

基于 LSTM 及注意力机制的锂电池健康状态预估

刘 晨

(河南理工大学计算机科学与技术学院, 河南 焦作 454000)

摘要: 锂离子电池健康状态(SOH)的精确预测对电池管理系统至关重要。现有基于深度学习的预测方法主要关注单一时间尺度特征,难以同时捕获电池退化过程中的多尺度动态特征。针对这一问题,提出一种基于多尺度注意力机制的 SOH 预测模型(MSANet)。该模型采用短期、中期、长期 3 个并行注意力模块捕获不同时间尺度特征,通过自适应特征融合策略实现了对电池状态的全面建模。同时,引入双向 LSTM(长短期记忆网络)和低秩自适应(LoRA)技术提升了模型的特征提取能力和参数效率。在 NASA(美国国家航空和宇宙航行局)电池数据集上的实验表明,该方法预测精度与效率优于 LSTM 预测方法,为电池健康状态评估提供了新的解决方案。

关键词: 锂离子电池; 健康状态预测; 多尺度注意力机制; 时序预测; 低秩适应

中图分类号: TM912 **文献标志码:** A **文章编号:** 1671-1807(2025)15-0095-06

锂离子电池因其高能量密度、长循环寿命和环境友好等优势,在电动汽车、储能系统和便携式电子设备等领域得到广泛应用。截至 2025 年 2 月 25 日,据国际权威机构 SNE Research 公布,宁德时代储能电池出货量达 256.4 GWh,相当于一次可存储 2.5 亿 kW·h 电,可为一座 500 万人口的中型城市提供 17 d 电力,充分展现了锂电池技术在大规模能源存储领域的巨大潜力。电池健康状态(state of health, SOH)的估计是电池管理系统的重要组成部分,是实现电池管理系统智能监控和科学运营的基础^[1],其精确预测对于保障能源系统可靠性、优化电池使用寿命以及降低维护成本具有重要战略意义。以中电联牵头建设的国家电化学储能平台为例,该平台通过集成物联网、大数据、云计算及人工智能等前沿技术,以储能电站安全风险为核心监测对象,实现了电化学储能电站安全信息数据的全面采集与深度分析,为行业储能电站安全管理水平的系统性提升提供了坚实的技术支撑,推动了整个储能产业的健康可持续发展。

然而,由于电池老化机理呈现出明显的复杂性、工作环境的多变性以及性能衰退过程的强非线性特征,准确预测 SOH 仍面临诸多技术挑战,亟须开发更加精确、高效的预测方法以满足不断增长的实际应用需求。

基于物理模型的 SOH 预测方法主要包括等效

电路模型(equivalent circuit model, ECM)和电化学模型(electrochemical model, EM)。这类方法基于电池内部物理化学过程建立数学模型,具有明确的物理意义。基于 EM 的方法利用复杂偏微分方程模拟电池内部发生的电化学反应过程,有助于了解电池潜在的退化机制。基于 ECM 的方法使用电阻、电容等电路元件描述电池的动态行为,计算复杂度较低,便于在工程实践中应用。Hosseinasab 等^[2]提出了一种基于分数阶电池 EM 模型的估计方法,同时以电池容量和内阻作为健康因子估计 SOH。首先从控制伪二维模型的偏微分方程推导出分数阶电池模型。其次,采用基于迭代模型的观测器进行电阻估计,实现对电池容量和电阻的自适应估计。

近年来,随着大数据和人工智能技术的快速发展,数据驱动方法为解决电池 SOH 估算这一复杂非线性问题提供了新的思路。基于数据驱动的 SOH 估算技术主要是通过采集电池在使用过程中的电流、电压和温度等参数,从中提取能够反映 SOH 变化规律的特征,将这些特征作为训练数据来构建估算模型,最终实现对锂电池 SOH 的准确预测。与传统的基于模型的方法相比,数据驱动方法不需要对电池内部复杂的电化学反应过程进行详细建模,也不需要进行烦琐的电池参数辨识,因此具有更好的可迁移性、鲁棒性和泛化能力。

收稿日期: 2025-01-08

作者简介: 刘晨(1988—),男,河南洛阳人,硕士研究生,研究方向为深度学习技术应用。

要使用数据驱动方法准确估算锂电池 SOH,关键在于能否提取出与电池容量退化高度相关的特征参数。Xia 和 Qahouq^[3]通过实验研究发现,当用于训练 SOH 估算算法的输入特征越丰富多样,估算性能就能得到越好的提升。基于这一发现,研究人员开始尝试提取多种特征参数来提高估算方法的精度,如从充放电曲线中提取特征、关注阻抗特性、综合考虑温度变化的影响等。

尽管 SOH 预测技术取得了显著进展,但仍面临诸多挑战。①多尺度建模能力不足。电池退化表现出明显的多尺度特性,短期尺度上受充放电工况影响产生波动,中期尺度上表现为循环间的性能差异,长期尺度上呈现容量持续衰减趋势。例如,潘子良等^[4]采用 LSTM 网络捕获锂电池序列特征;陈秀秀和朱凯^[5]利用注意力机制提取关键时序模式。但这些方法难以全面把握电池退化过程中的多尺度特征,限制了预测精度的进一步提升。现有方法多从单一时间尺度建模,难以全面刻画这种多尺度动态特征。②计算效率与精度的权衡。基于物理模型的方法计算开销大,而深度学习方法虽然推理快速但训练成本高。如何在保持预测性能的同时提升计算效率,是实际应用中的关键问题。③泛化能力有限。纯数据驱动方法在面对新型电池或非标准工作条件时泛化性能差,而物理模型的参数标定过程烦琐。

针对锂电池健康状态预测中的多尺度特征捕获不足、计算效率低下等问题,本文提出一种基于多尺度注意力机制的 SOH 预测框架(multi-scale attention net, MSANet),该框架主要有以下创新点。

(1)自适应多尺度特征建模机制,构建了 3 路并行的注意力模块架构,分别以不同的时间采样率(实现对电池退化过程中短期波动特征、中期循环差异特征和长期退化趋势特征的自适应提取。相较于现有单一时间尺度的建模方法,该机制能够全面捕获电池性能衰退过程中的多尺度动态特征,提高了模型对复杂退化过程的表征能力。

(2)将大规模语言模型中的低秩适应技术(low-rank adaptation, LoRA)引入电池健康状态预测领域,通过将原始高维权重矩阵分解为预训练权重与低秩更新矩阵之和,实现了模型参数数量的大幅降低,显著提升了训练和推理效率,同时保持了模型的表达能力。

(3)基于残差连接的特征融合策略,设计了一种基于特征重要性的多尺度特征自适应融合机制,通过

线性变换层学习不同尺度特征的重要性权重,结合残差连接机制将原始特征与融合特征相结合,既保留了原始输入信息,又强化了多尺度特征的表达能力。融合后的特征经过层归一化进一步提高了特征分布的稳定性,增强了模型的收敛性和泛化能力。

(4)双向时序建模与注意力协同机制,将双向 LSTM 与多尺度注意力机制进行深度融合,通过双向长短期记忆(long short term memory, LSTM)捕获前向和后向的长期依赖关系,结合多尺度注意力机制对关键时序模式的自适应识别,构建了一种时序建模与注意力协同的混合架构,能够更全面地感知电池性能退化过程中的复杂非线性时序模式,为 SOH 精确预测提供了更丰富的时序上下文信息。

1 相关技术

1.1 基于深度学习的 SOH 预测方法

近年来,深度学习在电池 SOH 预测领域得到广泛应用。例如,郝晓亮^[6]提出了一种基于 LSTM 的电池容量预测方法,使用遗传算法对 LSTM 网络搭建时的相关参数进行了寻优。张浩等^[7]进一步将 Bi-LSTM 与残差连接相结合,在 NASA 数据集上将预测准确率进一步提高。

注意力机制的引入为提升模型性能提供了新思路。罗鹏等^[8]设计了一种基于自注意力的 SOH 预测模型,通过计算不同时刻特征的相关性来识别关键模式。戴俊彦^[9]提出了双头注意力与 LSTM 相结合的混合架构,在处理非线性特征时表现出色。这些研究表明,注意力机制能够帮助模型更好地理解数据内在的时序依赖关系。

1.2 LoRA 低秩适应技术

LoRA 是一种用于大型语言模型的参数高效微调技术。其核心思想是通过冻结预训练模型的权重,并在每个 Transformer 层中注入可训练的低秩分解矩阵,从而显著减少下游任务所需的可训练参数数量^[10]。LoRA 通过低秩适应技术有效地解决了大型语言模型在微调过程中面临的参数量大、计算复杂度高等问题,使其能够在各种硬件平台上更高效地部署和应用。LoRA 技术在大规模语言模型微调中表现出较高的效率、更强的泛化能力和更好的适应性,尤其适用于需要高效资源利用和特定领域应用的场景。然而,在一些通用任务中,全量微调方法仍可能有其独特的优势。

2 MSANet 方法

2.1 网络结构

MSANet 总体结构如图 1 所示,包含双向

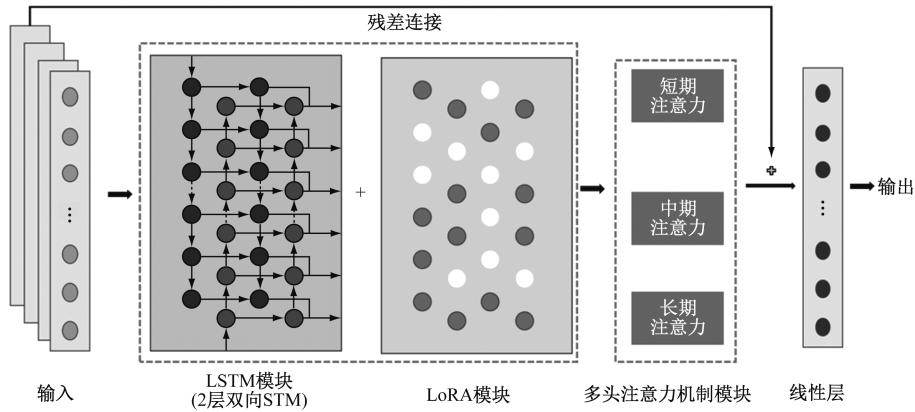


图 1 MSANet 总体结构

LSTM 结构、LoRA 低秩适应模块和多尺度注意力机制模块。

双向 LSTM^[11]能够捕获数据中的长期依赖关系,通过同时从前向和后向处理序列数据,可以获得更完整的上下文信息,对于 SOH 预测这种时序任务特别有效。LoRA 模块的作用是参数压缩,通过低秩分解将原始高维权重矩阵分解为两个低秩矩阵的乘积,大大减少了参数量,提高计算效率。多尺度注意力机制中,短期注意力关注当前时刻附近的局部特征,捕获瞬时变化信息,有助于检测突发性能变化。中期注意力每隔 2 个时间步抽取特征,捕获中等时间跨度的变化规律,平衡局部和全局特征的表达。长期注意力每隔 4 个时间步抽取特征,捕获长期趋势和周期性变化,有助于理解电池性能的长期退化趋势。三者结合既保证了预测精度,又确保了计算效率,同时具备了较强的泛化能力。

2.2 多尺度注意力机制

本文设计的多尺度注意力机制能够同时捕获锂电池性能衰退过程中不同时间尺度的动态特征。该机制由 3 个并行的注意力分支组成,分别针对短期、中期和长期时间尺度的特征提取,从而实现对电池退化过程的全面建模。多尺度注意力机制结构如图 2 所示。

在短期注意力分支中,模型直接处理原始序列数据,通过自注意力机制计算当前时刻与相邻时间步的关联强度。模型能够捕获充放电过程中的瞬时变化,如突发性能波动或局部退化特征,有助于提高模型对短期性能变化的响应能力。

中期注意力分支首先对输入序列进行降采样处理,采样间隔设为 2 个时间步,这种策略在保留关键信息的同时降低了计算复杂度。降采样后的序

列经过自注意力层处理,捕获中等时间跨度的变化模式,如循环间的性能差异。处理后的特征通过线性插值恢复到原始序列长度,确保与其他分支的特征维度一致。

长期注意力分支采用更大的采样间隔(4 个时间步),专注于提取序列中的长期依赖关系。这种设计使得模型能够有效识别电池容量的长期衰减趋势和周期性变化模式,为预测电池的长期性能演变提供重要依据。

为了整合不同时间尺度的信息,本文设计了特征融合模块。该模块首先将 3 个分支的输出特征进行拼接,然后通过线性变换层学习不同尺度特征的重要性权重。同时引入残差连接机制,将原始输入特征与融合后的特征相加,这种设计既保留了原始信息,又强化了多尺度特征的表达能力。最后通过层归一化确保特征分布的稳定性。

通过这种多尺度注意力机制的设计,模型能够自适应地关注不同时间尺度上的关键信息,实现了对电池退化过程的精细建模。实验结果表明,该机制相比单一时间尺度的方法能够取得更好的预测性能。

2.3 LoRA 模块

LoRA 技术的核心思想是将神经网络中的权重矩阵分解为低秩形式(图 3),从而显著减少可训练参数的数量,即

$$\mathbf{W} = \mathbf{W}' + \mathbf{A}\mathbf{B} \quad (1)$$

式中:原始权重矩阵 $\mathbf{W} \in \mathbf{R}^{d \times k}$, d 为输出特征维度, k 为输入特征维度; $\mathbf{W}' \in \mathbf{R}^{d \times k}$ 为低秩参数更新矩阵; $\mathbf{A} \in \mathbf{R}^{d \times r}$ 为下投影矩阵,其秩为 r 且满足 $r \ll \min(d, k)$,而 $\mathbf{B} \in \mathbf{R}^{r \times k}$ 为上投影矩阵,其维度与 \mathbf{W} 相同。这种分解方式可以有效减少需要训练的参数数量,同时保留大部分原始模型的知识,在实际

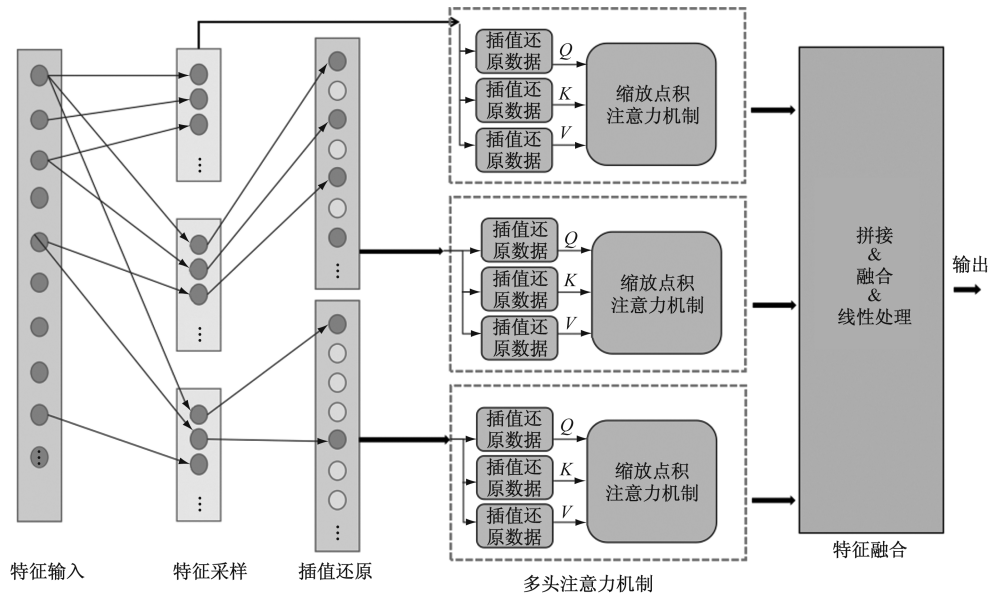


图 2 多尺度注意力机制结构




图 3 LoRA 原理示意图

应用中 LoRA 通过在模型的特定层(如 Linear 层)旁增加一个“旁支”,即通过矩阵 **A** 和 **B** 的乘积来实现对输入数据的变换。公式如下:

$$y \approx W + \beta AB \quad (2)$$

式中: **y** 为输入向量; β 为缩放因子。

3 实验结果

3.1 数据集和预处理

使用 NASA 电池数据集进行实验。该数据集包含了多组锂离子电池在室温下循环充放电的测试数据,常用于研究锂离子电池的老化特性,包括充放电循环数据和电池性能退化。选取 B0005 和 B0006 两组电池数据进行实验,B0005 和 B0006 为 18650 型锂钴氧化物电池,额定容量分别为 2.0 A·h 和 1.9 A·h,内阻约为 42 m·Ω 和 39 m·Ω,工作电压范围为 2.7~4.2 V,在恒流恒压充电和 2 A 恒流放电条件下,B0005 循环 168 次后容量衰减至初始值的 74.2%,B0006 同样循环次数后容量维持在初始值的 82.4%,展现出相似但不同程度的退化特性。其数据示例如图 4 所示,分别作为训练集和测试集。在数据预处理阶段,首先提取放电数据中的循环次

数(cycle)、容量(capacity)、测量电压(voltage_measured)、测量电流(current_measured)、测量温度(temperature_measured)、负载电流(current_load)、负载电压(voltage_load)和时间(time)作为特征,并计算健康状态指标 SOH 作为预测目标。随后对所有特征进行最小最大归一化处理,以消除不同量纲的影响。考虑到电池性能衰退的时序特性,采用滑动窗口法构建样本,窗口大小设为 20,即利用前 20 个时间步的特征预测当前时刻的 SOH 值,这样既保留了数据的时序依赖关系,又提供了充足的历史信息用于预测。

3.2 评价指标

RMSE(均方根误差)是评估回归模型性能的重要指标,它通过计算预测值与实际值之间的误差平方的平均值的平方根来衡量模型的预测精度。RMSE 的优势在于其结果与目标变量的单位一致,便于直观理解误差大小,并且对异常值敏感,能够有效惩罚较大的预测误差。这使得 RMSE 在模型评估中具有较高的实用性和可靠性。

3.3 实验结果

选用经典的 LSTM 网络作为基准模型。LSTM 凭借其门控机制能够有效捕获时序数据的长期依赖关系,在时序预测任务中已经得到广泛应用。本实验中的 LSTM 模型采用单层结构,隐藏层神经元数量为 30,输入特征维度为 8,采用 Adam 优化器进行训练,学习率设置为 0.01。

为了提升预测精度,使用了一种基于 CNN(卷

	cycle	capacity	voltage_measured	current_measured	temperature_measured	current_load	voltage_load	time
0	1	1.856 487	4.191 492	-0.004 902	24.330 034	-0.000 6	0	0
1	1	1.856 487	4.190 749	-0.001 478	24.325 993	-0.000 6	4.206	16.781
2	1	1.856 487	3.974 871	-2.012 528	24.389 085	-1.998 2	3.062	35.703
3	1	1.856 487	3.951 717	-2.013 979	24.544 752	-1.998 2	3.030	53.781
4	1	1.856 487	3.934 352	-2.011 144	24.731 385	-1.998 2	3.011	71.922
...
50 280	168	1.325 079	3.579 262	-0.001 569	34.864 823	0.000 6	0	2 781.312
50 281	168	1.325 079	3.581 964	-0.003 067	34.814 770	0.000 6	0	2 791.062
50 282	168	1.325 079	3.584 484	-0.003 079	34.676 258	0.000 6	0	2 800.828
50 283	168	1.325 079	3.587 336	0.001 219	34.565 580	0.000 6	0	2 810.640
50 284	168	1.325 079	3.589 937	-0.000 583	34.405 920	0.000 6	0	2 820.390

图 4 NASA 锂电池数据示例

积神经网络)-LSTM 的混合深度学习模型,命名为卷积多尺度融合与粒子群优化 LSTM,引入注意力机制进行特征融合与粒子群优化算法。使用多尺度特征提取结构,设计了短期(kernel_size=3)、中期(kernel_size=5)的平行卷积层,可以同时捕获不同时间尺度的特征模式。每个卷积分支后接 ReLU 激活函数、批归一化层和 Dropout 层以防止过拟合。

使用注意力机制对不同尺度的特征进行自适应融合,计算特征重要性权重,突出关键信息的贡献。包括注意力权重计算层、加权特征融合层、特征重构层,进行参数自动优化,引入粒子群优化算法(PSO)对模型关键超参数进行自动调优,包括 LSTM 隐藏层大小、学习率等参数。各方法比较结果见表 1。

原始模型结构中,需训练参数主要来自 LSTM 层(136 704 个)、线性变换层(8 192 个)、多尺度注意力层(49 152 个)和输出层(2 080 个),总计 196 128 个参数。通过引入 LoRA 技术这种低秩参数化方法使得可训练参数降至 52 768 个,减少了 73.1% 的参数量。参数规模的显著下降直接导致了计算复杂度和内存访问开销的相应减少,从而在保持预测精度的同时实现了训练效率的提升。

将本文模型应用在一个储能运营管理平台的 SOH 检测模块,使用本文模型与多种机器学习模型一起进行集成学习,深度学习模型和机器学习模型各有优势,将它们结合起来可以取长补短,获得更好的预测效果,提高预测的准确性和鲁棒性。

表 1 各方法比较结果

模型	RMSE	训练时长/s
LSTM ^[13]	0.157 3	1 069
卷积多尺度融合与粒子群优化 LSTM ^[13]	0.126 9	10 099
MSANet	0.085 2	331

4 结论

提出了一种基于深度学习的锂电池健康状态预测方法。首先,从原始数据中提取相关特征,并进行归一化处理。然后,采用滑动窗口方法构建多变量时间序列数据集。在模型设计上,使用双向 LSTM 作为基本单元,并引入 LoRA 技术减少参数量。同时,设计了一个多尺度注意力机制,用于捕捉不同时间尺度上的依赖关系。在电池健康状态预测任务上,该方法在训练集和测试集上都取得了良好的性能,证明了将 LoRA 和多尺度注意力机制应用于电池领域的有效性和可行性。

参考文献

- [1] 常伟,胡志超,潘多昭.基于多模型组合和 EIS 的锂电池 SOH 和 RUL 预测[J].科技和产业,2024,24(2):192-199.
- [2] HOSSEININASAB S, LIN C W, PISCHINGER S, et al. State-of-health estimation of lithium-ion batteries for electrified vehicles using a reduced-order electrochemical model[J]. Journal of Energy Storage, 2022, 52: 104684.
- [3] XIA Z Y, QAHOUC J A A. Lithium-ion battery ageing behavior pattern characterization and state-of-health estimation using data-driven method [J]. IEEE Access, 2021, 9: 98287-98304.
- [4] 潘子良,朱成杰,余梦书.基于贝叶斯优化 LSTM 的锂电池健康状态评估方法[J].仪表技术,2024(3):66-69.
- [5] 陈秀秀,朱凯.基于 CNN-LSTM 和注意力机制的锂电池健康状态评估[J].工业控制计算机,2022,35(12):80-82.
- [6] 郝晓亮.基于 LSTM 网络的锂离子电池健康状态估计研究[D].西安:西安理工大学,2023.
- [7] 张浩,胡昌华,杜党波,等.多状态影响下基于 Bi-LSTM 网络的锂电池剩余寿命预测方法[J].电子学报,2022,50(3):619-624.
- [8] 罗鹏,刘美俊,俞辉,等.基于注意力机制的 GRA-EMD-BILSTM 锂电池性能衰退趋势预测[J].电源技术,2023,

- 47(10): 1326-1331.
- [9] 戴俊彦, 夏明超, 陈奇芳. 基于双重注意力机制的电池SOH估计和RUL预测编解码模型[J]. 电力系统自动化, 2023, 47(6): 168-177.
- [10] HU J E, SHEN Y, WALLIS P, et al. LoRA: Low-rank adaptation of large language models[J]. ArXiv. abs/2106.09685, 2021.
- [11] 王铁君, 闫悦, 郭晓然, 等. 融合多尺度CNN与双向LSTM的唐卡问句分类模型[J]. 科学技术与工程, 2024, 24(22): 9490-9497.
- [12] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [13] 刘畅, 陈雯柏. 一种基于MSDCNN-LSTM的设备RUL预测方法[J]. 西北工业大学学报, 2021, 39(2): 407-413.

Lithium-ion Battery Health State Estimation Based on LSTM and Attention Mechanism

LIU Chen

(School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454000, Henan, China)

Abstract: Accurate prediction of lithium-ion battery state of health(SOH) is crucial for battery management systems. Existing deep learning-based prediction methods primarily focus on single temporal scale features, making it challenging to simultaneously capture multi-scale dynamic characteristics during battery degradation processes. To address this issue, a SOH prediction model based on multi-scale attention mechanism (MSANet) is proposed. The model employs three parallel attention modules - short-term, medium-term, and long-term - to capture features at different temporal scales, achieving comprehensive battery state modeling through an adaptive feature fusion strategy. Additionally, bidirectional LSTM(long short-term memory) and low-rank adaptation(LoRA) techniques are incorporated to enhance the model's feature extraction capability and parameter efficiency. Experiments on the NASA(National Aeronautics and Space Administration) battery dataset demonstrate that this method achieves superior prediction accuracy and efficiency compared to LSTM-based prediction methods, providing a novel solution for battery health state assessment.

Keywords: lithium-ion battery; state of health prediction; multi-scale attention mechanism; time series prediction; low-rank adaptation