

DOI:10.20189/j.cnki.CN/61-1527/E.202604004

基于 CNN-BiLSTM 的锂离子电池多状态联合预测方法

刘瀚儒¹, 智鹏鹏^{1,2,*}, 戎皓³, 焦胜⁴, 杨昌霖⁵

(1. 电子科技大学 长三角研究院(湖州), 湖州 313000;

2. 电子科技大学 广东电子信息工程研究院, 东莞 523808;

3. 陆军兵种大学, 合肥 230031;

4. 沪帆汽车电子系统有限公司, 湖州 313309;

5. 天能新能源(湖州)有限公司, 湖州 313099)

摘要: 针对锂离子电池健康状态(state of health, SOH)、荷电状态(state of charge, SOC)与能量状态(state of energy, SOE)协同预测困难的问题, 提出一种基于卷积神经网络和双向长短期记忆(convolutional neural network-bidirectional long short-term memory, CNN-BiLSTM)的电池多状态联合预测方法。首先, 针对充放电运行数据中多维健康特征冗余和相关性较强的问题, 分析能够反映电池状态的多维度特征参数, 并采用核主成分分析法对其进行非线性降维, 从而构建表征电池退化特性的低维特征空间; 然后, 利用 CNN 提取数据局部时序特征, 结合 BiLSTM 挖掘退化过程中的前后关联信息, 并引入退化感知自注意力机制与加权均方误差损失函数来增强模型对电池老化后期关键退化特征的代表能力和样本关注程度; 最后, 将预测得到的 SOH 作为动态边界约束引入 SOC 与 SOE 的估计过程, 构建多状态闭环联合预测框架。在 NASA 锂离子电池数据集上的实验结果表明: 所提方法对电池 SOH 预测结果的均方根误差为 0.013 8, 相较于次优方法 DAE-CNN-BiLSTM-Attention 降低了 27.7%; 在多状态协同估计中, 对电池 SOC 和 SOE 预测结果的均方根误差均为 0.003 1, 较次优方法分别降低了 26.19% 和 39.22%, 同时能够较好地跟踪电池退化趋势, 实现对电池多状态的协同准确预测。

关键词: 锂离子电池; 电池健康状态; 卷积神经网络; 长短期记忆网络; 状态预测

中图分类号: TK02

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2026)04-0056-15



听语音
与作者
聊科研

锂离子电池因具有能量密度高、循环寿命长、环境适应性强等优点, 已被广泛应用于电动汽车、储能系统及复杂装备供能等场景^[1-3]。随着使用需求的不断提高, 准确感知电池运行状态已成为保障系统安全性、可靠性和能量利用效率的重要基础^[4-6]。在电池管理过程中, 健康状态(state of health, SOH)反映电池容量衰减与寿命退化程度,

荷电状态(state of charge, SOC)描述当前剩余可用电量, 能量状态(state of energy, SOE)则用于刻画电池剩余可释放能量, 三者共同构成了电池运行状态评估的核心内容。

现有研究多将电池 SOC、SOH 和 SOE 的预测作为相对独立的问题分别进行建模。其中, 在 SOC 预测领域, 针对传统等效电路模型在复杂工况下参

收稿日期: 2026-03-30

修回日期: 2026-05-26

录用日期: 2026-06-24

基金项目: 广东省基础与应用基础研究基金(2025A1515010487); 湖州市重点研发计划(2024ZD2029)

第一作者: 刘瀚儒(2001—), 男, 硕士研究生, 主要从事智能航空装备结构可靠性、不确定性分析与优化研究。

* 通信作者: 智鹏鹏(1989—), 男, 副研究员, 主要从事智能航空装备结构可靠性、不确定性分析与优化研究。

引用格式: 刘瀚儒, 智鹏鹏, 戎皓, 等. 基于 CNN-BiLSTM 的锂离子电池多状态联合预测方法[J]. 火箭军工程大学学报, 2026, 40(4): 56-70. LIU Hanru, ZHI Pengpeng, RONG Hao, et al. Convolutional neural network-bidirectional long short-term memory-based multi-state joint prediction method for lithium-ion batteries[J]. Journal of Rocket Force University of Engineering, 2026, 40(4): 56-70.

数易漂移和估计精度受限的问题,吴波等^[7]提出基于扩展单粒子模型的参数辨识与 SOC 联合估计方法,其物理意义明确且能实现参数实时跟踪,但在极端温度变化或强非线性特征下该模型的拟合能力有限。在此基础上,夏雪磊等^[8]提出基于多新息最小二乘与多新息无迹卡尔曼滤波的联合估计算法,极大增强了模型在宽温域和全寿命周期下的收敛速度与抗噪鲁棒性,但多新息矩阵的引入显著增加了系统的计算复杂度。针对基于滤波的方法高度依赖精准物理先验、在未建模电化学动态下易发生估算失败的问题,研究人员将扩展卡尔曼滤波或无迹卡尔曼滤波与支持向量机、极限学习机及自适应神经网络相结合,提出模型-数据双驱动的估算方法^[9-11],巧妙结合了闭环滤波的反馈校正与智能算法的高精度拟合优势,有效克服了单一模型在温度突变或高极化区域下估算失准的缺陷,但网络训练与滤波器递推的耦合计算对硬件性能要求极为严苛。此外,Deng 和 Li 等^[12-13]分别提出基于高斯过程回归与粒子群优化-支持向量回归的数据驱动 SOC 估计方法,无需探究复杂的内部反应机理,具有极强的非线性映射能力,但其高度依赖于训练样本的覆盖丰度,在未知工况下的模型泛化能力有限。在电池 SOH 与剩余使用寿命预测领域,孙丙香与王长宏等^[14-15]针对电池在服役过程中容量衰退机理复杂、不同老化应力区间下衰退特征差异显著的问题,分析了不同区间应力下电池老化的影响因素,并提出了基于宏观退化经验模型的寿命与趋势预测方法,直观揭示了电池容量衰减与循环应力间的物理规律,但其在多物理场和复杂工况下的中长期预测易发生累积误差漂移。针对实测运行数据中普遍存在的大量测量噪声及“局部容量回弹”现象所导致的预测偏差过大等问题,苏康泽与张婷婷等^[16-17]分别提出结合数据平滑与混合函数退化模型、支持向量机的容量及寿命联合预测方法,通过有效剔除局部高频噪声干扰,显著提高了衰退轨迹捕捉的稳定性与长期预测精度,但模型性能对去噪算法的核心参数十分敏感。卓越等^[18]针对上述各类预测模型结构差异大、单一统计指标难以全面量化综合预测性能优劣的问题,提出基于综合预测性能的模型选择指标体系,实现对复杂工程场景下最优算法的客观量化遴选,但该体系的构建与应用需要以高度充分且多维度的评估数据作为支撑。以上方法在单状态预测领域中取得了一定进展,但电池退化具有明显的非

线性、时变性和多因素耦合特征,单一状态孤立建模难以反映不同状态量之间的内在联系。此外,随着循环老化加剧,电池最大可用容量和最大可用能量持续衰减,若 SOC 和 SOE 估计仍基于固定边界参数,则容易引入累计误差,影响长时间运行下的状态判断精度。

近年来,深度学习方法在电池状态估计领域中展现出较强的特征提取与非线性映射能力。针对原始非平稳老化序列中模态耦合复杂的问题,李嘉波等^[19]提出变模态分解下麻雀搜索算法优化组合的电池剩余使用寿命预测方法,通过有效剥离多尺度趋势项与波动干扰,显著提高了模型在非平稳退化序列下的预测精度,但模态分解等前置信号处理步骤显著增加了系统在线运行的计算开销。针对传统静态神经网络难以捕捉动态滞后特征的问题,Chen 等^[20]提出基于扩展输入、约束输出的长短期记忆网络,同时 Jiao 等^[21]提出基于动量优化门控循环单元的 SOC 估计方法,两者均能有效克服长序列训练中的梯度消失难题,增强时间记忆建模能力。李超然等^[22]提出基于卷积神经网络(convolutional neural network,CNN)的锂离子电池 SOH 估算方法,可从多维电信号中自动提取高阶深度特征,摆脱了对繁琐人工特征工程的依赖,但直接将原始时序信号输入网络易受高频测量噪声与模态混叠干扰,导致长程预测偏离^[23]。此外,鉴于 CNN 在局部空间特征筛选与处理过程中的出色表现^[24],研究人员提出了结合一维卷积与长短期记忆或双向长短期记忆网络(bidirectional long short-term memory,BiLSTM)的联合估算方法^[25-28],巧妙融合了 CNN 的空间特征挖掘优势与 BiLSTM 的双向动态时序记忆能力,大幅提升了复杂动态工况下模型的泛化性能,但多深度模型间串并联的级联结构大幅增加了网络的超参数量,在小样本数据集上易陷入过拟合。针对全寿命周期超长时序老化轨迹预测中传统循环结构存在长期信息遗忘、难以对不同衰退阶段中关键节点赋予动态关联权重的问题,李潇鹏和赵宇波等^[29-30]充分发挥融合注意力机制与全局信息捕捉在处理复杂长序列目标中的关键优势,分别提出基于全局自注意力机制、局部多尺度特征通道融合的 SOH 预测方法以及基于混合尺度健康因子的 LSTM-Transformer 复合寿命预测模型。此类方法利用自注意力机制有效打破了长时序建模的时间窗口限制,实现了对全局退化特征点及局部突变特征的自适应聚焦与关联建模,显著提高了

对寿命终点预测的绝对精度,但同时对电池管理系统的硬件底层算力和大规模实际运行数据储量提出了极为严苛的要求。

综上所述,现有深度学习算法在建立深层非线性特征映射关系上具有显著优势,但如何解决多网络协同建模所带来的高算力负担与轻量化部署需求之间的矛盾,仍是当前智能电池管理系统开发的核心难题。然而,面对电池退化后期的非平稳突变特征,现有模型仍然存在特征表达不充分、对关键退化阶段关注度不足以及泛化稳定性有限等问题。此外,如何将数据驱动预测结果与电池物理边界约束相结合,实现电池多状态高精度联合估计,仍是制约电池管理系统性能提升的关键技术问题。鉴于此,本文针对多维健康表征因子的冗余干扰与传统时序网络对长序列记忆失焦的问题,通过结合核主成分分析(kernel principal component analysis, KPCA)与退化感知自注意力机制(degradation-aware self-attention mechanism, DA-SAM)的联合架构,解决了高维输入耦合干扰下电池全生命周期退化特征捕捉困难的问题;针对算法对电池老化后期加速衰减阶段感知迟钝的问题,本文通过在深度网络中引入动态加权损失函数,强化模型对后期衰退区域的自适应聚焦学习,解决了临近寿命终点时模型对非线性突变拐点灵敏度不足与预测发散的问题;针对 SOC、SOH 与 SOE 独立开环估算导致累积误差失控的问题,通过将高精度的 SOH 实时估计值作为自适应边界参数动态引入 SOC 与 SOE 的能量校准流程,打破了单一状态建模的局限,实现了多状态闭环协同估计。

1 SOH 预测框架

为准确跟踪锂离子电池的全生命周期演化过程,需同时解决高维健康特征的多重共线性、长时序退化记忆的失焦缺陷以及开环状态估计中由基准漂移所引发的累积误差问题。为此,本文设计了一种基于 CNN-BiLSTM 和 DA-SAM 的电池多状态闭环联合预测框架。

1.1 特征提取与降维

1.1.1 多维健康特征提取

采集电池全生命周期循环充放电过程中的时序数据(包含电压 U 、电流 I 和温度 T),对其进行清洗并剔除异常循环数据。基于清洗后的时序数据,通过安时积分法计算电池实际放电容量,进而得到

电池的 SOH,数学表达式为

$$S_{\text{SOH}} = \frac{C_{N, \max}}{C_{\text{rated}}} \times 100\% \quad (1)$$

式中: $C_{N, \max}$ 为电池在第 N 次充放电循环下的实际最大放电容量; C_{rated} 为新电池的额定放电容量。伴随着电池的老化,充放电曲线会发生显著的形态演变。在电池循环充放电过程中,提取与 SOH 高度相关的多维健康特征参数,具体包括恒流充电时间(constant current charging time, CCCT)、恒流放电时间(constant current discharging time, CCDT)、恒压充电时间(constant voltage charging time, CVCT)、恒压上升充电时间(constant voltage rising time, CVRT)和恒压下降放电时间(constant voltage dropping time, CVDT)。

1.1.2 基于 KPCA 的特征解耦与非线性降维

鉴于所提取到的多维健康特征之间存在强多重共线性,采用 KPCA 对其进行非线性降维。该方法通过核函数将原始数据非线性映射至高维特征空间,从而实现对非线性特征的有效提取与解耦。设 $X = \{x_1, x_2, \dots, x_M\}$ 表示一组零均值数据。其中, M 为数据样本总数。特征空间中数据的协方差矩阵 C 可表示为

$$C = \frac{1}{M} \sum_{i=1}^M [\varphi(x_i) \varphi^T(x_i)] \quad (2)$$

式中: $\varphi(\cdot)$ 为点 x_i 到高维特征空间的映射函数。

将协方差矩阵通过特征值分解进行对角化处理,数学表达式为

$$\lambda A = CA \quad (3)$$

式中: λ 为协方差矩阵的特征值; A 为对应的特征向量。考虑到特征向量位于由 $\varphi(x_i)$ 张成的空间中,可将其线性表示为

$$A = \sum_{i=1}^M [\alpha_i \varphi(x_i)] \quad (4)$$

式中: α_i 为线性叠加系数。结合式(2)~(4)可得

$$\lambda \sum_{i=1}^M [\alpha_i \varphi(x_i)] = \frac{1}{M} \sum_{i=1}^M [\varphi(x_i) \varphi^T(x_i)] \cdot \sum_{i=1}^M [\alpha_i \varphi(x_i)] \quad (5)$$

定义核矩阵 K , 其元素 $K_{i,a} = \varphi(x_a) \cdot \varphi(x_i)$ 。若原始数据在特征空间中未完全中心化,则需对其进行修正,修正后的核矩阵 K' 中各元素为

$$K'_{i,a} = K_{i,a} - \frac{1}{M} \sum_{a=1}^M K_{i,a} - \frac{1}{M} \sum_{i=1}^M K_{i,a} + \frac{1}{M^2} \sum_{i,a=1}^M K_{i,a} \quad (6)$$

计算核矩阵 K' 的特征值和特征向量得到常系

数 α_i 后,训练样本在特征向量空间的投影即为降维后的主成分特征。

1.2 CNN-BiLSTM 和 DA-SAM 联合预测模型构建

1.2.1 输入特征矩阵

融合采集的时序数据、历史 SOH 值以及 KP-CA 降维后的特征向量,构建时间步为 t 的输入特征矩阵 $\mathbf{X}_t$ 为

$$\mathbf{X}_t = [\mathbf{U}_t, \mathbf{I}_t, \mathbf{T}_t, \mathbf{S}_{\text{SOH}}, \mathbf{F}_{\text{KPCA}}]^T \quad (7)$$

式中: $\mathbf{F}_{\text{KPCA}}$ 为经 KPCA 降维后的特征向量。

1.2.2 CNN 特征提取层

CNN 特征提取层旨在从原始冗杂且伴有高频传感噪声的电池多维充放电序列中,自动挖掘出对老化极度敏感的局部高阶特征。通过这种“局部感知-非线性转换-关键特征浓缩”的层级化处理方式, CNN 特征提取层彻底摆脱了对传统繁琐人工特征工程的依赖,为后续的时序记忆模型提供了高信噪比且具备极强判别力的空间深度特征向量。其中,第 l 层的传递与池化操作可表示为

$$\mathbf{f}_j^{(l)} = \sigma(\mathbf{W}_{ij}^{(l)} * \mathbf{f}_i^{(l-1)} + b_j^{(l)}) \quad (8)$$

$$\mathbf{p}_j^{(l)} = \text{maxpool}(\mathbf{f}_j^{(l)}) \quad (9)$$

式中: $\mathbf{f}_i^{(l-1)}$ 和 $\mathbf{f}_j^{(l)}$ 分别为上一层(第 $l-1$ 层)的第 i 个输入特征与当前层(第 l 层)的第 j 个输出特征; $\mathbf{W}_{ij}^{(l)}$ 和 $b_j^{(l)}$ 分别为权重矩阵和偏置; $*$ 为卷积运算; $\sigma(\cdot)$ 为 Sigmoid 激活函数; $\text{maxpool}(\cdot)$ 为最大池化操作; $\mathbf{p}_j^{(l)}$ 为降维后的输出特征。

1.2.3 BiLSTM 长期依赖捕捉层

BiLSTM 旨在克服传统单向时序网络难以全面捕捉电池长周期复杂衰退规律的局限。在标准 LSTM 基础上, BiLSTM 通过并联两套参数完全独立、信息传递方向截然相反的 LSTM 链条,打破了时序单向限制。正向 LSTM 按照充放电周期的自然顺序推进,专注捕捉电池从初始状态一步步累积的渐进式老化特征;反向 LSTM 则从序列末端逆向推演,对全局衰退拐点与中后期非线性加速演化进行全局轮廓感知。在每个离散时间步,正向与反向的隐藏状态最终被横向拼接融合,从而使网络在评估当前循环状态时,既拥有前向推演的历史记忆积累,又具备后向追溯的全局时序视野,显著提高了对复杂工况及寿命晚期加速衰减段的估计精度。BiLSTM 在时间步 t 的操作原理为

$$\mathbf{h}_t^{\text{fwd}} = f_{\text{LSTM}}(\mathbf{X}_t, \mathbf{h}_{t-1}^{\text{fwd}}) \quad (10)$$

$$\mathbf{h}_t^{\text{bwd}} = f_{\text{LSTM}}(\mathbf{X}_t, \mathbf{h}_{t+1}^{\text{bwd}}) \quad (11)$$

$$\mathbf{Y}_t = \mathbf{h}_t^{\text{fwd}} \oplus \mathbf{h}_t^{\text{bwd}} \quad (12)$$

式中: $f_{\text{LSTM}}(\cdot)$ 为复合运算函数; $\mathbf{h}_t^{\text{fwd}}$ 和 $\mathbf{h}_{t-1}^{\text{fwd}}$ 分别为 t 和 $t-1$ 时刻的前向 LSTM 的隐藏状态; $\mathbf{h}_t^{\text{bwd}}$ 和 $\mathbf{h}_{t+1}^{\text{bwd}}$ 分别为 t 和 $t+1$ 时刻的后向 LSTM 的隐藏状态; $\mathbf{Y}_t$ 为双向拼接融合后的输出序列。

1.2.4 DA-SAM 层

自注意力机制(self-attention mechanism, SAM)在处理等权重的时序特征时,容易忽略电池寿命末期的非线性加速老化现象。为使模型能够自适应地关注老化后期的关键特征突变,本文在标准 SAM 的基础上引入退化先验信息,构建 DA-SAM。

DA-SAM 在计算注意力得分时,不仅考虑了隐藏状态本身的特征,还额外引入了能够表征电池老化阶段的循环周期衰减因子 γ_t 。对于双向时序特征序列,其融合退化特征的注意力得分 e_t 为

$$e_t = \mathbf{v}^T \tanh(\mathbf{W}_h \mathbf{h}_t + \mathbf{W}_d \gamma_t + b) \quad (13)$$

式中: $\mathbf{W}_h$ 和 $\mathbf{v}$ 分别为对应的权重矩阵和特征映射向量; $\mathbf{W}_d$ 为退化因子的可训练权重矩阵; $\mathbf{h}_t$ 为 BiLSTM 在时间步 t 输出的特征表征向量; b 为偏置项; γ_t 为引入的循环周期衰减因子,其定义为当前循环次数 n 与预设最大循环次数 N_{max} 的指数比值,表达式为

$$\gamma_t = \exp\left(\frac{n}{N_{\text{max}}}\right) \quad (14)$$

随后,同样利用 Softmax 函数对修正后的得分进行归一化处理,获取退化感知的注意力权重 α_t 为

$$\alpha_t = \frac{\exp(e_t)}{\sum_{t=1}^u \exp(e_t)} \quad (15)$$

式中: u 为输入时间序列的总长度。

映射中间特征 ξ 为

$$\xi = \sum_{t=1}^u (\alpha_t \mathbf{h}_t) \quad (16)$$

最终输出门系数 o 为

$$o = \sigma(\mathbf{W}_o \xi + b_o) \quad (17)$$

式中: $\mathbf{W}_o$ 和 b_o 分别为输出门对应的可训练权重矩阵和偏置。为进一步整合时序上下文信息,将输出门系数 o 与 BiLSTM 最后一个时间步的隐藏状态进行拼接,并输入全连接层以生成最终的预测结果。

1.3 基于多重约束的 SOC 与 SOE 闭环联合预测

为打破多性能指标孤立评估的局限,本文将深度学习高保真预测出的当前宏观 SOH 作为底层物理边界,动态刷新 SOC 与 SOE 的积分上限,形成联合估计闭环,数学表达式为

$$S_{\text{SOC},k+p}^N = S_{\text{SOC},k}^N - \frac{1}{S_{\text{SOH}} \cdot C_{\text{rated}}} \sum_{i=1}^p I_{k+i}^N \Delta t' \quad (18)$$

$$S_{\text{SOE},k+p}^N = S_{\text{SOE},k}^N - \frac{1}{S_{\text{SOH}} \cdot E_{\text{max}}} \sum_{i=1}^p V_{k+i}^N I_{k+i}^N \Delta t' \quad (19)$$

式中: $S_{\text{SOC},k}^N$ 和 $S_{\text{SOE},k}^N$ 分别为第 N 个充放电周期下当前离散时间步 k 时刻的电池 SOC 与 SOE; $S_{\text{SOC},k+p}^N$ 和 $S_{\text{SOE},k+p}^N$ 分别为从当前时刻 k 经过 p 个时间步长演进后,未来的第 $k+p$ 时刻下电池的 SOC 与 SOE; $\Delta t'$ 为采样时间间隔; E_{max} 为新电池最大可用能量。通过动态引入 SOH 修正积分边界,可在一定程度上减弱长时间累积积分所带来的容量基准漂移误差。

1.4 模型优化策略与精度验证

1.4.1 正则化及超参数寻优

为抑制模型过拟合并提升其泛化鲁棒性,引入复合正则化体系。设原始损失函数为 $L_0(w, b)$, 则引入 L2 正则化后的总损失函数可表示为

$$L(w, b) = L_0(w, b) + \frac{\lambda}{2} \sum w_i^2 \quad (20)$$

式中: w 为权重; b 为偏置; λ 为 L2 正则化系数,用于控制惩罚强度; $\sum w_i^2$ 为所有权重参数的平方和。

从梯度下降的角度看, L2 正则化的作用机制更加直观。在每次参数更新时,权重 w 的梯度不仅包含原始损失函数的梯度,还包含正则化项的贡献,权重梯度公式为

$$\frac{\partial L(w, b)}{\partial w} = \frac{\partial L_0(w, b)}{\partial w} + \lambda w \quad (21)$$

式中: $\frac{\partial L(w, b)}{\partial w}$ 为总损失函数关于权重参数 w 的梯度; $\frac{\partial L_0(w, b)}{\partial w}$ 为原始损失函数关于权重参数 w 的梯度。

权重更新公式为

$$w_{t+1} = w_t - \eta \frac{\partial L(w_t, b_t)}{\partial w_t} \quad (22)$$

式中: η 为模型训练学习率; w_{t+1} 为更新后的权重; w_t 为更新前的权重; $L(w_t, b_t)$ 为更新前权重对应的总损失函数。

在前向传播过程中, Dropout 层以保留概率或丢弃率随机将某些神经元的输出置为零。被置零的神经元在当前迭代中不参与前向传播和反向传播,相当于暂时从网络中移除。Dropout 层的输出

结果 y 为

$$y = a \odot m \quad (23)$$

式中: a 为上一层网络的激活输出; m 为与 a 同维度的二进制掩码向量,其每个元素独立服从伯努利分布; $\odot$ 为逐元素相乘运算符号。

随后,以验证集上预测结果的平均绝对误差 (mean absolute error, MAE) 最小为目标,使用遗传算法对正则化后的 CNN-BiLSTM-DA-SAM 混合深度学习模型的超参数进行全局优化,得到其最优取值。

超参数包括 CNN 卷积核数量、BiLSTM 隐藏单元数、初始学习率、L2 正则化系数、Dropout 比率和批大小。超参数搜索区间的设定综合考量了深度学习网络容量与底层工程约束。结合一维时序信号特征维度较浅的物理特性,合理限定 CNN 卷积核与 BiLSTM 隐藏单元等网络规模的上下限,既保障了模型捕捉复杂非线性极化特征的最小表征能力(防欠拟合),又避免了网络过拟合高频量测噪声,而学习率与正则化参数区间则严格依据梯度动力学与结构风险最小化理论进行界定。超参数选取范围如表 1 所示。

表 1 超参数选取范围

Table 1 Range of hyperparameter values

序号	参数名称	选取范围
1	CNN 卷积核数量	16~128
2	BiLSTM 隐藏单元数	5~50
3	初始学习率	0.000 1~0.1
4	正则化系数	$10^{-6} \sim 10^{-2}$
5	Dropout 比率	0.1~0.5
6	批大小	16~128

1.4.2 老化加权损失函数

在模型训练阶段,传统的深度学习预测模型多采用均方误差 (mean squared error, MSE) 作为损失函数。然而,电池在寿命初期的 SOH 退化相对平稳,而在寿命中后期受极化内阻增加及活性物质加速剥离的影响,SOH 曲线会出现剧烈波动。若采用全局统一权重的 MSE,模型容易被早期的大量平稳数据所主导,导致模型对中后期电池状态预测严重失准。

为解决这一问题,本文提出了一种老化加权损失函数 (Weighted-MSE)。该函数根据真实 SOH 标签的数值大小,动态赋予不同的误差惩罚权重 ω'_i ,老化加权损失 L_{WMSE} 的数学表达式为

$$L_{\text{WMSE}} = \frac{1}{B} \sum_{i=1}^B \omega'_i (y_i - \hat{y}_i)^2 \quad (24)$$

式中: y_i 为第 i 个样本的真实 SOH 值; $\hat{y}_i$ 为预测的 SOH 值; B 为批次样本总数。惩罚权重 ω_i' 的表达式为

$$\omega_i' = 1 + \lambda' \exp(-\beta y_i) \quad (25)$$

式中: λ' 和 β 为调节超参数, 设定 $\lambda' = 2.0$, $\beta = 5.0$ 。该机制的物理意义在于: 当电池真实状态 y_i 较高时, 惩罚权重 ω_i' 趋近于 1, 等效于传统 MSE; 当电池健康状态 y_i 降低时, 指数项使得惩罚权重 ω_i' 显著增加。这一非对称惩罚机制强制引导网络在反向传播时向老化后期的局部特征波动倾斜, 从而大幅提升模型对早期失效的预警敏锐度。

1.4.3 模型精度评价指标

本文通过均方根误差 (root-mean-square error, RMSE) 及 MAE 来评价模型的精度, 其计算方法为

$$E_{\text{RMSE}} = \sqrt{\frac{1}{M'} \sum_{i=1}^{M'} (y_i - \hat{y}_i)^2} \quad (26)$$

$$E_{\text{MAE}} = \frac{1}{M'} \sum_{i=1}^{M'} |y_i - \hat{y}_i| \quad (27)$$

式中: M' 为用于计算误差的样本总数。

为进一步从拟合优度和稳健性角度评估模型表现, 本文引入决定系数 R^2 和相对分析误差 (relative percent deviation, RPD) $E_{\text{RPD},i}$ 作为补充评价指标, 其计算公式分别为

$$R^2 = \frac{\sum_{i=1}^{M'} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{M'} (y_i - \bar{y})^2} \quad (28)$$

$$E_{\text{RPD},i} = \frac{|y_i - \hat{y}_i|}{\sigma_a} \quad (29)$$

式中: $\bar{y}$ 为第 i 个样本的平均值; σ_a 为预测误差的标准差。

1.5 电池多状态联合预测方法

综上所述, 基于 CNN-BiLSTM 和 DA-SAM 的锂离子电池多状态联合预测方法流程如图 1 所示, 具体步骤如下。




图 1 基于 CNN-BiLSTM 和 DA-SAM 的电池多状态预测方法流程

Fig. 1 Flowchart of the CNN-BiLSTM and DA-SAM-based battery state prediction method

1)数据采集与预处理:采集电池全生命周期充放电数据,完成异常值剔除、归一化处理及 KPCA 非线性降维,完成样本集构建。

2)CNN 局部特征提取:利用一维卷积层沿时间步滑动,自动提取关键极化波形特征,随后通过池化层下采样降维并去除高频抖动,最后由展平层压缩为一维关键特征向量。

3)BiLSTM 长期依赖捕捉:将展平后的特征输入双向长短期记忆网络,正向链条负责捕捉电池从早至晚的正向累积老化演进,逆向链条负责倒推感知中后期的加速衰减拐点,从而获取兼顾历史记忆与未来趋势的全局时序特征。

4)Attention 特征权重分配:将所有时间步的隐藏状态序列送入退化感知自注意力层,打破传统等权限制,模型能够识别出老化后期的高风险衰退特征,并为其分配更高的关键注意力权重。

5)全连接层特征交叉整合:经过注意力加权后的综合退化向量进入全连接层,依靠多层神经元将局部波形特征、双向记忆特征与关键阶段权重进行深度交叉映射与融合。

6)输出层定量状态预测:将全连接层整合完成的高阶表征输入末端映射层,直接定量输出高精度的电池 SOH 预测结果向量。

7)模型训练与参数优化:采用加权损失函数、正则化策略和遗传算法完成模型训练与超参数寻优,直至模型误差满足要求,可以实现对电池实时 SOH 的精准推断。


8)多状态联合估计:将预测 SOH 作为动态边界约束,联合完成对 SOC 与 SOE 的估计。

2 实验验证与结果仿真


2.1 参数及数据集介绍

作为电子元器件的核心动力来源,锂离子电池的 SOH 直接决定着设备的续航能力和运行效能。为此,本文采用 NASA 公开的 B0006 锂离子电池退化数据集,通过提取电池全生命周期的充放电数据,以电池状态精确预测为目标,验证本文所提方法的有效性。该电池额定容量为 2 Ah,充电过程采用 1.5 A 恒流充电至 4.2 V 后转入恒压充电,直至电流降至 20 mA,放电过程采用 2 A 恒流放电至 2.5 V。


以 B0006 电池全生命周期充放电数据为研究对象,对其运行特征和状态演化规律进行分析,结果如图 2 所示。




(a) 充电电流随循环次数的变化特征



(b) 电池容量增量特征



(c) 电池充放电提取特征



(d) SOE 健康状态

图 2 电池具体运行数据

Fig. 2 Specific operational data of the battery

图 2 综合反映了电池在 160 余次循环中的老化特征与 SOH 演变过程。就充放电动力学演变而言,如图 2(a)所示,随着循环次数的增加,充电电流曲线整体向时间轴左侧平移。结合图 2(c)提取的特征时间可知,恒流充电时间呈现显著缩短趋势,而恒压阶段充电时间明显延长,表明电池的电荷接收能力与恒流充电容量发生严重衰退。这是因为电池在大电流充放电下过电位显著增大,导致端电压更快触及截止电压上限,从而迫使电池过早退出恒流阶段并进入扩散控制的恒压阶段。其次,为进一步解耦容量衰减的微观机理,图 2(b)的容量增量(incremental capacity, IC)曲线展示了关键的热力学特征变换。随着电池老化加剧,IC 曲线主峰峰值大幅降低,且峰位向高压侧偏移,表明了循环过程中活性锂离子的不可逆消耗与正负极活性材料的剥落损失,而峰位向高压侧偏移则从热力学角度再次印证了系统极化阻抗的增加。如图 2(d)所示,在内外阻抗激增与可用活性锂损耗的双重主导下,一次充放电循环下电池 SOE 由初始的 1.0 线性衰减至接近 0.2。

电池 SOH 演变过程如图 3 所示,从整体趋势与老化结果来看,电池 SOH 在充放电循环过程中伴有局部容量恢复现象,在第 60 余次循环时跌破 0.8,并最终降至 0.6 以下。从局部动态现象观察,衰减曲线伴随多次显著的脉冲式反弹尖峰。究其内在电化学原因,这种局部“容量再生”现象是由测试过程中的间歇性静置休眠引起的,即长时间的静置促使电极内部固相扩散弛豫充分释放,浓差极化得以消除,被偏析或束缚的活性锂离子短暂恢复热力学平衡分布,从而表现为容量的暂态回升。这种耦合轨迹,不仅真实揭示了电池老化的物理本质,同时也对后续 SOH 估算模型的抗扰动与平滑追踪能力提出了严峻考验。




图 3 电池 SOH 演变

Fig. 3 Evolution of battery SOH

因锂电池充放电曲线的多维健康特征之间存在较强的关联性,本文采用 KPCA 算法对其进行降维,提取累积贡献率超过 90% 的核心主成分,作为后续 CNN 网络的输入特征。各主成分的贡献率如图 4 所示。




图 4 KPCA 贡献率分析结果

Fig. 4 Analysis results for KPCA contribution rate

如图 4 所示,CCCT、CCDT 和 CVCT 的贡献率分别为 58.3%、24.7% 和 7.3%,前 3 个主成分的累计贡献率达到 90.4%。因此,本文采用前 3 个主成分即可保留原始健康特征中的主要信息,为后续模型训练提供较为紧凑的输入表示。为证明所提 KPCA 的有效性,不同降维策略的对比结果如表 2 所示。

表 2 不同降维策略结果对比

Table 2 Comparison of results under different dimensionality reduction strategies

降维策略	输出维度	训练时间/s	MAE
无降维	8	187	0.015 6
PCA	3	156	0.013 2
KPCA	3	142	0.010 7

由表 2 可得,采用 KPCA 对电池多维健康特征进行降维处理后,模型的预测精度与训练效率均显著优于传统 PCA 及无降维策略,原因在于 KPCA 能够成功捕捉电池老化的深层非线性映射关系。传统 PCA 受限于线性正交投影,在处理极具非线性特性的充放电特征时,极易丢失关键耦合特征,而 KPCA 将低维数据映射至高维空间,实现了高效的非线性解耦与高频去噪。这种高质量的主成分表征不仅剔除了冗余误差,使预测的平均绝对误差缩

减了 31.41%，还进一步加速了下游模型的梯度收敛，实现了精度与效率的双重突破。

2.2 模型对比实验

为保证模型能够充分挖掘多维时序数据特征并实现稳定收敛，结合模型结构特性，本文对核心网络参数与训练选项进行了设置。1) 特征提取部分：CNN 层配置了 32 个大小为 1×2 的卷积核，卷积步长、膨胀因子以及池化窗口大小均设定为 1，并选用 ELU 作为激活函数以缓解梯度消失问题。2) 捕捉时序依赖部分：第一层和第二层的 LSTM 隐藏层单元数分别设置为 30 和 32，采用固定长度滑动窗口构造输入序列，并在 BiLSTM 层前引入失活概

率为 0.25 的 Dropout 机制以抑制过拟合。3) 在训练选项及超参数配置方面：采用 Adam 优化器进行网络参数的迭代更新，批处理样本量由遗传算法在预设范围内搜索确定，最大迭代次数限定为 1 000 次。为兼顾训练初期的收敛速度与后期的寻优精度，初始学习率设定为 0.10，并采用动态衰减策略，学习率下降周期设为 90 次迭代，下降因子设定为 0.06，同时设置 0.019 的梯度阈值以防止梯度爆炸。此外，模型输出端通过 Min-Max 反归一化处理，将网络的预测输出还原至真实的电池物理尺度。随后进行模型训练与参数寻优，训练迭代过程如图 5 所示。




图 5 所提模型训练迭代过程

Fig. 5 Training iteration process of the proposed model

图 5 全面展示了所提模型在 1 000 次迭代过程中的损失函数、RMSE 变化以及学习率调度策略。由图 5 可知，模型在初始较高学习率的驱动下迅速在特征空间寻优，使得损失与 RMSE 均大幅骤降，其中 RMSE 由初始的 1.2 迅速跌至 0.03 左右，模型快速完成初级收敛。为防止参数在全局最优解附近发生震荡，引入了阶梯式学习率调度机制。随迭代周期推进，学习率按分段阶梯有规律地衰减并最终趋近于 0。在该动态学习率策略的保障下，损失与 RMSE 曲线在第 150 次至 1 000 次的后续迭代中保持了高度的平稳与贴地，未出现任何发散或扰动迹象，确保了模型能够稳定收敛至全局最优并输出高精度的 SOH 预测值。

图 6 展示了所提模型在训练集上的预测效果。从图中可以看出，模型的预测值与真实值高度吻合，能够准确捕捉数据的局部波动与整体演变趋势。用测试集进行 SOH 预测，模型预测误差与测试回归拟合如图 7 所示。

由图 7 可得，模型的预测结果表现出极高的分布收敛性与线性拟合度。如图 7(a) 所示，在全生命周期的 33 个独立测试样本中，预测误差整体紧密围

绕零水平线振荡，绝大多数被高精度地包络在 $[-0.02, +0.02]$ 的窄区间内。图 7(b) 中，预测值紧密贴合对角线，回归拟合优度 R^2 高达 0.995 22，表明本文所提模型具备较高的预测精度和较强的泛化鲁棒性。这主要得益于其深度架构的协同赋能，凭借 Dropout 正则化与动态注意力权重的超强自适应抗扰能力，使其仅在一部之内便完成了自纠偏并收敛到常规微差区间，实现了算法精度与物理真实规律的统一。






图 6 训练集上电池 SOH 预测结果

Fig. 6 Prediction results of battery SOH on the training dataset



(a)测试集预测误差



(b)测试集回归图

图 7 测试集上电池 SOH 预测结果

Fig.7 Prediction results of battery SOH on the testing dataset

为验证所提方法的优越性,本文选取了 5 种具有代表性的方法进行量化对比,结果如表 3 所示。其中,CNN、LSTM 与 Transformer 作为典型的单一架构模型,分别侧重于局部特征提取、长周期时序记忆与全局关联建模,旨在揭示单一网络在应对复杂的非线性老化与局部突变干扰时的表征局限性。CNN-BiLSTM 融合了空间切片与双向循环追踪优势,反映了基础串联混合架构的预测性能,而 DAE-CNN-BiLSTM-Attention 则作为当前领域中的强对照基线,进一步挂载了去噪自编码器与注意力分配机制。

由表 3 可得,不同模型在 SOH 预测任务中的表现存在显著差异。由于缺乏长时关联捕捉与去噪能力,Transformer 在小样本非线性序列下的拟合效果最差,而本文方法则取得了综合评估最优的量化结果。依据计量学公认的定量模型外推评价准则,残差预测偏差 $E_{RPD} \geq 3$ 即代表该模型具备极其优异的高可靠定量预测能力,而本文方法的 E_{RPD} 高达 8.78,远超标准优秀阈值,在客观上证实了本文模型的估计精度。从架构演进的对比逻辑来看,

本文方法预测结果的 RMSE 相较于次优方法 DAE-CNN-BiLSTM-Attention 显著降低了约 27.7%,证明了 KPCA 解耦能够减少多维充放电特征中的极化高频扰动与交叉冗余,且 DA-SAM 机制较传统注意力方法增强了网络对间歇静置容量阶跃突变等关键退化信息特征的动态表征能力,从而为后续多状态闭环联合预测框架下 SOC 与 SOE 容量边界的实时动态更新提供了极高置信度的数据基准与理论物理支撑。

表 3 不同方法的 SOH 预测结果对比

Table 3 Comparison of SOH prediction results using different methods

方法	E_{RMSE}	E_{MAE}	R^2	E_{RPD}
LSTM	0.034 6	0.011 8	0.985 5	8.29
Transformer	0.098 0	0.069 0	0.345 2	1.24
CNN	0.030 2	0.013 9	0.937 8	4.01
CNN-BiLSTM	0.026 4	0.021 5	0.952 5	4.59
DAE-CNN-BiLSTM-Attention	0.019 1	0.015 4	0.975 1	6.34
本文方法	0.013 8	0.011 9	0.995 2	8.78

注:粗体表示每列最优值。

2.3 消融实验

为探究本文方法中各关键组件对模型整体预测性能的贡献程度,在 B0006 锂离子电池退化数据集上开展各模块的消融实验,分别对比了 CNN-BiLSTM、CNN-BiLSTM-SAM、CNN-BiLSTM-DA-SAM 及本文方法的电池 SOH 状态预测性能,实验结果如表 4 所示。

表 4 消融实验结果对比

Table 4 Comparison of ablation study results

模型	E_{RMSE}	E_{MAE}	R^2	E_{RPD}
CNN-BiLSTM	0.026 4	0.021 5	0.952 5	4.59
CNN-BiLSTM-SAM	0.019 8	0.016 2	0.973 3	6.12
CNN-BiLSTM-DA-SAM	0.014 5	0.012 7	0.985 7	8.35
本文方法	0.013 8	0.011 9	0.995 2	8.78


由表 4 可得,各模块间的协同作用共同解决了电池 SOH 长周期预测难的问题。具体而言,相比抗噪能力不足的基础模型 CNN-BiLSTM,引入 SAM 模块能够有效筛选关键退化特征并过滤掉冗

余噪声,使基础模型的 E_{RMSE} 显著降低了 25.0%;其次,引入的 DA-SAM 模块通过动态调整历史状态权重,有效攻克了长序列下电池退化特征的监测难题,使模型的 E_{RMSE} 进一步大幅下降约 26.8%,极大地增强了模型在电池老化后期的泛化稳定性;最后,结合 Weighted-MSE 加权损失函数构建本文方法,通过重点惩罚寿命末期的预测误差,消除了预测曲线的尾部发散现象。总体来看,本文方法相比基础模型的 E_{RMSE} 大幅降低 47.7%,且 E_{RPD} 提升了 91.3%,证明该模型不仅具备极高的预测精度与鲁棒性,同时还能提升电池极端退化状态下的安全预警能力,具有较高的工程应用与实际价值。


2.4 SOE 和 SOC 预测

在获取电池 SOH 高保真预测序列之后,进一步将解析输出的 SOH 作为动态边界反馈至积分模型中,最终联合输出电池 SOC 与 SOE 状态,完成全生命周期多状态协同估计,SOC 与 SOE 的估计结果如图 8 所示。


如图 8 (a) 和图 8 (b) 所示,SOC 与 SOE 的预测误差整体上均在零刻度线附近呈现平稳的随机波动,全测试周期内未出现明显的系统性误差累积或序列发散现象,证实了估算模型具备长时高精度的鲁棒性。同时,图 8 (c) 和图 8 (d) 直观阐明了 SOH 优化对模型精度的决定性提升。在未引入 SOH 优化前,受电池老化因素影响,SOC 和 SOE 预测均存在较严重的偏离;当引入 SOH 优化后,估算曲线(绿线)迅速收敛并与真实值(红线)高度吻合,显著抑制了系统性漂移。实验结果充分表明,所提算法能够有效克服参数时变特性,在时间序列上精准表征电池状态的动态演化趋势,实现高一致性的轨迹跟踪。为进一步论证所提方法在电池 SOC 与 SOE 在线评估中的可靠性与准确性,表 5 给出了各模型的 SOC 与 SOE 预测性能量化结果对比。




(a) 测试集 SOC 预测误差分布



(b) 测试集 SOE 预测误差分布



(c) 引入 SOH 优化前后的 SOC 预测结果对比



(d) 引入 SOH 优化前后的 SOE 预测结果对比

图 8 SOC 和 SOE 估计效果

Fig. 8 SOC and SOE calculation effect

由表 5 可得,随着模型的网络结构从单一特征提取向多模态协同优化演进,其预测精度呈现出明显的阶梯式跃升。首先,单一网络模型存在性能上限,传统的 CNN 与 LSTM 模型由于缺乏综合时空深度特征表达能力,其估算误差相对较大,即便是引入自注意力机制的 Transformer 模型,其 SOC 和 SOE 预测结果的 E_{RPD} 也仅为 44.42 和 18.43。CNN-BiLSTM 虽然在一定程度上弥补了单一结构的缺陷,但在非线性动态工况下的长时跟踪能力仍有不足。其次,相比于当前表现较优的 DAE-CNN-BiLSTM-Attention,本文方法取得了突破性的性能提升。在 SOC 预测任务中,本文方

法的拟合优度 R^2 达到 0.999 9,其 E_{RMSE} 和 E_{MAE} 较次优模型 DAE-CNN-BiLSTM-Attention 分别下降了 26.19%和 22.86%, E_{RPD} 跃升至 93.13。最后,在非线性耦合度更高、估计难度更大的 SOE 预测任务中,本文方法表现出极其优异的鲁棒性与非线性解耦能力。由于电池剩余能量同时受到实时电压下降与容量衰减的双重影响,传统模型在 SOE 任务上的精度均出现显著下滑,CNN 模型的 E_{RPD}

仅为 9.36,而本文方法在该任务中的 E_{RMSE} 与 E_{MAE} 分别为 0.003 1 与 0.002 0,相较于 DAE-CNN-BiLSTM-Attention 模型大幅降低了 39.22%和 53.49%, E_{RPD} 突破至 55.87。综上所述,本文所提出的多特征融合优化机制不仅能有效攻克高难度状态估算中的特征衰减难题,更能实现多维状态间的高精度联合监测,在全局精度与稳定性上优于现有基准方法。

表 5 不同模型的 SOC 与 SOE 预测性能对比
Table 5 Comparison of SOC and SOE predictive performance of different models

方法	预测物理量	E_{RMSE}	E_{MAE}	R^2	E_{RPD}
LSTM	SOC	0.012 5	0.010 5	0.998 1	23.10
	SOE	0.014 4	0.012 8	0.993 1	12.03
Transformer	SOC	0.006 5	0.005 2	0.999 5	44.42
	SOE	0.009 4	0.007 8	0.997 1	18.43
CNN	SOC	0.016 2	0.013 5	0.996 8	17.82
	SOE	0.018 5	0.015 4	0.988 6	9.36
CNN-BiLSTM	SOC	0.008 8	0.007 2	0.999 1	32.81
	SOE	0.010 5	0.008 9	0.996 3	16.50
DAE-CNN-BiLSTM-Attention	SOC	0.004 2	0.003 5	0.999 8	68.74
	SOE	0.005 1	0.004 3	0.999 1	33.96
本文方法	SOC	0.003 1	0.002 7	0.999 9	93.13
	SOE	0.003 1	0.002 0	0.999 1	55.87

3 结论

针对锂离子电池 SOH、SOC 和 SOE 协同预测困难的问题,提出了一种基于 CNN-BiLSTM 和 DA-SAM 的锂离子电池状态预测方法,并基于现有公开数据集进行了实验验证,得出如下结论。

1)通过提取充放电过程中的健康特征并结合 KPCA 非线性降维,构建了能够表征电池退化过程的低维特征表示,在保留主要退化信息的同时降低了输入冗余,为后续状态预测提供了较为紧凑且具有物理意义的数据基础。

2)构建的 CNN-BiLSTM-DA-SAM 模型能够综合实现局部特征提取、时序依赖建模与关键退化阶段特征增强,对电池 SOH 演化趋势具有较好的建模能力。引入加权损失后,模型对老化后期样本的关注程度得到提高,有助于增强对退化后期预测

的有效性。量化评估表明,该模型对 SOH 预测的 E_{RMSE} 达到 0.013 8, E_{MAE} 为 0.011 9, R^2 为 0.995 2, E_{RPD} 为 8.78。预测精度明显优于常规的 CNN-BiLSTM 及其他对比基准网络。

3)构建了以预测 SOH 为动态边界约束的多状态闭环联合估计框架。该策略彻底打破了固定边界参数所导致的误差累积瓶颈,实现了 SOC 与 SOE 估计过程的动态纠偏与协同优化。实验结果表明,联合估计下 SOC 与 SOE 预测的 E_{RMSE} 均达到 0.003 1,较传统算法有显著的误差改善,为电池管理系统中的多状态联合监测提供了高精准度与高可靠性的系统解决方案。

参考文献

[1] 田君,高洪波,张跃强,等.电动汽车动力锂离子电池寿命预测方法研究[J].电源技术,2020,44(5):767-770.
Tian Jun, Gao Hongbo, Zhang Yueqiang, et al. Re-

- search of life prediction methods for power Li-ion battery in electric vehicles[J]. Chinese Journal of Power Sources, 2020, 44(5): 767-770.
- [2] 王浩伟, 蔡幸福, 郭晓辉, 等. 基于蒙特卡罗方法的车事故碎片辐射场模拟计算[J]. 火箭军工程大学学报, 2024, 38(2): 32-38.
- Wang Haowei, Cai Xingfu, Guo Xiaohui, et al. Simulation calculation of radiation field of nuclear accident debris based on Monte Carlo method[J]. Journal of Rocket Force University of Engineering, 2024, 38(2): 32-38.
- [3] 任超, 司小胜, 张正新, 等. 退化模型动态校准的备件订购与替换联合决策[J]. 火箭军工程大学学报, 2025, 39(4): 22-31.
- Ren Chao, Si Xiaosheng, Zhang Zhengxin, et al. Joint decision-making for spare parts ordering and replacement based on dynamic calibration of degradation models[J]. Journal of Rocket Force University of Engineering, 2025, 39(4): 22-31.
- [4] 刘大同, 宋宇晨, 武巍, 等. 锂离子电池组健康状态估计综述[J]. 仪器仪表学报, 2020, 41(11): 1-18.
- Liu Datong, Song Yuchen, Wu Wei, et al. Review of state of health estimation for lithium-ion battery pack[J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 1-18.
- [5] 刘月峰, 张公, 张晨荣, 等. 锂离子电池 RUL 预测方法综述[J]. 计算机工程, 2020, 46(4): 11-18.
- Liu Yuefeng, Zhang Gong, Zhang Chenrong, et al. Review of RUL prediction method for lithium-ion batteries[J]. Computer Engineering, 2020, 46(4): 11-18.
- [6] Liu Kailong, Gao Yizhao, Zhu Chong, et al. Electrochemical modeling and parameterization towards control-oriented management of lithium-ion batteries[J]. Control Engineering Practice, 2022, 124: 105176.
- [7] 吴波, 谢锋, 卢佩航, 等. 基于 ESP 模型的锂电池参数辨识和 SOC 估计[J]. 电源技术, 2020, 44(6): 914-917.
- Wu Bo, Xie Feng, Lu Peihang, et al. Lithium battery parameter identification and SOC estimation based on ESP model[J]. Chinese Journal of Power Sources, 2020, 44(6): 914-917.
- [8] 夏雪磊, 杨博, 赵志刚, 等. 基于 MILS-MIUKF 算法的锂离子电池宽温度全寿命荷电状态估计[J]. 中国公路学报, 2024, 37(8): 289-301.
- Xia Xuelei, Yang Bo, Zhao Zhigang, et al. State of charge estimation of lithium-ion batteries under wide temperature and full life cycle based on MILS-MIUKF algorithm[J]. China Journal of Highway and Transport, 2024, 37(8): 289-301.
- [9] Zhang Feng, Zhi Hui, Zhou Puzhe, et al. State of charge estimation of Li-ion battery for underwater vehicles based on EKF-RELM under temperature-varying conditions [J]. Applied Ocean Research, 2021, 114: 102802.
- [10] 刘兴涛, 李坤, 武骥, 等. 基于 EKF-SVM 算法的动力电池 SOC 估计[J]. 汽车工程, 2020, 42(11): 1522-1528, 1544.
- Liu Xingtao, Li Kun, Wu Ji, et al. Estimation of power battery SOC based on EKF-SVM algorithm[J]. Automotive Engineering, 2020, 42(11): 1522-1528, 1544.
- [11] Wang Yangtao, Wang Shunli, Fan Yongcun, et al. A novel adaptive back propagation neural network-unscented Kalman filtering algorithm for accurate lithium-ion battery state of charge estimation[J]. Metals, 2022, 12(8): 1369.
- [12] Deng Zhongwei, Hu Xiaosong, Lin Xianke, et al. Data-driven state of charge estimation for lithium-ion battery packs based on Gaussian process regression[J]. Energy, 2020, 205: 118000.
- [13] Li Ran, Xu Shihui, Li Sibao, et al. State of charge prediction algorithm of lithium-ion battery based on PSO-SVR cross validation [J]. IEEE Access, 2020, 8: 10234-10242.
- [14] 孙丙香, 任鹏博, 陈育哲, 等. 锂离子电池在不同区间下的衰退影响因素分析及任意区间的老化趋势预测[J]. 电工技术学报, 2021, 36(3): 666-674.
- Sun Bingxiang, Ren Pengbo, Chen Yuzhe, et al. Analysis of influencing factors of degradation under different interval stress and prediction of aging trend in any interval for lithium-ion battery[J]. Transactions of China Electrotechnical Society, 2021, 36(3): 666-674.
- [15] 王长宏, 董汉成, 凌鸣祥, 等. 车用锂离子电池剩余使用寿命预测方法[J]. 汽车工程, 2015, 37(4): 384-388.
- Wang Changhong, Dong Hancheng, Ling Mingxiang, et al. Remaining useful life prediction of automotive lithium-ion battery[J]. Automotive Engineering, 2015, 37(4): 384-388.
- [16] 苏康泽, 邓飙, 孙晓艳, 等. 基于混合函数退化模型和数据平滑的锂电池剩余寿命预测[J]. 火箭军工程大学学报, 2023, 37(4): 65-71, 78.
- Su Kangze, Deng Biao, Sun Xiaoyan, et al. Remaining useful life prediction of lithium-ion batteries based on hybrid function degradation model and data smoothing [J]. Journal of Rocket Force University of Engineering, 2023, 37(4): 65-71, 78.
- [17] 张婷婷, 于明, 李宾, 等. 基于 Wavelet 降噪和支持向量机的锂离子电池容量预测研究[J]. 电工技术学报,

- 2020,35(14):3126-3136.
- Zhang Tingting, Yu Ming, Li Bin, et al. Capacity prediction of lithium-ion batteries based on Wavelet noise reduction and support vector machine[J]. Transactions of China Electrotechnical Society, 2020, 35(14): 3126-3136.
- [18] 卓越, 张建勋, 董青, 等. 综合预测性能的模型选择指标构建及其应用[J]. 火箭军工程大学学报, 2025, 39(3): 127-136.
- Zhuo Yue, Zhang Jianxun, Dong Qing, et al. Comprehensive prediction performance-based construction and application of model selection indicators[J]. Journal of Rocket Force University of Engineering, 2025, 39(3): 127-136.
- [19] 李嘉波, 王志璇, 田迪, 等. 变模态分解下 SSA-LSTM 组合的锂离子电池剩余使用寿命预测方法[J]. 储能科学与技术, 2025, 14(2): 1-10.
- Li Jiabo, Wang Zhixuan, Tian Di, et al. Prediction method for remaining service life of lithium batteries using SSA-LSTM combination under variable mode decomposition[J]. Energy Storage Science and Technology, 2025, 14(2): 1-10.
- [20] Chen Junxiong, Zhang Yu, Wu Ji, et al. SOC estimation for lithium-ion battery using the LSTM-RNN with extended input and constrained output[J]. Energy, 2023, 262: 125375.
- [21] Jiao Meng, Wang Dongqing, Qiu Jianlong. A GRU-RNN based momentum optimized algorithm for SOC estimation [J]. Journal of Power Sources, 2020, 459: 228051.
- [22] 李超然, 肖飞, 樊亚翔, 等. 基于卷积神经网络的锂离子电池 SOH 估算[J]. 电工技术学报, 2020, 35(19): 4106-4119.
- Li Chaoran, Xiao Fei, Fan Yaxiang, et al. An approach to lithium-ion battery SOH estimation based on convolutional neural network [J]. Transactions of China Electrotechnical Society, 2020, 35(19): 4106-4119.
- [23] 王英楷, 张红, 王星辉. 基于 1DCNN-LSTM 的锂离子电池 SOH 预测[J]. 储能科学与技术, 2022, 11(1): 294-301.
- Wang Yingkai, Zhang Hong, Wang Xinghui. Hybrid 1DCNN-LSTM model for predicting lithium ion battery state of health [J]. Energy Storage Science and Technology, 2022, 11(1): 294-301.
- [24] 李邦杰, 武健, 张大巧, 等. 基于卷积神经网络的景象匹配区适配性筛选方法[J]. 火箭军工程大学学报, 2024, 38(3): 45-50, 59.
- Li Bangjie, Wu Jian, Zhang Daqiao, et al. A CNN-based scene matching adaptability screening method [J]. Journal of Rocket Force University of Engineering, 2024, 38(3): 45-50, 59.
- [25] 赵晶钰, 李敏, 陈谢发, 等. 融合注意力机制与全局信息的 SAR 舰船目标检测算法[J]. 火箭军工程大学学报, 2024, 38(4): 40-46.
- Zhao Jingyu, Li Min, Chen Xiefa, et al. SAR ship target detection algorithm combining attention mechanism and global information [J]. Journal of Rocket Force University of Engineering, 2024, 38(4): 40-46.
- [26] 高德欣, 刘欣, 杨清. 基于卷积神经网络与双向长短时融合的锂离子电池剩余使用寿命预测[J]. 信息与控制, 2022, 51(3): 318-329, 360.
- Gao Dexin, Liu Xin, Yang Qing. Remaining useful life prediction of lithium-ion battery based on CNN and BiLSTM fusion [J]. Information and Control, 2022, 51(3): 318-329, 360.
- [27] 张浩男, 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): 594-602.
- Zhang Haonan, Hu Changhua, Du Dangbo, et al. Remaining useful life prediction method of lithium-ion battery based on Bi-LSTM network under multi-state influence [J]. Acta Electronica Sinica, 2022, 50(3): 594-602.
- [28] 李晓耕. 基于 IHHO-CNN-BiLSTM 的电池健康状态预测研究[D]. 哈尔滨: 哈尔滨工程大学, 2024: 1-42.
- Li Xiaogeng. Based on the IHHO-CNN-BiLSTM of the battery health state prediction research [D]. Harbin: Harbin Engineering University, 2024: 1-42.
- [29] 李潇鹏, 赵明航, 钟诗胜, 等. 基于全局自注意力机制和局部多尺度特征通道融合的锂电池健康状态预测[J]. 电气工程学报, 2025, 20(5): 1-12.
- Li Xiaopeng, Zhao Minghang, Zhong Shisheng, et al. State-of-health estimation for lithium-ion batteries based on global self-attention mechanism and local multi-scale feature channel fusion [J]. Journal of Electrical Engineering, 2025, 20(5): 1-12.
- [30] 赵宇波, 黄伟, 张剑飞. 基于混合尺度健康因子的 LSTM-Transformer 锂电池寿命预测[J]. 电子测量技术, 2024, 47(11): 1-8.
- Zhao Yubo, Huang Wei, Zhang Jianfei. Lithium-ion battery life prediction based on hybrid scale health factors with LSTM-Transformer model [J]. Electronic Measurement Technology, 2024, 47(11): 1-8.

Convolutional Neural Network-Bidirectional Long Short-Term Memory-Based Multi-State Joint Prediction Method for Lithium-Ion Batteries

LIU Hanru¹, ZHI Pengpeng^{1,2,*}, RONG Hao³, JIAO Sheng⁴, YANG Changlin⁵

(1. Yangtze Delta Region Institute (Huzhou),

University of Electronic Science and Technology of China, Huzhou 313000, China;

2. Institute of Electronic and Information Engineering in Guangdong,

University of Electronic Science and Technology of China, Dongguan 523808, China;

3. PLA Army Services University, Hefei 230031, China;

4. Hufan Automobile Electronic System Co. Ltd., Huzhou 313309, China;

5. Tianneng Battery Group (Huzhou) Co. Ltd., Huzhou 313099, China)

ABSTRACT: To address the challenge of joint prediction of lithium-ion battery state of health (SOH), state of charge (SOC), and state of energy (SOE), a joint prediction method based on convolutional neural network-bidirectional long short-term memory (CNN-BiLSTM) was proposed. First, to overcome the redundancy and strong correlation of multidimensional health features in charge/discharge operational data, multi-dimensional feature parameters reflecting battery states were analyzed, and kernel principal component analysis method was employed for nonlinear dimensionality reduction. Thus, a low-dimensional feature space was constructed to characterize battery-degradation properties. Consequently, a convolutional neural network was utilized to extract local temporal features of data, and a bidirectional long short-term memory network was incorporated to mine forward and backward correlation information during degradation. A degradation-aware self-attention mechanism and weighted mean squared error loss function were introduced to enhance the ability of the model to represent critical degradation features in the later stage of battery aging and increase sample attention. Finally, the predicted SOH was incorporated as a dynamic boundary constraint into the SOC and SOE estimation processes, establishing a closed-loop multi-state joint prediction framework. Experimental results on the NASA lithium-ion battery dataset demonstrate that the proposed method achieves a root mean square error of 0.013 8 for SOH prediction, which is a reduction of 27.7% compared to the suboptimal method DAE-CNN-BiLSTM-Attention. In the multi-state joint estimation, the prediction root mean squared error values for both the SOC and SOE reach 0.003 1, representing reductions of 26.19% and 39.22%, respectively, compared to the suboptimal method. The proposed method can effectively track the battery degradation trend while enabling accurate multi-state joint predictions.

KEYWORDS: lithium-ion battery; battery state of health; convolutional neural network; long short-term memory network; state prediction

(编辑:刘建民)