction

收稿日期: 2025-09-05 Received Date: 2025-09-05

* 基金项目: 国家自然科学基金(52575089)、高端装备机械传动全国重点实验室开放基金(SK-LMT-MSKFKT-202405)项目资助

accuracy, stability, and generalization ability. This study not only provides a theoretical perspective and engineering practice scheme for lithium battery life prediction but also offers an example for the in-depth application of large model technology in the field of intelligent operation and maintenance of high-end equipment.

Keywords: lithium-ion batteries; state-of-health estimation; large models; intelligent operation and maintenance

0 引言

锂离子电池作为高端装备的核心能源单元,其健康状况(state-of-health, SOH)的精准评估直接决定了装备运行的可靠性与安全性,也是实现智能运维、优化全生命周期管理的核心前提^[1]。在双碳目标与能源结构转型下,锂离子电池作为新能源汽车、大规模储能电站、航空航天装备等关键领域的核心能量单元,其战略地位日益凸显^[2]。电池系统的性能、安全与寿命需要精准预测。然而,锂离子电池是一个复杂的电化学系统,在反复的充放电循环中,其内部会发生锂枝晶生长、电解液分解、活性材料损失等一系列不可逆的微观退化,宏观上表现为容量衰减与内阻增加^[3]。这一退化过程呈现出三大挑战,使其SOH的精准估计十分困难:1)强非线性与时变性:容量衰减并非简单的线性过程,而是在不同阶段呈现出不同的衰减速率,并伴随容量跳水等突变现象;2)多因素耦合:电池的退化速率受到工作温度、充放电倍率、放电深度等多种因素的动态影响,这些因素相互耦合,使得退化机理极其复杂;3)个体差异性:即便是同一批次生产的电池,由于制造过程中的微小差异,寿命表现也可能大相径庭^[4]。

因此,对锂离子电池SOH的精准估计,已成为制约新能源系统安全性、可靠性与经济性的核心技术瓶颈。为攻克SOH估计难题,学术界与工业界已探索出多种技术路径,大致可分为两代范式^[5]。

基于模型的物理方法:该类方法以等效电路模型(equivalent circuit model, ECM)或伪二维(pseudo two-dimensional, P2D)模型为代表,通过构建微分方程来描述电池内部的电化学动力学过程。这类方法^[6]理论清晰、可解释性强,但其应用瓶颈十分突出,首先,模型复杂度高,需要精确辨识大量难以在线测量的电化学参数,实际应用中常被迫简化,牺牲了精度^[7]。其次,计算负荷巨大,难以满足实时在线监测的需求。最后,模型对工况变化敏感,温度、负载的波动极易导致模型失准,环境适应性差^[8]。数据驱动的传统机器学习与深度学习^[9]方法:随着传感技术与算力的发展,数据驱动方法为绕开复杂的物理建模提供了新思路^[10]。早期研究采用支持向量回归、随机森林等浅层模型,挖掘电压、电流等易测信号与容量衰退间的统计关联^[11]。近年来,深度学习技术凭借其强大的自动特征提取能力成为主流,应用于多种场

景^[12]。卷积神经网络(convolutional neural network, CNN)通过局部感知捕捉充放电曲线的形状特征;长短期记忆网络(long short-term memory, LSTM)及其变体(如双向门控循环单元(bidirectional gated recurrent unit, BiGRU))利用门控机制建模容量衰退的时序依赖性^[13]。然而,这些看似先进的深度学习模型仍存在根本性缺陷^[14]。1)架构碎片化:特征工程、时序建模、回归预测等环节通常由不同模块堆砌而成,架构冗余且优化困难,未能实现端到端的整体学习;2)长程依赖捕捉不足:锂电池的退化是一个横跨数百甚至上千次循环的漫长过程。如传统循环神经网络(recurrent neural network, RNN)类模型受限于梯度消失或爆炸问题,难以有效建模如此长时间跨度的衰减轨迹,导致“记忆力”不足;3)泛化能力孱弱:在特定数据集上训练出的模型,一旦应用于新型号电池或新工况,性能往往会急剧下降,缺乏真实工业场景所必需的鲁棒性与通用性^[15]。

从物理模型到标准深度学习模型的演进过程,揭示了一个矛盾:模型在追求对特定数据的高拟合度的同时,往往牺牲了对未知环境的泛化能力。现有方法的局限性并非简单的性能不足,而是指向了当前模型范式需要创新,亟需一种能够同时处理长程依赖、具备强大泛化能力的全新架构。以GPT、DeepSeek为代表的基础大模型(large model, LM)的崛起,为突破上述困境引入了新方法^[16-17]。这些模型通过在海量数据上进行预训练^[18],获得了强大的上下文学习(in-context learning)和跨任务迁移能力,展现出通用人工智能的潜力^[19-20],这一技术浪潮正迅速从自然语言处理领域渗透至科学与工程领域。大模型有望成为驱动工业智能化的新引擎,在研发设计、生产管理等全链条中挖掘新的应用场景。在机械工程领域,雷亚国团队^[21]率先提出了面向机械设备的智能运维大模型,通过统一的数据编码与多任务协同训练,在轴承、齿轮等部件上实现了“监测-诊断-预测”的全流程健康管理。这项开创性工作证明,借鉴大模型架构优势,构建面向特定工程领域的通用化健康管理模型,是破解当前技术瓶颈的关键路径。然而,将大模型应用于电池SOH估计并非易事。工业数据与自然语言存在本质差异:电池数据是低采样率、多变量的连续时序信号,其退化特征隐藏在长周期的缓慢演变中。此外,工业应用对模型的可靠性、实时性和成本有着极为严苛的要求。因此,简单套用现有大模型架构无法成功,必须设计适配电池数据特性的令牌化策略与特征增强机制,才能充分释

放大模型的潜力,与工程实际相结合。针对上述挑战与机遇,提出一种面向智能运维的锂离子电池健康状态大模型估计方法(state-of-health large model, SOH-LM),主要创新贡献包括:

- 1)提出了一种由基础大模型驱动的SOH估计新范式。针对传统深度学习模型架构碎片化及泛化能力弱的问题,本文首次将前沿的基础大模型架构引入锂电池健康管理领域。利用其在海量数据预训练中获得的卓越长时序推理能力与上下文感知机制,构建了端到端的预测框架,突破了传统深度学习方法在捕捉电池全生命周期长程依赖关系上的局限。
- 2)设计了适配工业时序数据的层次化编码与特征增强架构。为解决连续数值型电池数据与大模型语义空间存在的“模态鸿沟”,本文提出了一种层次化时序令牌编码(Hierarchical Temporal Tokenization)机制,这一编码机制兼顾了时序数据的局部波动特征与全局趋

势信息,将多维电池循环特征转化为模型可理解的语义序列;同时构建了残差增强特征映射网络,该网络通过深层残差连接不仅强化了微弱退化信号的传递效率,还有效缓解了深度网络训练中的梯度消失问题,实现了从原始传感数据到高维语义空间的精准对齐与特征提取。

1 面向智能运维的锂离子电池健康状态大模型估计方法

针对传统深度学习模型在捕捉锂离子电池全生命周期长程依赖关系上的局限性,本文提出了一种基于基础大模型驱动的SOH-LM估计方法。其整体架构如图1所示,包含数据预处理模块、特征映射模块、面向SOH预测的端到端回归模块以及回归预测模块3部分组成,各模块协同工作,为精准预测提供全流程技术支撑。




图1 融合时序令牌编码与残差增强的锂离子电池健康状态大模型整体架构

Fig. 1 Overall architecture diagram of the large-model-based estimation method for lithium-ion battery SOH

进一步,所提出方法主要包含3个核心处理阶段,形成从原始传感数据到SOH预测值的端到端映射,通过各阶段的协同优化,有效解决了传统方法在时序建模适配性、模态兼容性及长程依赖捕捉能力上的不足:1)数据预

处理与特征工程阶段:对采集的电压、电流、温度等原始数据进行去噪与清洗,并提取反映电池电化学反应机理的关键统计特征与物理特征,实现从原始信号到退化信息的初步转化;2)层次化令牌编码与特征增强阶段:为了

弥合工业时序数据与大模型文本语义空间的模态差异,设计了层次化时序令牌编码机制,结合残差增强特征映射网络,将多维特征序列转化为包含丰富语义信息的高维嵌入向量,实现时序数据与大模型语义空间的精准适

配;3)基于大模型的端到端回归预测阶段:利用大模型的时序推理引擎,通过旋转位置编码与多头自注意力机制,深度挖掘电池全生命周期的老化轨迹,实现高精度的SOH回归预测,算法详细流程如图2所示。




图2 SOH-LM估计方法三阶段详细处理流程

Fig.2 Three-stage detailed processing flow of the SOH-LM

1.1 数据预处理与特征工程

1) 数据清洗及去噪

针对锂离子电池在充放电过程中采集的原始数据,由于实际采集环境中存在测量误差和干扰信号,需要进行数据清洗和噪声滤除^[22]。在数据预处理阶段,针对原始序列 $\{x_j\}_{j=1}^N$ 计算其均值与标准差,即:

$$\begin{cases} \mu = \frac{1}{N} \sum_{j=1}^N x_j \\ \sigma = \sqrt{\frac{1}{N} \sum_{j=1}^N (x_j - \mu)^2} \end{cases} \quad (1)$$

其中, μ 和 σ 分别表示原始序列特的统计均值与标准差, N 为样本总数。为同时兼顾对极端异常与长尾分布的鲁棒性,取阈值 $\tau = 3$ 进行异常值剔除,并结合四分位距法进行异常检测, z_j 为筛选后的样本,保留索引集合 I 内的数据点,剔除 $|z_j| > \tau$ 的异常样本,即:

$$\begin{cases} z_j = \frac{x_j - \mu}{\sigma} \\ I = \{j: |z_j| \leq \tau\} \end{cases} \quad (2)$$

随后,为避免引入非物理振荡。在索引集合中断点处,对序列中缺失位置 x_k 使用相邻点线性插值填补;针对多点连续缺失,则使用分段线性插值,即:

$$x_k = x_{k-1} + \frac{k - (k-1)}{(k+1) - (k-1)} (x_{k+1} - x_{k-1}) \quad (3)$$

$$x_{k+m} = x_k + \frac{m}{M+1} (x_{k+M+1} - x_k), \quad m = 1, \dots, M \quad (4)$$

其中, k, m, M 分别代表起始位置、间隔数以及分段长度。上述处理能够降低噪声对后续模型训练的影响,提高模型鲁棒性,进而提升数据的可信度,为特征提取模块提供稳定输入^[23]。

2) 特征提取及归一化

为了从原始的电压、电流曲线中充分挖掘与电池老化状态相关的隐含信息,提取了一系列统计与物理意义兼备的健康指标。

如表1所示,特征涵盖了均值、标准差、偏度、峰度等描述数据分布形态的统计量^[24],以及充电时间、电荷量、电压曲线斜率等反映电化学过程变化的物理量,与电池内部的退化机理高度相关,为模型提供了一个比原始信号更丰富、更具信息量的输入。采用 min-max 归一化方法将所提取的各特征统一至相同尺度,确保模型在训练过程中不会因特征尺度差异而影响收敛速度^[25],从而有效捕捉电池状态变化的核心信息,进而简化网络学习非线性关系的难度,提升模型的稳定性^[26]。

3) 电池状态序列的层次化令牌编码

基础大模型擅长处理由离散令牌组成的序列信息,因此在电池场景中,首先需要将原始的连续、多变量状态数据转换为模型能够理解的“语言形式”。为了实现

表1 特征提取计算

Table 1 Calculation formulas of extracted features

特征	计算方法	特征	计算方法
均值	$\frac{1}{n} \sum_{i=1}^n x(i)$	时间差值	$t_{\text{end}} - t_{\text{start}}$
标准差	$\sqrt{\frac{1}{n-1} \sum_{i=1}^n (x(i) - \bar{x})^2}$	电荷差值	$\int_{t_{\text{start}}}^{t_{\text{end}}} I \cdot dt$
峰度	$\frac{\sum_{i=1}^n (x(i) - \bar{x})^4}{(n-1)\sigma^4}$	斜率	$\frac{V_{\text{end}} - V_{\text{start}}}{t_{\text{end}} - t_{\text{start}}}$
偏度	$\frac{\sum_{i=1}^n (x(i) - \bar{x})^3}{(n-1)\sigma^3}$	熵	$-\sum_{i=1}^n p_i \cdot \log(p_i)$

这一点,研究构建了一种层次化令牌编码机制:将电池每一次充放电循环中提取的、已经归一化的多维特征向量视作一个独立“令牌”(Token),用于紧凑表达该周期的整体健康状态。

在这种表示下,电池从投入使用到当前时刻经历的所有循环,都被依时间顺序组织成一个令牌序列,使得其完整的退化轨迹能够以序列形式输入模型。这样处理后,原本基于连续时间的SOH估计任务,被自然地转化为一个序列到序列(sequence to sequence, Seq2Seq)建模问题。这种序列化表示^[27]不仅保留了电池老化过程中的时序结构,还使模型能够在令牌层面理解循环之间的相互影响,从而捕捉退化行为中的短期变化与长期趋势。

1.2 基于残差增强的层次化特征映射机制

电池SOH退化过程本质上是一个强非线性、多尺度的电化学演变过程,其早期的老化信号在原始数据空间中往往表现为微弱的扰动,极易在深层网络的逐层传递中发生耗散或被环境噪声淹没^[28]。为了将低维的时间序列数据有效映射至大模型可理解的高维语义空间,并确保关键退化特征的无损传递,构建了一个包含高维线性投影、非线性流形变换及残差特征增强的层次化映射架构。

首先,为了挖掘原始多维特征序列中隐含的退化动力学规律,采用线性投影层将第*t*个循环周期的原始输入向量 $\mathbf{x}_t \in \mathbb{R}^{d_{\text{in}}}$ 映射至高维潜在特征空间。随后,引入层标准化以消除协变量偏移,并利用线性整流函数(rectified linear unit, ReLU)激活函数诱导稀疏性以捕捉复杂的非线性退化模式:上述激活函数不仅能够增加非线性,更与电池的电化学退化特性高度契合。锂离子电池的衰退过程并非线性匀速,而是在不同老化阶段呈现出显著的速率差异,后期会出现内阻激增进而引发容量骤降。ReLU的稀疏激活特性能够有效滤除平稳期的冗

余噪声,敏锐捕捉这些标志着电池健康状态发生相变的突变特征,从而提升模型对SOH轨迹中突变的感知能力。具体变换过程可形式化描述为:

$$\mathbf{z}_t = \mathbf{W}_p \mathbf{x}_t + \mathbf{b}_p \quad (5)$$

$$\mathbf{h}_t = \text{ReLU}(\text{LayerNorm}(\mathbf{z}_t)) =$$

$$\max\left(0, \frac{\mathbf{z}_t - \boldsymbol{\mu}}{\boldsymbol{\sigma} + \epsilon} \cdot \boldsymbol{\gamma} + \boldsymbol{\beta}\right) \quad (6)$$

其中, $\mathbf{z}_t$ 为线性投影后的中间变量; $\mathbf{W}_p \in \mathbb{R}^{d_{\text{model}} \times d_{\text{in}}}$ 与 $\mathbf{b}_p$ 分别为可学习的投影权重矩阵与偏置向量; $\boldsymbol{\mu}$ 和 $\boldsymbol{\sigma}$ 分别表示特征维度的统计均值与标准差; ϵ 为数值稳定性常数; $\boldsymbol{\gamma}$ 与 $\boldsymbol{\beta}$ 为层归一化的仿射变换参数。基于此,模型能够将不同分布的电池工况数据统一至标准化的流形空间中,从而显著提升后续大模型时序推理的收敛稳定性。

考虑到电池早期的健康状态衰退主要由微观层面的SEI(solid electrolyte interphase)膜增厚引起,宏观外特性的变化极其微弱。随着网络深度的增加,微弱的早期退化特征容易面临梯度消失问题^[29]。为此,本文设计了残差增强路径,将线性投影前的原始信息流与经过非线性变换的高层语义特征进行融合,确保包含电池早期老化信息的原始物理特征能够无损传递至深层网络,从而提升模型对全生命周期变化的感知能力。电池的SOH退化为累积过程,其早期的健康状态衰退反映在宏观曲线上的特征极其微弱。随着网络层数的加深,上述早期退化信号极易在非线性变换中丢失。因此,引入残差连接将确保包含电池早期老化机理的原始物理特征能够无损传递至深层语义空间。假设输入与输出维度已通过投影对齐,则残差增强后的最终特征输出 $\mathbf{y}_t$ 定义为:

$$\mathbf{y}_t = F(\mathbf{x}_t, \{\mathbf{W}_i\}) + T(\mathbf{x}_t) \quad (7)$$

$$T(\mathbf{x}_t) = \begin{cases} \mathbf{x}_t, & d_{\text{in}} = d_{\text{model}} \\ \mathbf{W}_s \mathbf{x}_t, & d_{\text{in}} \neq d_{\text{model}} \end{cases} \quad (8)$$

其中, $F(\cdot)$ 代表上述包含非线性激活的变换映射残差函数; $T(\cdot)$ 为恒等映射,也即或维度匹配投影。这一设计构建了梯度的快速连接,使得误差信号在反向传播时能够直接传导至浅层网络,有效保留了反映电池健康状态本质的原始物理特征。此外,在残差块输出端引入Dropout正则化机制($p=0.1$),通过在训练过程中随机阻断神经元连接,模拟模型集成效应,进一步增强了算法在面对小样本电池数据时的泛化鲁棒性。

1.3 面向SOH预测的端到端回归模块

本工作基于DeepSeek-LLM-7B-base^[30]预训练模型,设计了一种用于电池健康状态高精度预测的时序建模主干结构。本节将介绍其主要组成部分。

1) 多头自注意力机制

自注意力机制使得模型能够自动捕捉数据间的依赖

关系。多头自注意力模块的引入,能够对输入序列中任意两个位置间的相关性进行并行计算,在捕捉局部和全局依赖的基础上提高了检索效率。

首先构造查询矩阵以及键值矩阵,对于输入的令牌序列,该机制通过计算查询(query, Q)、键(key, K)和值(value, V)这 3 个矩阵来动态地为序列中的每个元素分配注意力权重,即:

$$\begin{aligned} Q &= H_{\text{输入}} W_Q \\ K &= H_{\text{输入}} W_K \\ V &= H_{\text{输入}} W_V \end{aligned} \quad (9)$$

其中, $W_Q, W_K, W_V \in \mathbb{R}^{D \times D}$ 且均可学习。随后,进行注意力计算,即:

$$O = \text{softmax}\left(\frac{QK^T}{\sqrt{D}}\right) V \quad (10)$$

上述计算不依赖于令牌在序列中的距离,使得模型能够直接建立任意两个循环周期之间的依赖关系,进而使模型能够构建一个贯穿整个电池生命周期的全局衰退视图。最后,构建多个注意力头针对不同子空间内的注意力分数实现并行计算,进行拼接并输入后续网络。多头注意力机制的引入使模型能够灵活捕捉不同尺度、不同角度的数据依赖关系。此外,并行计算提高了模型计算效率^[31],适合大规模数据在线部署。

2) 位置编码

对于锂离子电池而言,SOH 的演变不仅取决于当前的循环次数(绝对位置),更与历史循环中累积的不可逆电化学损伤(相对间隔)密切相关。标准 Transformer 模型中的绝对位置编码难以有效泛化至不同长度的序列,且无法显式建模时间间隔这一对电池退化至关重要的物理概念。在提出的方法中,引入旋转位置编码(rotary position embedding, RoPE)^[32]。其核心思想是将绝对位置编码转化为复数域的几何旋转操作,从而在注意力计算中显式保留相对位置关系。通过复数域的旋转操作, RoPE 使得注意力权重仅依赖于循环周期之间的相对距离,从而更精准地刻画电池长期退化过程中的记忆特性,赋予模型更符合电化学退化客观规律的时序推理能力。

给定序列位置索引 $m \in \mathbb{Z}^+$ 与特征维度索引 $i \in \{1, 2, \dots, d/2\}$, RoPE 通过构造分块对角旋转矩阵 $R_m \in \mathbb{R}^{d \times d}$ 实现位置编码。该矩阵由 $d/2$ 个二维旋转子矩阵沿对角线拼接构成,即:

$$\begin{cases} R_m = \bigoplus_{k=1}^{d/2} \begin{pmatrix} \cos\theta_k & -\sin\theta_k \\ \sin\theta_k & \cos\theta_k \end{pmatrix} \\ \theta_k = 10\,000^{-2k/d} \end{cases} \quad (11)$$

其中, $\bigoplus$ 为分块对角矩阵构造算子, θ_k 为维度相关的旋转基频参数。对于查询向量 $q \in \mathbb{R}^d$ 与键向量 $k \in \mathbb{R}^d$, 位置感知投影可等价表示为复数域旋转操作,即:

$$f(q, m) = R_m q = q \odot e^{i\Theta m} \quad (12)$$

$$f(k, n) = R_n k = k \odot e^{i\Theta n}$$

其中, $\Theta = \text{diag}(\theta_1, \theta_2, \dots, \theta_{d/2})$ 为对角旋转频率矩阵, $\odot$ 为逐元素乘法。由欧拉公式 $e^{i\theta} = \cos \theta + i \sin \theta$, 该形式将实数空间的线性变换映射为复数平面的旋转变换。而在注意力分数计算阶段,这一机制使得:

$$\alpha_{m,n} = \text{Re}[(q^T e^{i\Theta(m-n)})k] = q^T R_{m-n} k \quad (13)$$

即,注意力权重 $\alpha_{m,n}$ 仅依赖于相对位置偏移量 $|m - n|$, 满足平移不变性。因此相较于传统位置编码,这一现实相对位置建模方法保证了数值稳定性:旋转矩阵的正交性避免了长序列场景下梯度爆炸以及梯度消失的问题。

3) 前馈神经网络及残差连接

数据在经过上述操作后将被送入前馈神经网络中:这一网络对自注意力输出进行非线性处理,进一步抽取深层特征。

$$\text{FFN}(H) = \text{ReLU}(W_1 H + b_1) W_2 + b_2 \quad (14)$$

其中, $W_1 \in \mathbb{R}^{D \times D_{\text{隐藏层}}}$ 和 $W_2 \in \mathbb{R}^{D_{\text{隐藏层}} \times D}$ 均为可学习的权重。这一网络能够有效增强模型的非线性表达能力,进而保证层与层之间的信息传递与融合更加充分,提高模型对复杂动态变化的表达能力,尤其适用于工业设备状态监控。最后,所提出方法在自注意力模块和前馈网络中均引入残差连接,并采用层归一化操作,从而保证整体网络的训练稳定性,适应多数据场景下的高端装备运维需求。

2 实验与结果分析

2.1 实验数据集

研究所采用的数据集包括华中科技大学(Huazhong University of Science and Technology, HUST)公开的大规模循环实验数据^[22]、麻省理工学院(Massachusetts Institute of Technology, MIT)开源的长期衰退数据^[27]、西安交通大学(Xi'an Jiaotong University, XJTU)高精度电池循环数据^[25]以及同济大学(Tongji University, TJU)温控健康状态数据^[26]。

HUST 数据集来源于华中科技大学电池实验室,涵盖 77 种不同充放电协议下的循环过程,共计约 14 万条循环数据,用于全面刻画电池在多样化工况下的性能演变;MIT 数据集为麻省理工学院公开平台提供的多种充电策略下的长周期循环数据,包含电流、电压、温度等多维度监测指标,重点反映电池衰退趋势;XJTU 数据集由西安交通大学采集,涵盖多型号电池在不同环境条件(如温度、湿度变化)下的精准电化学测试数据,是目前规模较大的开源数据集之一;TJU 数据集则由同济大学提供,

主要记录了电池在恒温与温控切换条件下的健康状态演变情况。为保证数据的一致性和模型输入的可靠性,所有数据均按照 80%:10%:10% 的比例划分为训练集、验证集和测试集,并统一实施了预处理流程:首先统计全局均值与标准差,基于此对原始时序数据进行归一化;随后采用三倍标准差及四分位距法剔除异常点,以最大程度地消除噪声干扰并提升数据质量。

2.2 基准方法

为了验证所提模型在电池剩余寿命预测任务中的有效性,研究选取了 4 种典型深度学习模型:CNN、LSTM、残差网络(residual network, ResNet)、基于自注意力机制的 Transformer,以及 Jafari 等^[33]提出的粒子群优化(particle swarm optimization, PSO)的 CNN-LSTM-ConvLSTM 融合模型(PSO-optimized CNN-LSTM-ConvLSTM fusion model, P-CLCL)对照。

CNN 通过局部卷积核与池化层对输入的时序特征进行多层次抽取,能够高效捕捉电流、电压等信号的短期变化规律;LSTM 凭借其门控结构在时间维度上传递并保留长依赖信息,尤为适合挖掘电池循环衰退过程中的长期趋势;ResNet 借助跨层残差连接缓解深层网络训练中的梯度消失问题,不仅提升了网络的可训练深度,也增强了模型的泛化能力;Transformer 模型则通过自注意力机制对整个序列进行全局相关性建模,并辅以位置编码弥补时序信息的缺失,使其在处理超长序列时表现出卓越的并行计算能力和远距离依赖捕捉能力。P-CLC 融合 CNN、LSTM 与 ConvLSTM 这 3 种网络,其中 CNN 提取电压、电流等数据的局部空间特征(如信号突变趋势),LSTM 通过门控单元捕捉电池衰退的长时序依赖,ConvLSTM 则结合卷积与循环特性同步挖掘时空关联特征,为进一步提升模型精度与泛化能力,引入粒子群优化(PSO)算法,集成沙普利可加解释(Shapley additive explanations, SHAP)技术实现全局关键特征识别,所有基线模型均在相同的数据划分和预处理条件下进行训练。

2.3 评价指标

为了定量评估模型对锂离子电池 SOH 的预测性能及其在实际运维中的应用价值,选取均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)和决定系数(coefficient of determination, R^2)作为综合评价体系。各指标的定义及物理含义为:

RMSE:该指标对预测误差中的异常极大值高度敏感。在电池管理系统中,个别的 SOH 预测严重偏离可能导致过充或过放,引发严重的安全事故。RMSE 越低,表明模型在极端工况下的预测稳定性越好,系统安全性越高。计算公式为:

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

(15)

MAE:反映了预测值与真实值之间的平均偏离程度,代表了模型在全生命周期内 SOH 估计的整体准确性。计算公式为:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

(16)

R^2 :用于表征模型对数据变异的解释能力。对于电池 SOH 估计, R^2 越接近 1,说明模型越能精准地捕捉和拟合电池复杂的非线性退化轨迹,而非仅仅是拟合了数据的均值。计算公式为:

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

(17)

其中, N 为测试样本数, y_i 为 SOH 真实值, $\hat{y}_i$ 为模型预测值, $\bar{y}$ 为真实值的均值。

2.4 实验结果及分析

1) 整体性能分析

表 2 和表 3 记录了基准模型及所提出模型在 HUST、MIT、TJU 和 XJTU 这 4 个数据集上的表现。

表 2 RMSE 对比实验结果

Table 2 Comparison of RMSE (%)

对比方法	HUST	MIT	TJU	XJTU
CNN	0.97±0.06	0.37±0.17	0.51±0.07	0.62±0.13
ResNet	1.00±0.03	0.31±0.03	0.51±0.04	0.82±0.39
LSTM	1.49±0.06	0.28±0.02	0.46±0.02	0.87±0.17
Transformer	1.12±0.09	0.29±0.07	0.67±0.28	0.21±0.19
BiGRU	1.40±0.08	0.27±0.01	0.74±0.12	0.96±0.58
P-CLCL	0.72±0.05	0.25±0.02	0.45±0.01	0.17±0.05
SOH-LM	0.63±0.04	0.26±0.01	0.45±0.01	0.13±0.06

在 4 个数据集上,提出的模型在 RMSE 和 MAE 指标上均实现了最优:HUST 数据集上,提出的模型的 RMSE 值为 0.63、MAE 值为 0.43,较最好的 CNN 分别降低约 35%和 34%;MIT 数据集上,这一模型的 RMSE/MAE 值分别为 0.26/0.14,略优于最佳基线(ResNet 的 0.31/0.20);TJU 数据集以及 XJTU 数据集上,该模型也存在优势。

总体来看,此模型在多源电池寿命预测任务上表现更为稳健,能够持续取得最优或近最优的预测精度。此外,在 MIT 数据集上,所有模型在该数据集上表现普遍较好, RMSE 值均在 0.26~0.37 范围, MAE 值也在 0.15~0.24,表明该数据集噪声较低、循环特征易于捕捉,因此基线模型的优势表现得不够明显;在 HUST 与 XJTU 数据集上,两者均具有更为复杂的退化模式,尤其

表 3 MAE 对比实验结果
Table 3 Comparison of MAE (%)

对比方法	HUST	MIT	TJU	XJTU
CNN	0.65±0.04	0.24±0.15	0.23±0.02	0.36±0.13
ResNet	0.66±0.02	0.20±0.03	0.27±0.04	0.50±0.28
LSTM	0.99±0.04	0.16±0.02	0.23±0.02	0.56±0.14
Transformer	0.73±0.05	0.18±0.06	0.40±0.29	0.15±0.12
BiGRU	0.93±0.04	0.15±0.01	0.50±0.12	0.58±0.40
P-CLCL	0.48±0.04	0.14±0.01	0.22±0.03	0.11±0.04
SOH-LM	0.43±0.03	0.14±0.01	0.22±0.01	0.09±0.04

是 XJTU 数据集,基线模型 RMSE 值最大接近 1.0,所提出的模型得到了 0.13 的 RMSE 值,以及 0.09 的 MAE 值,显示出其强大的特征提取和泛化能力。此外,在 TJU 数据集上,数据存在较大周期波动,不同模型在此上差异较小,但此模型仍以微弱优势胜出,说明其对循环内外层次特征的综合建模能力更全面。

由表 4 可见,4 个数据集中,所提出的模型的 R^2 分别达到了 0.994 6(HUST)、0.995 8(MIT)、0.988 5(TJU)和 0.998 3(XJTU),均高于基线方法,表明此模型对 SOH 衰退过程的拟合几乎达到了“无残差”水平。尤其在退化模式复杂的 HUST 和 XJTU 数据集上,其 R^2 超 0.99 并伴随极低的标准差,显示出卓越的稳定性和鲁棒性;短期内细微波动和长期趋势均被精准捕捉;而在噪声较低的 MIT 数据集,所有模型表现相近,所提出的模型仍凭借对非线性特征的深度映射与多头自注意力的长程依赖建模取得微弱优势。

表 4 R^2 对比实验结果
Table 4 Comparison of R^2 (%)

对比方法	HUST	MIT	TJU	XJTU
CNN	98.72±0.17	99.01±0.99	98.47±0.44	96.34±1.33
ResNet	98.64±0.08	99.38±0.12	98.52±0.22	92.57±6.14
LSTM	96.98±0.24	99.52±0.09	98.76±0.11	92.76±2.88
Transformer	98.30±0.27	99.45±0.28	97.07±2.53	99.33±1.17
BiGRU	97.36±0.31	99.55±0.03	96.76±0.94	88.98±13.65
P-CLCL	99.35±0.08	99.60±0.10	98.80±0.04	99.78±0.15
SOH-LM	99.46±0.07	99.58±0.04	98.85±0.03	99.83±0.17

2) 误差幅度与偏差趋势

如图 3 所示,图 3(a)和(b)分别展示了在 HUST 和 MIT 数据集上,6 种模型预测值与真实 SOH 之间的误差随循环次数的变化曲线。

所提出模型在整个循环过程中误差基本保持在





图 3 误差-循环次数对比

Fig. 3 Error curves versus cycle number of different models

$\pm 1\%$,并且大多数点分布极其接近 0,未出现明显的系统性高估或低估现象。相比之下,其他基线模型在部分周期出现了 2%甚至更高的偏离,尤其是在 HUST 数据的第 20 次循环附近,LSTM、Transformer 和 BiGRU 出现了明显的误差峰值,而该模型峰值不足 1%。在 MIT 数据集上,所有模型的误差总体更集中、峰值也更低,但基线模型仍存在短时的剧烈波动,而提出的模型的误差曲线最为平滑且无较大尖峰,尽管对比的 P-CLCL 方法也保持着较低的误差,但是在部分循环节点也出现了较大的波动。最后,若模型对长程依赖捕捉不足,误差往往会随循环次数逐步放大。所提出模型循环内误差无累积漂移趋势,验证了多头自注意力与相对位置编码在长期特征建模上的有效性。

如图 4 所示,图 4(a)~(g)分别展示了基线模型以及提出的模型在 HUST 数据集上的误差统计特征。



(a) SOH-LM 的误差分布
(a) Error distribution of SOH-LM




图4 6种模型误差分布

Fig. 4 Error distribution of 6 models

其中,横坐标为误差,纵坐标统计对应误差的出现频率。从直方图的柱状宽度与核密度曲线可观察到,不同模型在误差集中程度上的差异显著。CNN、ResNet、Transformer等模型的误差大致集中在 ± 0.02 范围, P-CLCL呈现出集中趋势,但是仍然存在预测误差较大的簇,而SOH-LM(图4(a))展示出最显著的集中趋势,其误差几乎全部压缩在 ± 0.01 范围,且核密度函数在误差为0附近呈现极为陡峭的尖峰。

此外,直方图的形态揭示了误差分布的峰度特性:所提出模型的误差分布曲线呈现明显的尖峰与纤细尾部,反映出强烈的中心集中趋势与轻尾性质;相比之下, BiGRU与LSTM的分布曲线更为扁平,表明预测误差易出现较大偏离;ResNet和CNN虽然也展现出一定的集中趋势,但中心区域分布不如提出的模型紧凑;Transformer分布较为对称但整体峰度偏低,表明其虽然整体稳健,但

精度仍有提升空间。图中尾部的轻重直接影响模型对异常情况的鲁棒性:提出的模型分布尾部迅速衰减,几乎无超过 ± 0.02 的误差样本,显示出极佳的异常抑制能力。最后,提出的模型标准差显著优于其他基线模型,在大多数样本上实现了更稳定、更精确的预测,减小了SOH估计的波动性。

从整体趋势来看,提出的模型在所有模型中具有最小的误差波动范围、最显著的中心集中度、最轻的尾部分布和最对称的偏差表现,充分验证了其结构设计在电池健康预测任务中的有效性与先进性。此外,尽管模型因引入大模型架构和多层残差连接而导致计算量有所增加,但在实验中对应的预测精度提升显著,尤其是在复杂和噪声较高的数据集上优势更为明显。由此,这一方法不仅可应用于电池健康状态监测,或具备良好的拓展性。

综合上述实验结果,SOH-LM方法在多数数据集上的优异表现主要得益于其独特的架构:首先,层次化令牌编码策略成功消除了工业时序数据与大模型语义空间的模态差异,使模型能充分利用预训练的通用知识;其次,特征映射网络中的残差连接有效缓解了深层网络的梯度消失问题,保证了长期退化特征完整性;最后,多头自注意力机制与旋转位置编码的结合,使其在捕捉长达数百次循环的非线性退化轨迹时,较传统循环网络具有更强的全局建模能力与数值稳定性。

3 结 论

针对传统深度学习方法在锂离子电池SOH估计中存在的长程依赖捕捉不足和泛化能力弱等问题,本文提出了一种面向智能运维的锂离子电池健康状态大模型估计方法。通过设计创新的层次化时序令牌编码和残差增强特征映射网络,成功将预训练大模型的时序推理能力迁移至电池健康管理领域。在HUST、MIT、XJTU及TJU这4个公开数据集上的综合验证表明,所提方法在RMSE和MAE指标上均优于CNN、Transformer等主流基准模型,展现出卓越的预测精度与鲁棒性。

尽管所提方法取得了理想的实验结果,但在极端复杂工况下的适应性及模型在嵌入式边缘端的轻量化部署方面仍有提升空间,如:1)宽温域冲击(如极寒或高温环境下的充放电);2)高动态负载(如电动汽车急加速/急减速导致的剧烈电流波动);3)传感器故障导致的数据严重缺失或含噪(如电压/温度采样丢失)。未来的工作将重点探索跨模态数据(如结合运维日志文本与时序数据)的融合机制,以及基于模型剪枝与量化的端侧部署方案,以进一步推动大模型技术在装备智能运维中的工程化落地。

参考文献

- [1] 林京, 焦金阳. 可解释机械智能诊断技术的研究进展与挑战[J]. 机械工程学报, 2023, 59(20): 215-224.
LIN J, JIAO J Y. Research progress and challenges of interpretable mechanical intelligent diagnosis[J]. Journal of Mechanical Engineering, 2023, 59(20): 215-224.
- [2] 董凯. “十四五”智能制造发展规划解读及趋势研判[J]. 中国工业和信息化, 2022(1): 26-29.
DONG K. Interpretation and trend analysis of the development plan of intelligent manufacturing in the "14th Five-Year Plan" [J]. China Industry & Information Technology, 2022(1): 26-29.
- [3] WANG F J, ZHAO ZH B, REN J X, et al. A transferable lithium-ion battery remaining useful life prediction method from cycle-consistency of degradation trend[J]. Journal of Power Sources, 2022, 521: 230975.
- [4] BOKSTALLER J, SCHNEIDER J, BROCKE J V, et al. Estimating SoC, SoH, or RuL of rechargeable batteries via IoT: A review[J]. IEEE Internet of Things Journal, 2024, 11(5): 7559-7582.
- [5] 熊瑞, 李幸港. 基于简化 P2D 模型的锂离子电池析锂评估方法[J]. 机械工程学报, 2025, 61(22): 176-188.
XIONG R, LI X G. Lithium precipitation evaluation method for Li-ion batteries based on simplified P2D model[J]. Journal of Mechanical Engineering, 2025, 61(22): 176-188.
- [6] RODRIGUEZ-CEA A I, MORINIGO-SOTELO D, TINAUT F V. A procedure for evaluating the SOH of Li-ion batteries from data during the constant voltage charge phase and the use of an ECM with internal resistance[J]. Journal of Energy Storage, 2025, 108: 115074.
- [7] WU L X, LYU ZH Q, HUANG Z B, et al. Physics-based battery SOC estimation methods: Recent advances and future perspectives[J]. Journal of Energy Chemistry, 2024, 89: 27-40.
- [8] 王学远, 李日康, 魏学哲, 等. 基于传荷电阻的锂离子电池剩余寿命预测研究[J]. 机械工程学报, 2021, 57(14): 105-117.
WANG X Y, LI R K, WEI X ZH, et al. Study on remaining useful life prediction of lithium-ion batteries based on charge transfer resistance[J]. Journal of Mechanical Engineering, 2021, 57(14): 105-117.
- [9] 舒星, 刘永刚, 申江卫, 等. 基于改进最小二乘支持向量机与 Box-Cox 变换的锂离子电池容量预测[J]. 机械工程学报, 2021, 57(14): 118-128.
SHU X, LIU Y G, SHEN J W, et al. Capacity prediction for lithium-ion batteries based on improved least squares support vector machine and Box-Cox transformation[J]. Journal of Mechanical Engineering, 2021, 57(14): 118-128.
- [10] 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. Prediction of remaining service life of electric submersible pump based on ensemble learning model[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3): 13-20.
- [11] ZHAO J Y, FENG X N, PANG Q Q, et al. Battery prognostics and health management from a machine learning perspective [J]. Journal of Power Sources, 2023, 581: 233474.
- [12] 李斌, 王幸之, 王志鹏. 基于 CPO 的 IFMD-BiTCN-BiGRU-AT 断路器寿命预测方法研究[J]. 电子测量与仪器学报, 2025, 39(10): 255-268.
LI B, WANG X ZH, WANG ZH P. IFMD-BiTCN-BiGRU-AT remaining usable life prediction method for circuit breakers based on CPO[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(10): 255-268.
- [13] 周明博, 曹军义, 邹忠月. 多方向实车振动路谱对电池容量和阻抗特性影响的试验研究[J]. 振动工程学报, 2022, 35(4): 841-848.
ZHOU M B, CAO J Y, ZOU ZH Y. Experimental study on the influence of multi-directional real road spectrum on battery capacity and impedance[J]. Journal of Vibration Engineering, 2022, 35(4): 841-848.
- [14] TAO SH Y, MA R F, ZHAO Z X, et al. Generative learning assisted state-of-health estimation for sustainable battery recycling with random retirement conditions[J]. Nature Communications, 2024, 15(1): 10154.
- [15] WANG J R, PENG Q, MENG J H, et al. A physics-informed neural network approach to parameter estimation of lithium-ion battery electrochemical model[J]. Journal of

- of Power Sources, 2024, 621: 235271.
- [16] YIN SH K, FU CH Y, ZHAO S R, et al. A survey on multimodal large language models[J]. National Science Review, 2024, 11(12): nwae403.
- [17] 彭宇,季拓,郭楚亮.故障预测与健康领域大语言模型:应用与展望[J].仪器仪表学报, 2025, 46(10): 2-21.
- PENG Y, JI T, GUO CH L. Prognostics and health management domain-specific large language models: Applications and prospects[J]. Chinese Journal of Scientific Instrument, 2025, 46(10): 2-21.
- [18] MIN B, ROSS H, SULEM E, et al. Recent advances in natural language processing via large pre-trained language models: A survey[J]. ACM Computing Surveys, 2024, 56(2): 1-40.
- [19] DeepSeek-AI, GUO D Y, YANG D J, et al. DeepSeek-R1: Incentivizing reasoning capability in LLMs via reinforcement learning[J]. ArXiv preprint arXiv: 2501.12948, 2025.
- [20] KHAN M A, ALI Z A, MASOOD R J. UAV-assisted LoRa-based wireless sensor network for environmental monitoring[J]. Instrumentation, 2025, 12(2): 91-100.
- [21] 雷亚国,李熹伟,李响,等.面向机械设备通用健康管理的智能运维大模型[J].机械工程学报, 2025, 61(6): 1-13.
- LEI Y G, LI X W, LI X, et al. Research on large model for general prognostics and health management of machinery[J]. Journal of Mechanical Engineering, 2025, 61(6): 1-13.
- [22] MA G J, XU S P, JIANG B B, et al. Real-time personalized health status prediction of lithium-ion batteries using deep transfer learning[J]. Energy & Environmental Science, 2022, 15(10): 4083-4094.
- [23] WANG F J, ZHI Q Q, ZHAO ZH B, et al. Inherently interpretable physics-informed neural network for battery modeling and prognosis[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(1): 1145-1159.
- [24] WANG F J, ZHAI ZH, LIU B CH, et al. Open access dataset, code library and benchmarking deep learning approaches for state-of-health estimation of lithium-ion batteries[J]. Journal of Energy Storage, 2024, 77: 109884.
- [25] WANG F J, ZHAI ZH, ZHAO ZH B, et al. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis[J]. Nature Communications, 2024, 15(1): 4332.
- [26] ZHU J G, WANG Y X, HUANG Y, et al. Data-driven capacity estimation of commercial lithium-ion batteries from voltage relaxation[J]. Nature Communications, 2022, 13(1): 2261.
- [27] SEVERSON K A, ATTIA P M, JIN N, et al. Data-driven prediction of battery cycle life before capacity degradation[J]. Nature Energy, 2019, 4(5): 383-391.
- [28] WANG F J, ZHAO ZH B, ZHAI ZH, et al. Explainability-driven model improvement for SOH estimation of lithium-ion battery[J]. Reliability Engineering & System Safety, 2023, 232: 109046.
- [29] OUYANG T CH, WANG CH CH, XU P H, et al. Prognostics and health management of lithium-ion batteries based on modeling techniques and Bayesian approaches: A review[J]. Sustainable Energy Technologies and Assessments, 2023, 55: 102915.
- [30] DeepSeek-AI, LIU AI X, FENG B, et al. DeepSeek-V2: A strong, economical, and efficient mixture-of-experts language model[J]. ArXiv preprint arXiv: 2405.04434, 2024.
- [31] DeepSeek-AI, LIU AI X, FENG B, et al. DeepSeek-V3 technical report[J]. ArXiv preprint arXiv: 2412.19437, 2024.
- [32] SU J L, LU Y, PAN SH F, et al. RoFormer: Enhanced Transformer with rotary position embedding[J]. ArXiv preprint arXiv: 2104.09864, 2023.
- [33] JAFARI S, KIM J, BYUN Y C. A novel fusion-based deep learning approach with PSO and explainable AI for batteries state of charge estimation in electric vehicles[J]. Energy Reports, 2024, 12: 3364-3385.

作者简介



E-mail:jiaojinyang@buaa.edu.cn

焦金阳(通信作者),2015年于中国石油大学(华东)获得学士学位,2020年于西安交通大学获得博士学位,现为北京航空航天大学可靠性与系统工程学院副教授,主要研究方向为人工智能、机械故障诊断及状态预测。

Jiao Jinyang (Corresponding author) received his B.Sc.

degree from China University of Petroleum (East China) in 2015, his Ph. D. degree from Xi'an Jiaotong University in 2020. He is currently an associate professor in School of Reliability and Systems Engineering at Beihang University. His main research interests include artificial intelligence, machine fault diagnosis and condition prediction.



黄珊,2024 年于东北林业大学获得学士学位,目前正在北京航空航天大学可靠性与系统工程学院攻读电子信息硕士学位,主要研究方向为大语言模型、电池健康状态预测。

E-mail:hshan0322@ buaa. edu. cn

Huang Shan received her B.Sc. degree from Northeast Forestry University in 2024. She is currently a master's candidate in School of Reliability and Systems Engineering at Beihang

University. Her main research interests include LLMs and state-of-health prediction for batteries.



李豪,2020 年于北京航空航天大学获得学士学位,目前正在北京航空航天大学攻读机械工程博士学位,现为北京航空航天大学可靠性与系统工程学院博士研究生,主要研究方向为信号处理、深度学习在机械故障诊断与预测中的应用。

E-mail:buaalihao@ buaa. edu. cn

Li Hao received his B.Sc. degree from Beihang University in 2020. He is currently pursuing his Ph. D. degree in mechanical engineering at Beihang University. He is currently a Ph. D. candidate in School of Reliability and Systems Engineering at Beihang University. His main research interests include signal processing and deep learning for mechanical fault diagnosis and prognosis.