



基于多特征融合和CBLS模型的锂离子电池SOH估计方法

江善和¹, 荣浩威¹, 张朝龙²

(¹安庆师范大学 智能制造与机器人学院 安庆 246011; ²金陵科技学院 智能科学与控制工程学院 南京 211100)

摘要: 针对锂离子电池健康状态 (state of health, SOH) 估计中单一健康特征表征能力有限, 以及深度学习模型训练复杂、计算开销较大的问题, 提出一种基于多特征融合和一维卷积增强宽度学习系统 (convolutional broad learning system, CBLS) 的 SOH 估计方法。首先, 在电池恒流充电阶段提取循环次数、能量及温度统计特征, 采用 Pearson 相关性分析筛选与 SOH 具有较强线性关联的循环次数和能量均值, 并将表面温度均值作为互补健康特征, 构建循环次数、能量均值和温度均值融合的多特征输入。其次, 引入一维卷积增强节点改进传统宽度学习系统, 实现随机映射特征与卷积增强特征有机融合, 充分提取相邻循环局部退化信息, 再通过 Moore-Penrose 广义逆一次性求解输出权重, 从而在无须反向传播条件下实现 SOH 快速估计。力神 18650 锂离子电池数据集 A 和 B 的循环老化数据实验表明, 所提的 CBLS 模型的 RMSE 值较 CNN、BiLSTM 和 CNN-BiGRU 分别降低 92.52% 和 93.67%、83.35% 和 93.49%、92.93% 和 92.13%。不同特征组合下的消融实验结果表明, 三类特征融合的 CBLS 在两个数据集上均获得最低估计误差。XJTU 公开数据集中 23 个电池老化数据测试显示, CBLS 的平均 MAE 和 RMSE 分别为 0.178% 和 0.259%, 在不同循环倍率下仍能保持较低的估计误差。所提方法能够有效融合电池老化特征信息, 且 CBLS 模型具有较高的估计精度和泛化性能。

关键词: 锂离子电池; 健康状态估计; 多特征融合; 一维卷积; 宽度学习系统

doi: 10.19799/j.cnki.2095-4239.2026.0639

中图分类号: TM 614

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-18

Lithium-Ion Battery State-of-Health Estimation Method Based on Multi-Feature Fusion and Convolutional Broad Learning System

JIANG Shanhe¹, RONG Haowei¹, ZHANG Chaolong²

(¹School of Intelligent Manufacturing and Robotics, Anqing Normal University, Anqing 246011; ²School of Intelligent Science and Control Engineering, Jinling Institute of Technology, Nanjing 211100)

Abstract: To address the limited representation capability of individual health features and the high training complexity and computational cost of deep learning models for lithium-ion battery state-of-health (SOH) estimation, this study proposes an SOH estimation method based on multi-feature fusion and a one-dimensional convolution-enhanced broad learning system (CBLS). Firstly, cycle number and statistical features of charging energy and temperature are extracted from the constant-current charging stage. Pearson correlation

收稿日期: 2026-07-21; 修改稿日期: 2026-08-25。

基金项目: 国家自然科学基金项目 (51607004), 安徽省自然科学基金项目 (2008085MF197)。

第一作者: 江善和 (1975—), 男, 博士, 教授, 基于数据驱动的锂离子电池状态监测, E-mail: jshxlxlw@163.com。通信作者: 张朝龙 (1982—), 男, 博士, 教授, 储能系统运行控制, E-mail: zhangchaolong@126.com。

引用本文: 江善和, 荣浩威, 张朝龙. 基于多特征融合和CBLS模型的锂离子电池SOH估计方法[J]. 储能科学与技术, XXXX, XX(XX): 1-18.

Citation: JIANG Shanhe, RONG Haowei, ZHANG Chaolong. Lithium-Ion Battery State-of-Health Estimation Method Based on Multi-Feature Fusion and Convolutional Broad Learning System[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-18.

analysis is employed to select cycle number and mean charging energy, both of which exhibit strong linear correlations with SOH, while mean surface temperature is introduced as a complementary health feature. Accordingly, a multi-feature input integrating cycle number, mean charging energy, and mean surface temperature is constructed. Secondly, one-dimensional convolutional enhancement nodes are incorporated into the conventional broad learning system to integrate random mapping features with convolutional enhancement features and extract local degradation information across adjacent cycles. The output weights are then analytically determined in a single step using the Moore-Penrose pseudoinverse, enabling rapid SOH estimation without backpropagation. Compared with CNN, BiLSTM, and CNN-BiGRU methods, experiments on cycling-aging Datasets A and B collected from Lishen 18650 lithium-ion batteries show the root mean square error (RMSE) of the proposed CBLS was significantly reduced by 92.52% and 93.67%, 83.35% and 93.49%, 92.93% and 92.13%, respectively. The ablation experimental results under different feature combinations demonstrate that the proposed CBLS with three types of feature fusion achieves the lowest estimation error on both datasets. Tests on 23 batteries aging data samples from the publicly available XJTU datasets demonstrate that an average mean absolute error (MAE) of the CBLS method are 0.178% and 0.259%, respectively. Also, the CBLS still achieved low estimation errors under different cycling rates. The proposed CBLS method effectively integrates complementary battery degradation information and achieves high SOH estimation accuracy with favorable generalization capability across the evaluated batteries and operating conditions.

Keywords: lithium-ion battery; state-of-health estimation; multi-feature fusion; one-dimensional convolution; broad learning system

0 引言

锂离子电池因其高能量密度、长循环寿命等优势,已成为电动汽车、储能系统及便携式电子设备的核心能源载体^[1]。然而,电池在长期使用过程中不可避免地发生老化和性能退化,其健康状态(state of health, SOH)直接影响电池的可用容量、安全性及经济性。SOH作为衡量电池当前性能与新电池性能差异的关键指标,其准确估计对电池管理系统优化运行、寿命预测及退役决策具有重要意义^[2]。

锂离子电池 SOH 估计方法大致可以分为直接测量法^[3]、模型法及数据驱动法^[4]。直接测量法通过测量电池容量、内阻等关键参数获得电池健康状态,主要包括内阻测试法^[5]和电化学阻抗谱测试法^[6-7],但该方法依赖专业测试设备和严格实验条件,实际应用场景受限。模型法通过参数辨识、状态估计等方法,将电池复杂的电化学行为和老化过

程转化为可计算模型,实现 SOH 间接估计,主要包括等效电路模型^[8]、电化学模型^[9]和数学模型^[10],但其估计精度往往受模型结构、参数辨识精度和工况适应性的影响。相比之下,数据驱动法无须建立精确的电池机理模型,而是利用历史运行数据自动学习电池特征与健康状态之间的非线性映射关系,因此在锂离子电池 SOH 估计中得到了广泛应用。

近年来,数据驱动方法在锂离子电池 SOH 估计中取得了较好的研究进展。该类方法的估计性能主要取决于两个方面:一是能否从电池运行数据中提取有效的健康特征,二是能否构建适合特征映射关系的数据驱动模型。在健康特征提取方面,除直接采用电压、电流、温度等原始数据作为输入特征外^[11-13],已有研究还从等压充电曲线^[14-17]、容量增量曲线^[18-20]和弛豫过程^[21-22]等响应过程中提取退化特征,以表征电池容量衰减规律。然而,电池表面温度作为运行过程中可直接采集的热响应信息,能够在一定程度上反映电池充放电过程中的热积累、内

阻变化和老化状态变化。随着循环次数增加, 电池容量逐渐衰减, 其表面温度响应也可能发生相应变化。因此, 分析电池表面温度变化与容量衰减之间的关联性, 有助于进一步挖掘温度特征中蕴含的SOH退化信息。现有研究对电池表面温度特征与容量衰减关系的利用仍不充分, 限制了健康特征对电池退化状态的表征能力。

在数据驱动模型选择方面, 卷积神经网络(convolutional neural network, CNN)^[23]、长短期记忆神经网络(long short-term memory, LSTM)^[24]和门控循环单元(gated recurrent unit, GRU)^[25]等深度学习模型被广泛用于锂离子电池SOH估计。其中, LSTM和GRU依靠门控机制能够缓解传统循环神经网络中的梯度消失和梯度爆炸问题, CNN则具有较强的局部空间特征提取能力。文献[26]提出了一种基于CNN-Transformer的迁移学习模型, 并在多个数据集上验证了其对电池时间特征的提取能力, 能够较好地处理SOH预测任务。文献[27]构建了结合CNN和LSTM的混合架构CNN-LSTM模型, 用于估计SOH和电荷转移电阻, NASA数据集测试结果表明该模型具有较好的预测性能。文献[28]提出ALA-CNN-GRU方法用于锂离子电池SOH预测, 有效缓解了模型参数调优困难的问题。上述组合深度学习模型在一定程度上提高了SOH估计精度和噪声鲁棒性, 但仍存在网络结构较深、权重参数较多、训练时间较长等问题, 限制了其在快速建模和小样本场景中的应用。

针对现有锂离子电池SOH估计方法存在多源退化信息利用不足, 深度学习模型训练过程复杂、计算开销较大的问题, 提出了一种基于多特征融合和一维卷积增强宽度学习系统的SOH估计方法。主要研究内容包括:

(1) 构建了融合老化进程、能量变化和热响应信息的多特征输入。采用Pearson相关性分析筛选出循环次数和能量均值作为基础健康特征, 进一步考虑电池的温度变化趋势, 将其表面温度均值作为互补健康特征, 从而得到体现老化进程、能量存储能力和表面热响应等多个维度表征电池健康状态。

(2) 提出了一种面向电池局部退化信息提取的一维卷积增强宽度学习系统。采用一维卷积重构传统BLS增强节点, 以提取相邻循环的局部退化信息, 并融合随机映射特征与卷积增强特征, 再通过

Moore-Penrose广义逆一次性求解输出权重, 在保留BLS快速解析求解能力的同时增强模型对电池局部退化信息的表征能力。

(3) 多种测试方案结果验证了所提方法的有效性。针对两组力神18650锂离子电池循环老化数据, 分别开展了CBLS与BLS、CNN、BiLSTM和CNN-BiGRU模型的对比实验, 验证了所提模型的改进效果和优越性能; 不同输入特征组合的消融实验进一步验证了三个有效关键特征的互补作用。在此基础上, 选择XJTU公开数据集上的23个电池老化数据开展跨倍率测试, 以此验证所提方法在不同电池个体和循环倍率下的估计泛化性能。

1 特征提取方法

1.1 SOH定义

电池SOH是衡量电池健康状态的重要指标, 表示电池在反复充放电过程中, 电池的电能存储能力。SOH通常由电池容量和电池电阻定义, 由电池容量定义的SOH的含义为实际电池当前最大可用容量与其初始额定容量的百分比, 如公式(1)所示。由电池电阻定义的SOH的含义为电池寿命结束时的内阻与电池当前状态下的内阻之差和电池寿命结束时的内阻与电池初始状态下的初始内阻之差的百分比^[29], 如公式(2)所示。虽然采用电阻定义的健康状态较为直观, 但电池寿命结束时的电阻难以获取, 故该定义难以有效利用。因此, 本文选择电池容量定义方式估计电池健康状态。

$$\text{SOH}_C = \frac{C_{\text{now}}}{C_{\text{initial}}} \times 100\% \quad (1)$$

$$\text{SOH}_R = \frac{R_{\text{end}} - R_{\text{now}}}{R_{\text{end}} - R_{\text{initial}}} \times 100\% \quad (2)$$

其中, C_{now} 表示电池当前的最大可用容量; C_{initial} 表示电池的初始额定容量。 R_{end} 为电池使用寿命结束时的内阻; R_{initial} 是电池初始状态时的内阻; R_{now} 为当前状态下的电池内阻。

1.2 特征提取方法

电池充放电循环过程本质上伴随着电能与化学能之间的转换。随着循环次数增加, 电池可用容量逐渐衰减, 在相同充电条件下所能接受和存储的能量也会发生变化。同时, 电池老化通常伴随内阻增大和极化增强, 部分输入能量以热的形式耗散, 使电池表面温度响应随退化程度发生变化。因此, 能量类特征能够反映电池能量输入和存储能力的变

化, 表面温度类特征能够从热响应角度补充描述电池退化状态。由于恒流充电阶段具有电流恒定、工况相对稳定、不同循环之间可比性较强等特点, 本文统计恒流充电阶段内的能量参数和电池表面温度参数, 用于捕捉能量变化和温度响应随循环老化过程产生的长期趋势, 从而反映电池容量衰减规律。

为讨论方便, 记 E_k 记录当前循环充入的能量, E_{μ_k} 表征电池在恒流充电状态下的平均能量状态, E_{σ_k} 反映能量波动的稳定性, $E_{\sigma_k^2}$ 衡量电池能量数据的离散程度; T_{μ_k} 表征电池工作时的平均热状态, T_{σ_k} 反映温度波动的稳定性, $T_{\sigma_k^2}$ 衡量电池温度数据的离散程度, 其计算公式如 (3) - (9) 所示。

$$E_k = E_{k_{t_1}} - E_{k_{t_0}} \quad (3)$$

其中, E_k 表示第 k 次恒流充电阶段充入的能量, $E_{k_{t_1}}$ 表示第 k 次恒流充电结束时 t_1 记录的能量值, $E_{k_{t_0}}$ 表示第 k 次恒流充电开始时 t_0 记录的能量值。

$$E_{\mu_k} = \frac{1}{n_k} \sum_{i=1}^{n_k} E_{k_i} \quad (4)$$

其中, E_{μ_k} 表示第 k 次恒流充电阶段的能量均值, n_k 表示第 k 次循环中的数据样本个数, E_{k_i} 表示第 k 次循环中第 i 个记录的充电能量。

$$E_{\sigma_k^2} = \frac{1}{n_k} \sum_{i=1}^{n_k} (E_{k_i} - E_{\mu_k})^2 \quad (5)$$

其中, $E_{\sigma_k^2}$ 表示第 k 次恒流充电阶段的能量总体方差。

$$E_{\sigma_k} = \sqrt{\frac{1}{n_k} \sum_{i=1}^{n_k} (E_{k_i} - E_{\mu_k})^2} \quad (6)$$

其中, E_{σ_k} 表示第 k 次恒流充电阶段的能量总体标准差。

$$T_{\mu_k} = \frac{1}{n_k} \sum_{i=1}^{n_k} T_{k_i} \quad (7)$$

其中, T_{μ_k} 表示第 k 次恒流充电阶段的温度均值, n_k 表示第 k 次循环中的数据样本个数, T_{k_i} 表示第 k 次循环中第 i 时刻的温度。

$$T_{\sigma_k^2} = \frac{1}{n_k} \sum_{i=1}^{n_k} (T_{k_i} - T_{\mu_k})^2 \quad (8)$$

其中, $T_{\sigma_k^2}$ 表示第 k 次恒流充电阶段的温度总体方差。

$$T_{\sigma_k} = \sqrt{\frac{1}{n_k} \sum_{i=1}^{n_k} (T_{k_i} - T_{\mu_k})^2} \quad (9)$$

其中, T_{σ_k} 表示第 k 次恒流充电阶段的温度总体标准差。

为从以上特征中选择合适且可靠的健康特征, 本文选择 Pearson 相关系数进行筛选。Pearson 相关系数的本质是描述两个变量之间的线性相关性的强弱, 当 r 越接近 1, 说明特征与可用容量的正相关性越高, 当 r 越接近 -1, 说明特征与可用容量的负相关性越高, 当 r 越接近 0, 说明特征与可用容量之间的线性相关性越弱, 具体计算如式 (10) 所示。

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (10)$$

其中, X_i 和 Y_i 是变量 X 和变量 Y 的样本值, $\bar{X}$ 和 $\bar{Y}$ 是 X 和 Y 的样本均值, r 的取值范围是 $[-1, 1]$ 。

2 一维卷积增强宽度学习系统

2.1 宽度学习系统

宽度学习系统 (BLS) 是 CHEN^[30] 于 2017 年提出的一种基于随机向量函数连接网络设计的宽度网络结构, 与神经网络通过增加网络深度层数提高表达能力不同, BLS 通过增加网络宽度, 实现高效的特征学习和模型训练。此外 BLS 前向计算的特点能够避免深度学习网络梯度消失和梯度爆炸问题, 计算速度更快, 尤其适合小样本场景。

BLS 网络结构如图 1 所示, 其模型核心架构是基于随机映射的扁平化设计, 通过随机映射节点和随机增强节点的线性组合扩展特征空间, 本质上是面向特征向量的处理框架, 而非直接处理原始空间数据。BLS 通过随机映射节点矩阵 Z 和随机增强节点矩阵 H 提升维度, 将升维后的矩阵 Z 和 H 拼接形成矩阵 A , 由伪逆层求解出 A 与 Y 的权重, 其实现的工作过程如下:

$$Z = \xi(W_z X + b_z) \quad (11)$$

$$H = \xi(W_h Z + b_h) \quad (12)$$

$$A = [Z|H] \quad (13)$$

$$W_y = (\lambda I + A A^T)^{-1} A^T Y_{\text{train}} \quad (14)$$

$$Y_{\text{out}} = W_y A_{\text{test}} \quad (15)$$

其中, W_z 、 b_z 是随机映射节点的权重和偏置, W_h 、 b_h 是随机增强节点的权重和偏置, $\xi()$ 为 $\tanh$ 激活函数, W_y 是在训练集下由伪逆运算计算出的输出权重, λ 是对 W_y 的进一步约束, 若 $\lambda=0$, 则导致解为原始伪逆, 若 $\lambda \rightarrow \infty$, 解受到严重约束并趋




图1 BLS网络结构图

Figure 1 Network structure diagram of BLS

于 $0^{[30]}$ 。 Y_{train} 是训练集的SOH训练标签。 A_{test} 是测试集输入特征通过(11) - (13)计算得来的。 Y_{out} 是测试集的SOH估计结果。

2.2 一维卷积增强宽度学习系统

BLS扁平化结构设计使其缺乏对局部空间结构的自主建模能力，在空间特征捕捉方面存在显著局限性。为解决BLS模型在局部特征空间捕捉上的不足，引入了卷积神经网络中的一维卷积层替换BLS模型中的随机增强节点的计算方式，从而构建改进的一维卷积增强宽度学习系统CBLS模型。该模型首先利用BLS模型的随机映射层将输入数据提升维度，然后通过卷积计算的方式捕捉升维后的数据之间的局部空间特征，从而获得更为丰富的电池数据特征之间的信息。然后，将升维后的电池数据特征和局部空间特征进行拼接，在共同输入伪逆层中建立起与SOH之间的映射关系，同时模型还可以通过调整映射节点数量和卷积核数量扩展特征表达能力，输出层权重则由伪逆运算一次性求解得到。这种方法既能充分利用电池数据特征之间的信息，又避免了反向传播的大量复杂计算导致的时间过长问题。

改进的一维卷积增强宽度学习系统CBLS模型网络结构如图2所示。由图2可知，改进的CBLS模型仍采用宽度学习系统的网络结构，通过将随机增强节点的计算方式改用卷积计算使该结构获得能捕捉特征空间的能力。工作原理可以表述为，输入序列 X ，经随机映射得到映射节点 z ，组成映射节点矩阵 Z ，再经过卷积增强映射得到空间增强节点矩阵 H_c ，将矩阵 Z 和矩阵 H_c 拼接后得到特征矩阵

A_c ，最后通过伪逆计算输出层的权重 W_{yc} ，从而建立输入与输出的非线性映射关系，其计算过程如(16) - (20)所示。




图2 CBLS网络结构图

Figure 2 Network structure diagram of CBLS

$$Z = \xi(W_z X + b_z) \quad (16)$$

$$H_c = \xi(F_c(Z)) = \xi([H'_{c1}, H'_{c2}, \dots, H'_{cj}]) \quad (17)$$

$$A_c = [Z | H_c] \quad (18)$$

$$W_{yc} = (\lambda I + A_c A_c^T)^{-1} A_c^T Y_{train} \quad (19)$$

$$Y_{out} = W_{yc} A_{test} \quad (20)$$

其中， $F_c(\cdot)$ 表示由 j 个一维卷积核构成的卷积线性映射， H'_{ci} 表示第 i 个卷积核作用于随机映射节点矩阵 Z 后得到的激活前卷积特征序列， H_c 表示经过 $\tanh$ 激活函数 $\xi(\cdot)$ 后得到的空间增强节点矩阵。 A_c 是由随机映射节点矩阵 Z 和空间增强节点矩阵 H_c 拼接得到的特征矩阵， W_{yc} 是在训练集下由伪逆运算计算得到的输出权重， Y_{train} 为训练集SOH标签， Y_{out} 为测试集SOH估计结果。

CBLS模型中的空间增强节点矩阵 H_c 是由随机映射节点矩阵 Z 经过一维卷积映射和非线性激活后得到的，一维卷积层能够通过局部感受野捕捉数据中的局部空间关联信息，其工作原理如图3所示。长度为 k

的卷积核在映射节点序列 Z 上滑动，并在每一个局部窗口内与对应输入元素相乘后求和，得到该卷积核在

当前位置的激活前输出 h'_{ci} 。当第 i 个卷积核完成整个序列的滑动计算后，可得到一个激活前局部特征序列 H'_{ci} ；由 j 个卷积核得到的 $[H'_{c1}, H'_{c2}, \dots, H'_{cj}]$ 共同组成卷积映射结果 $F_c(\cdot)$ ，再经过 $\tanh$ 激活函

数 $\xi(\cdot)$ 后形成空间增强节点矩阵 H_C 。卷积运算的原理如式(21) - (22)所示。

$$h'_{Ci,t} = b_{Ci} + \sum_{q=0}^{k-1} w_{Ci,q} z_{t+q} \quad (21)$$

$$H'_{Ci} = [h'_{Ci,1}, h'_{Ci,2}, \dots, h'_{Ci,L-k+1}] \quad (22)$$

式中, $h'_{Ci,t}$ 表示第 i 个卷积核在第 t 个滑动窗口处的激活前输出, b_{Ci} 表示第 i 个卷积核的偏置, $w_{Ci,q}$ 表示第 i 个卷积核中第 q 个位置的卷积权重, z_{t+q} 表示随机映射节点矩阵 Z 中与当前卷积窗口对应的输入元素, k 表示卷积核长度, L 表示输入序列长度, $L-k+1$ 表示步长为1且无填充条件下得到的卷积输出长度。 H'_{Ci} 表示第 i 个卷积核滑动计算后得到的激活前局部特征序列。




图3 一维卷积工作原理图

Figure 3 Principle diagram of one-dimensional convolution

3 实验验证

3.1 实验方案

为验证提出的CBLS模型估计电池SOH的准确性和快速性,以及所筛选出的电池健康特征的有效性,选择两个不同充放电循环老化实验的电池进行验证,所采用的电池SOH估计实验方案框架如图4所示。具体实现步骤如下:

步骤1: 电池循环老化实验。在电池测试平台上对电池进行循环老化实验,获取恒流充电阶段电池数据和放电阶段容量数据。

步骤2: 特征提取及可靠性分析。在恒流充电电池数据中提取待筛选的特征,采用Pearson相关系数从中选出健康特征,对健康特征和SOH进行可视化分析验证其可靠性,并通过后续的特征消融实验进一步确定输入特征组合。

步骤3: 数据预处理及划分。按照充放电循环的先后顺序划分数据,不对样本进行随机打乱。对于每条电池老化轨迹,将数据划分为训练集和测试集,进一步将训练集划分为子训练集和验证集,子训练集用于模型拟合,验证集用于超参数选择,测试集仅用于最终性能评价。

步骤4: 训练模型及性能评估。验证集调整超参数,训练集训练CBLS模型,测试集评估其性能并与其他模型进行对比,同时在XJTU的两组锂电池公开数据集上进行实验,以验证本方法的准确性和优越性。




图4 锂离子电池SOH估计实验流程

Figure 4 Experimental procedure for lithium-ion battery SOH estimation

3.2 电池循环老化实验

3.2.1 老化实验环境

本研究使用的电池测试平台如图5所示,主要由数据记录服务器、电池测试设备(新威BTS-4000)和恒温箱组成。其中,电池测试设备用于对实验电池进行充放电循环测试,并采集测试过程中的电压、电流、容量和温度等运行数据;数据记录服务器用于记录电池测试设备采集的数据,并对电池充放电状态进行可视化监测;恒温箱用于放置实验电池并提供相对稳定的测试空间,以降低外部环境扰动对测试过程的影响。需要说明的是,本文未将环境温度控制作为主要研究变量,后续分析中使用的温度特征为测试过程中采集到的电池表面温度,而非环境温度或电池内部温度。




图5 电池测试平台
Figure 5 Battery testing platform

对力神 18650 锂离子电池进行充放电循环老化实验，其中电池的正极材料为 NCM，负极材料为石墨，电池额定容量为 2500mAh。首先，对单体锂离子电池 A 和电池 B 分别以 250mA 和 500mA 的恒流电流充电，直到电池电压达到上限截止电压 4.2V。然后，保持电压恒定进行恒压充电，直到电流减小到截止电流 48mA。恒压充电结束后静置 5min，以缓解充电过程产生的电压极化和浓差极化，使电池端电压在放电前趋于相对稳定。随后，在 1250mA 下进行恒流短时放电 6min，用于在固定负载条件下激发电池的瞬态响应，使不同老化阶段电池的电压变化、能量输出和表面温度响应差异能够被观测和提取。短时放电结束后静置 30min，以减弱短时放电引起的电压恢复、浓度梯度变化和表面温度波动等瞬态效应。之后，继续以 1250mA 恒流放电，直到电池电压降至 3V。放电结束后搁置 2min，使电池在进入下一循环前完成短时间状态恢复，从而降低上一循环末端状态对下一循环初始状态的影响。上述循环过程重复进行，测试流程如图 6 所示。

3.2.2 电池循环老化实验数据

在锂离子电池恒流恒压充放电循环实验中，电池 A 共循环 872 次，电池 B 共循环 1123 次，记录了充电时间、电池表面温度、充电能量和可用容量等运行数据，如图 7 所示。由图 7 (a) 可知，在长时间放电阶段，电池表面温度先快速上升；当电池进入充电阶段后，表面温度快速下降，并在一定范围内波动。图 7 (b) 进一步给出了不同循环次数下恒流充电阶段的表面温度变化曲线。可以看出，不同循环阶段的电池表面温度在恒流充电初期均呈下降趋势，随后进入相对稳定的波动状态。例如，第 1 次循环时，表面温度由 26.3℃ 下降，并在 25.2℃ 附近波动；第 300 次循环时，表面温度由 18.3℃ 下降，并在 17.5℃ 附近波动；第 800 次循环时，表面




图6 电池老化实验测试流程
Figure 6 Test process of battery aging

温度由 21.5℃ 下降，并在 18.8℃ 附近波动。上述现象表明，电池表面温度响应随循环次数增加呈现非线性变化，说明表面温度特征中包含与电池老化状态相关的信息。由图 7 (c) 可知，各循环下电压曲线整体呈现先快速上升、随后缓慢上升、后期再次加快上升的变化趋势。随着循环次数增加，电压曲线整体向左移动，高循环次数下电池更早达到 4.2V 充电截止电压，表明恒流充电阶段持续时间逐渐缩短。由图 7 (d) 可知，恒流充电阶段充入能量随循环次数增加整体呈下降趋势。其中，第 1 至 200 次循环期间充入能量累计下降 0.69Wh，第 200 至 700 次循环期间累计下降 0.58Wh，而第 700 至 800 次循环期间累计下降 0.55Wh。可以看出，充入能量在循环早期和循环后期下降较为明显，其变化趋势与电池可用容量衰减过程基本一致。图 7 (e) 显示，随着充放电循环次数增加，电池可用容量整体呈现非线性衰减趋势。同时，在第 242 至 265 次、第 316 至 331 次和第 343 至 386 次循环区内，可用容量出现短暂恢复现象。此类局部容量恢复是电池实际老化过程中可能出现的正常可逆波动，可能与极化状态缓解、活性物质阶段性恢复、界面状态调整及其他电化学反应有关。由于 SOH 估计的目标是准确表征真实电池状态，而非拟合理想化的单调衰减曲线，因此这些非单调点被视为真实退化轨迹的一部分，并完整用于模型训练和测试。由此，模型评价结果不仅反映其对整体容量衰减趋势的拟合能力，也反映其对局部容量波动的跟




图7 部分运行数据及恒流充电阶段表面温度、电压、能量变化与容量衰减曲线

Figure 7 Partial operating data and curves of surface temperature, voltage, energy variation, and capacity attenuation during the constant-current charging stage

踪能力。综上所述, 电池可用容量衰减、表面温度响应变化和恒流充电阶段充入能量减少均与循环次数密切相关, 且三者随循环老化呈现不同程度的非线性变化。因此, 可将循环次数、表面温度均值和充入能量等参数作为候选健康特征, 用于后续SOH估计模型的特征筛选与建模分析。

3.3 特征提取及可视化分析

为评价候选特征与电池可用容量之间的关联程

度, 通过Pearson相关系数进行分析。不同候选特征与可用容量之间的Pearson相关系数如表1所示。

由表1可知, 能量及其统计特征在电池A和电池B上的相关系数均大于0.99, 表明恒流充电阶段的能量特征与可用容量之间具有较强的正线性关联。循环次数与可用容量的相关系数分别为-0.9105和-0.9326, 表明随着循环次数增加, 电

池可用容量总体呈下降趋势。因此，循环次数和能量均值能够分别从老化进程和能量接受能力两个方面反映电池退化状态，本文将其作为基础健康特征。相比之下，温度均值、温度标准差和温度方差的相关系数整体较低，说明温度统计特征与可用容

量之间不存在稳定的全局线性关系。需要指出的是，本文并未依据 Pearson 相关系数将温度均值判定为强相关特征，而是将其作为后续消融验证中的互补候选特征。

表 1 电池特征与可用容量的皮尔逊相关系数

Table 1 Pearson correlation coefficients between each feature and available capacity

组别	循环次数	能量	能量均值	能量标准差	能量方差	温度均值	温度标准差	温度方差
电池 A	-0.9105	0.9983	0.9984	0.9983	0.9974	0.2266	0.1111	0.1212
电池 B	-0.9326	0.9998	0.9998	0.9997	0.9944	-0.0539	-0.2317	-0.0680

为进一步分析候选特征的变化规律及 Pearson 相关分析结果的合理性，本文对各特征与可用容量之间的关系进行可视化，如图 8 所示。图 8 (a) - (d) 显示，能量及其统计特征与可用容量之间的散点分布整体接近线性关系，与表 1 中较高的 Pearson 相关系数一致。图 8 (f) 和图 8 (g) 表明，温度标准差和温度方差在不同容量状态下变化不明显，难以有效反映电池退化过程，因此不将其作为主要输入特征。

图 8 (e) 显示，温度均值与可用容量之间虽然未呈现明显的全局线性关系，但其变化过程具有一定的阶段性，并且不同循环阶段的温度响应存在差异。该现象可能与电池老化过程中内阻增长、极化变化、产热特性改变以及容量恢复等因素有关。由于温度响应还可能受到充电初始状态和局部运行条件的影响，其与可用容量之间的关系不一定表现为稳定的单调线性关系。因此，较低的 Pearson 相关系数不能直接说明温度均值不包含退化信息，而是表明其难以通过单一线性相关指标充分刻画 SOH 变化。

基于上述分析，本文采用相关性初筛和消融实验验证相结合的特征选择策略。循环次数和能量均值根据较强的线性相关性确定为基础健康特征；温度均值则根据其潜在的热响应意义和阶段性变化特征作为互补候选特征，并通过特征消融实验评价其在多特征融合模型中的实际贡献。消融实验结果表明，与仅使用循环次数和能量均值相比，加入温度均值后，数据集 A 的 RMSE 由 0.9614% 降至 0.2562%，数据集 B 的 RMSE 由 1.5958% 降至 0.2851%，说明温度均值虽然单独用于 SOH 估计时的表征能力有限，但能够提供能量和循环次数未充分包含的补充信息。最终，选取循环次数、能量

均值和温度均值共同构成 SOH 估计的多特征输入。

3.4 基于多特征融合和 CBLS 模型的锂电池 SOH 估计

3.4.1 数据集划分、实验条件和评价指标

本文将前 50% 的循环样本划分为训练集，后 50% 的连续循环样本作为独立测试集，以评价模型利用前期老化信息估计后续退化状态的能力。在训练集内部，进一步将前 80% 作为子训练集、后 20% 作为验证集，即子训练集、验证集和测试集分别约占完整轨迹的 40%、10% 和 50%，如表 2 所示。

本实验在相同软硬件环境下完成，具体配置如下：CPU 为 Intel Core i5-13600KF，GPU 为 NVIDIA GeForce RTX 4060 Ti，显存容量为 8GB。软件环境采用 Python 3.12，深度学习框架为 PyTorch 2.5.1，并使用 NumPy 1.26.4 和 Pandas 2.2.3 完成数据处理、模型训练与实验结果分析。

为量化评估模型的性能，选择平均绝对误差 (MAE)、均方误差 (MSE)、均方根误差 (RMSE) 和运行时间 t_{run} 作为性能评价指标，各指标计算公式如 (23) ~ (26) 所示。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (23)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (24)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (25)$$

$$t_{run} = t_{end} - t_{start} \quad (26)$$

MAE 表示模型的估计结果与真实结果的吻合程度，误差小于给定的容忍度，即认为该估计是准确的；MSE 表示平均估计误差的大小，衡量了估计值与真实值之间的差异，量化结果越小，说明估




图8 电池特征与可用容量散点图

Figure 8 Scatter plot of battery feature and available capacity estimation method

表2 两组电池老化数据集的循环样本数量及时间序贯划分

Table 2 Numbers of cycle samples and chronological data partitioning for the two battery aging datasets

数据集	循环次数	训练集		测试集
		子训练集	验证集	
A	872	349	87	436
B	1123	449	112	562

计的效果越好；RMSE可作为模型估计值与数据真实值相似程度的参考项，数值越小，表示模型估计误差的波动性越小，收敛性能更佳； t_{run} 是模型在测试集上运行的时间，用来衡量模型的推理速度，反映估计方法运行时的快慢。本文采用百分数形式表示电池SOH，因此MAE和RMSE的单位为%，MSE的单位为%²。这里的%表示SOH估计值与真

实值在百分数尺度上的差值，不表示相对百分比误差。

3.4.2 CBLS模型参数选择

CBLS模型的估计性能主要受映射节点数 N_m 、增强节点数 N_e 、卷积核尺寸 k 、收缩系数 s 和伪逆截断阈值 r_{cond} 五个超参数影响，其中 N_m 决定随机映射层的特征维度，较大的映射节点数能够提高输入特征的表示能力，但也会增加模型复杂度及矩阵病态化风险； N_e 对应一维卷积层的输出通道数，用于控制模型可提取的时序增强特征数量； k 决定卷积操作覆盖的相邻循环范围，从而调节模型对局部退化趋势的感知野； s 用于缩放卷积增强特征后再输入双曲正切激活函数，其取值会影响增强节点的非线性程度，过大的 s 可能导致激活函数饱和，而过小的 s 则可能削弱增强特征的区分能力； r_{cond} 是求解输出权重时广义逆计算的奇异值截断阈值，用于抑制近奇异分量并改善数值稳定性。

为合理确定CBLS模型参数的设定值，文中按照电池循环顺序将全部样本以1:1的比例划分为训练集和测试集，并进一步将训练集后20%的样本作为验证集，其余80%用于模型拟合。参数范围设置为 $N_m \in \{5, 10, 20, 40\}$ 、 $N_e \in \{3, 5, 10, 20\}$ 、 $K \in \{5, 9, 17, 25\}$ 、 $s \in \{0.1, 0.3, 0.5, 0.8, 1.0\}$ 和 $r_{\text{cond}} \in \{10^{-6}, 10^{-5}, 10^{-4}, 10^{-3}\}$ ，共形成 $4 \times 4 \times 4 \times 5 \times 4 = 1280$ 种参数组合。为降低随机映射权重和随机卷积权重对评价结果的影响，每种组合分别采用5个固定随机种子独立运行，并在原始量纲下计算平均绝对误差（MAE）。参数选择以5次运行的MAE最小为首要准则，并以MAE的样本标准差作为稳定性指标，在平均性能相同时优先选择标准差较小的组合，搜索结果如图9所示。从图9可以看出，CBLS模型参数的最优组合为 $N_m = 40$ 、 $N_e = 20$ 、 $K = 5$ 、 $s = 0.1$ 和 $r_{\text{cond}} = 10^{-5}$ ，此参数下的模型评估指标MAE为0.1132%，标准差为0.0486%。确定最优参数后，将训练子集与验证集重新合并用于最终模型拟合，并在独立测试集上评价模型的泛化性能。为避免因调参程度不同造成比较偏差，其他模型均在相同训练集和验证集上进行参数选择，并采用相同的评价指标。深度学习模型使用MAE或MSE作为训练损失，以验证集MAE实施早停，并恢复验证集表现最优的模型权重。所有模型均在参数确定后使用完整训练区域重新训练，再在测试集

上统一评价。




图9 CBLS模型不同超参数组合的平均验证集MAE
Figure 9 Mean validation MAE of the CBLS model under different hyperparameter combinations

3.4.3 CBLS和BLS模型SOH估计

为了验证一维卷积Conv1d引入宽度学习系统后对SOH估计性能的提升作用，文中将CBLS模型与传统的BLS模型进行对比测试，结果如图10和表3所示。由图10可知，在训练集阶段，CBLS和BLS的估计结果均能较好地跟踪真实SOH变化趋势，说明两种模型均具有较强的训练集拟合能力。在测试集阶段，随着循环次数增加，BLS的估计曲线逐渐偏离真实SOH值，尤其在数据集A后期和数据集B测试阶段后半段偏差更为明显；相比之下，CBLS的估计结果与真实SOH曲线更为接近，能够更稳定地跟踪电池容量衰减趋势。局部放大图进一步表明，CBLS在SOH波动区间内的估计误差小于BLS，说明一维卷积增强策略能够有效提取输入特征中的局部空间信息，提高宽度学习系统在测试集上的估计精度和泛化能力。

表3给出了CBLS和BLS在两个电池数据集上的SOH估计性能指标。对于数据集A，CBLS的MAE、MSE和RMSE分别为0.1905%、0.0657%²和0.2562%，明显低于BLS的0.9619%、1.5994%²和1.2647%；对于数据集B，CBLS的MAE、MSE和RMSE分别为0.2148%、0.0813%²和0.2851%，同样低于BLS的1.5409%、3.9954%²和1.9988%。这表明CBLS在不同数据集上均具有更高的SOH估计精度。

从测试运行时间来看，BLS模型在数据集A和数据集B上的运行时间分别为0.0158s和0.0149s，CBLS模型分别为0.0234s和0.0241s。与BLS相比，CBLS在两个数据集上的测试耗时分别增加0.0076s和0.0092s。虽然引入一维卷积运算后模

表3 CBLS和BLS电池健康状态估计的性能指标
Table 3 Performance indicators of different estimation models for battery state of health

数据集	模型	MAE/%	MSE/% ²	RMSE/%	t_{run}/s
A	CBLS	0.1905	0.0657	0.2562	0.0234
	BLS	0.9619	1.5994	1.2647	0.0158
B	CBLS	0.2148	0.0813	0.2851	0.0241
	BLS	1.5409	3.9954	1.9988	0.0149

型运行时间略有增加，但增加幅度较小，且仍保持在毫秒级范围内。综合估计精度和运行耗时可以看出，CBLS以较小的计算代价显著提升了SOH估计精度，验证了一维卷积增强策略在宽度学习系统中的有效性。

3.4.4 与其他估计模型的对比实验

为了验证CBLS模型估计方法的优越性能，选择卷积神经网络CNN^[31]、双向长短时间序列网络BiLSTM^[32]和卷积双向门控循环单元CNN-BiGRU^[33]作为对比模型进行测试分析。CBLS模型及其对比模型的参数设置如表4所示。

不同模型的SOH估计结果如图11所示。由图11可知，在训练集阶段，各模型均能在一定程度上跟踪电池SOH的变化趋势，说明所选模型均具备对训练样本的拟合能力。在测试集阶段，不同模型


的估计性能差异逐渐显现。CNN在测试初期能够较好地跟踪真实SOH值，但随着循环次数增加，其估计结果逐渐偏离真实值，说明单一CNN模型对长周期退化序列中时序变化信息的捕捉能力有限。BiLSTM对部分测试区间具有较好的跟踪效果，但在循环后期仍出现明显偏差，表明当退化序列较长或后期退化模式发生变化时，BiLSTM对长期依赖关系和局部波动特征的学习仍存在不足。CNN-BiGRU结合了局部特征提取和双向时序建模能力，其整体估计效果优于单一CNN和BiLSTM，但在测试后期仍存在一定偏差。相比之下，CBLS模型在数据集A和数据集B的测试阶段均能更稳定地跟踪真实SOH变化趋势，估计曲线与真实值重合度更高，说明所提模型具有更好的估计精度和跨工况适应性。

表5给出了不同模型在两个数据集上的SOH估计性能指标。由表5可知，CBLS在数据集A上的MAE、MSE和RMSE分别为0.1905%、0.0657%²和0.2562%，在数据集B上分别为0.2148%、0.0813%²和0.2851%，均为各对比模型中的最优结果。相比之下，CNN在数据集A和B上的RMSE分别为3.4259%和4.5053%，误差较大，表明其单独用于SOH估计时泛化能力相对有


表4 对比估计模型的参数配置

Table 4 Parameter configuration of the comparative estimation model

模型	模块	参数设置
CBLS	输入层	特征维度：循环次数，恒流充电能量均值，恒流充电温度均值
	随机映射层	随机映射节点个数40
	卷积增强映射层	卷积核大小5，卷积核个数20，填充方式：镜像填充，两侧填充大小8，收缩系数0.1，激活函数tansig函数
	伪逆层	输入大小15，奇异值截断阈值10 ⁻⁵
	输出层	输出维度1
CNN	输入层	特征维度：循环次数，恒流充电能量均值，恒流充电温度均值
	一维卷积层1	卷积核大小3，卷积核个数16，滑动步长1，两侧零填充大小2
	一维卷积层2	卷积核大小3，卷积核个数32，滑动步长1，两侧零填充大小2
	激活函数	Relu激活函数
	平均池化层	池化窗口大小2，滑动步长2，两侧零填充大小1
BiLSTM	输出层	输出维度1
	输入层	特征维度：循环次数，恒流充电能量均值，恒流充电温度均值
	BiLSTM层1、2	前向隐藏神经元个数32，反向隐藏神经元个数32
CNN-BiGRU	输出层	输出维度1
	输入层	特征维度：循环次数，恒流充电能量均值，恒流充电温度均值
	一维卷积层1、2	卷积核大小8，卷积核个数128，滑动步长1，两侧零填充大小2
	双向门控循环单元1、2	前向单元数128，反向单元数128，dropout=0.5，L2=0.0001
	输出层	输出维度1



(a) 数据集A




(b) 数据集B


图10 CBLS模型和BLS模型估计电池健康状态对比图
Figure 10 Comparison of battery state of health estimation between CBLS Model and BLS model estimation method

限。BiLSTM在数据集A上的MAE为1.0824%，RMSE为1.5390%，但在数据集B上MAE和RMSE分别增至3.4681%和4.3785%，说明其估计性能对数据集特征具有一定敏感性。CNN-BiGRU在数据集A和B上的MAE分别为2.7391%和1.7782%，RMSE均为3.6247%，虽然在数据集B上较CNN和BiLSTM有一定改善，但整体误差仍明显高于CBLS。

从不同电流的稳定性来看，CBLS在两个数据集上的误差波动最小，其MAE仅由数据集A的0.1905%变化为数据集B的0.2148%，RMSE仅由0.2562%变化为0.2851%。相比之下，CNN、BiLSTM和CNN-BiGRU在不同电流上的误差变化更为明显，说明对比的深度学习模型的性能更容易受到数据集特征和退化模式差异的影响。CBLS通过宽度学习系统的快速非线性映射能力和一维卷积的局部特征提取能力，在两个不同电流下均保持了



(a) 数据集A



(b) 数据集B

图11 CBLS模型和对比模型的电池健康状态估计结果对比图
Figure 11 Comparison of battery state-of-health estimation results between the CBLS model and the baseline models

Figure 11 Comparison of battery state-of-health estimation results between the CBLS model and the baseline models

表5 电池健康状态估计不同模型的性能指标

Table 5 Performance indicators of different estimation models for battery state of health

数据集	模型	MAE/%	MSE/% ²	RMSE/%	t_{run}/s
A	CBLS	0.1905	0.0657	0.2562	0.0234
	CNN	2.8431	11.7366	3.4259	0.0160
	BiLSTM	1.0824	2.3684	1.5390	0.0259
	CNN-BiGRU	2.7391	13.1381	3.6247	0.1665
B	CBLS	0.2148	0.0813	0.2851	0.0241
	CNN	3.3991	20.2977	4.5053	0.0173
	BiLSTM	3.4681	19.1714	4.3785	0.0308
	CNN-BiGRU	1.7782	5.1001	3.6247	0.2135

较高的估计精度和较好的稳定性。

从测试运行时间来看，CNN在两个数据集上的运行时间分别为0.0160s和0.0173s，耗时最短；CBLS的运行时间分别为0.0234s和0.0241s，略

高于 CNN，但低于 BiLSTM 的 0.0259s 和 0.0308s，且远低于 CNN-BiGRU 的 0.1665s 和 0.2135s。虽然 CBLS 的测试耗时不是最低，但其运行时间仍保持在较低水平，同时估计误差显著小于其他模型。以 RMSE 为例，在数据集 A 上，CBLS 相比 CNN、BiLSTM 和 CNN-BiGRU 分别降低了 92.52%、83.35% 和 92.93%；在数据集 B 上，CBLS 相比 CNN、BiLSTM 和 CNN-BiGRU 分别降低了 93.67%、93.49% 和 92.13%。综合估计精度、运行时间和跨数据集稳定性可知，CBLS 在锂离子电池 SOH 估计任务中具有更优的综合性能。

3.4.5 多特征消融实验

为验证循环次数、能量均值和温度均值三类特征对 CBLS 模型 SOH 估计性能的影响，本文设计了特征消融实验。实验以 CBLS 作为测试模型，在保持模型结构和参数设置一致的条件下，分别采用单特征、两特征以及三特征融合输入进行 SOH 估计，并通过 MAE、MSE 和 RMSE 评价不同特征组合下的估计效果，结果如表 6 所示。

由表 6 可知，不同特征对 SOH 估计性能的贡献存在明显差异。在数据集 A 中，仅使用循环次数作为输入时，模型误差最大，MAE、MSE 和 RMSE 分别为 26.8099%、1151.9152%² 和 33.9399%，说明单独依赖循环次数难以准确表征电池容量衰减过程。仅使用能量均值时，模型误差明显降低 MAE 和 RMSE 分别为 0.4724% 和 0.7504%，表明能量均值与 SOH 之间具有较强关联性。仅使用温度均值时，模型误差仍较大，说明温度均值单独作为输入特征时，难以充分描述电池退化状态，其中可能包含与容量衰减相关的信息。

从两特征组合结果来看，数据集 A 中“能量均值+温度均值”组合取得了较好的估计效果，MAE、MSE 和 RMSE 分别为 0.2640%、0.1251%² 和 0.3537%，优于单独使用能量均值或温度均值的结果。这说明温度均值能够为能量特征提供补充信息，有助于提升模型估计精度。相比之下，“循环次数+温度均值”和“循环次数+能量均值”组合的误差均高于“能量均值+温度均值”组合，表明循环次数作为单独或部分组合特征时，对模型估计性能的提升有限，但仍可作为老化进程信息参与多特征融合。在数据集 B 中，仅使用循环次数、能量均值和温度均值时，MAE 分别为 3.0801%、

1.1874% 和 13.3689%，其中能量均值仍表现出相对较强的

表 6 不同特征组合下 CBLS 模型的 SOH 估计性能
Table 6 SOH estimation performance of the CBLS model under different feature combinations

数据集	特征组合			评价指标		
	循环次数	能量均值	温度均值	MAE/%	MSE/% ²	RMSE/%
A	√			26.8099	1151.9152	33.9399
		√		0.4724	0.5631	0.7504
			√	9.1328	93.2122	9.6546
	√	√		0.7345	0.9243	0.9614
	√		√	2.1053	7.4657	2.7323
		√	√	0.2640	0.1251	0.3537
	√	√	√	0.1905	0.0657	0.2562
	√			3.0801	13.6860	3.6995
B		√		1.1874	3.5929	1.8902
			√	13.3689	221.7458	14.8911
	√	√		1.4265	2.5467	1.5958
	√		√	2.1747	6.3066	2.5113
		√	√	1.5633	2.9603	1.7205
	√	√	√	0.2148	0.0813	0.2851

SOH 表征能力，而温度均值单独建模时误差最大。两特征组合中，“循环次数+能量均值”组合的 RMSE 为 1.5958%，优于单一循环次数和单一能量均值特征；“能量均值+温度均值”组合的 RMSE 为 1.7205%，也较单独温度均值显著降低。说明在数据集 B 中，能量均值仍是主要有效特征，而循环次数和温度均值能够在一定程度上提供补充信息。

综合两个数据集结果可以看出，三特征融合输入均取得了最优估计性能。在数据集 A 中，循环次数、能量均值和温度均值共同输入时，CBLS 的 MAE、MSE 和 RMSE 分别降低至 0.1905%、0.0657%² 和 0.2562%；在数据集 B 中，三特征融合输入下的 MAE、MSE 和 RMSE 分别为 0.2148%、0.0813%² 和 0.2851%，同样为所有特征组合中的最优结果。该结果表明，循环次数能够反映电池老化进程，能量均值能够直接表征电池可用容量变化，温度均值则提供了电池表面热响应相关信息。三类特征之间具有一定互补性，将其共同输入 CBLS 模型能够更充分地表征电池退化状态，从而提高 SOH 估计精度和模型稳定性。

3.4.6 模型泛化能力测试

为验证所提出模型在不同电池和倍率下的泛化能力,采用XJTU^[34]公开电池老化数据集的第一组和第二组电池开展对比实验,共包含23个电池样本,第一组电池数据中2C倍率电池8个,第二组电池数据中3C倍率电池15个。所有模型均按照电池编号分别进行测试,并采用MAE、MSE和RMSE以及运行时间评价模型性能。各模型在不同电池上的测试结果如图12(a)-(d)所示。

23个电池上的测试结果表明,CBLS模型的MAE、MSE和RMSE分别为0.178%、0.074%²和0.259%,均明显低于其他对比模型,其中CNN模型的上述三项指标分别为5.486%、49.848%²和6.996%,BiLSTM模型分别为4.938%、42.114%²和6.420%,CNN-BiGRU模型分别为4.126%、30.469%²和5.486%。在三种基准模型中,CNN-BiGRU取得了相对较好的预测精度;与该模型相比,CBLS的MAE、MSE和RMSE




图12 不同模型在XJTU公开电池数据集上的预测误差与测试效率对比

Figure 12 Comparison of prediction errors and testing efficiency of different models on the XJTU public battery datasets

分别降低了95.68%、99.76%和95.29%,表明卷积增强节点有效提取电池循环过程中的局部退化特征,同时宽度学习结构能够较好地建立退化特征与SOH之间的映射关系。从不同电池的误差变化趋势来看,CBLS在2C和3C倍率下均保持了较

低的预测误差,说明其对不同倍率及不同退化轨迹具有较好的适应能力。

在计算效率方面,CBLS、CNN、BiLSTM和CNN-BiGRU在23个电池上的累计测试时间分别为0.0030s、0.0050s、0.0102s和0.0431s,单个电

池的平均测试时间分别为 0.130ms、0.216ms、0.443ms 和 1.873ms。CBLS 的累计测试时间较 CNN 缩短约 39.54%，且明显低于 BiLSTM 和 CNN-BiGRU，其主要原因在于 CBLS 通过广义逆直接求解输出权重，测试阶段仅需进行随机特征映射、卷积增强和线性输出计算，无须执行循环神经网络中的逐时刻状态更新。显然，CBLS 在公开电池数据集上获得了更低的 SOH 估计误差和更短的测试时间，体现出其在电池健康状态快速评估任务中的应用潜力。

4 结束语

针对现有锂离子电池 SOH 估计方法中存在的电池表面温度特征信息利用不足及深度学习模型结构复杂、计算开销较大问题，提出了一种基于多特征融合与一维卷积增强宽度学习系统 (CBLS) 的锂离子电池 SOH 估计方法。该方法利用 Pearson 相关性分析结果对比筛选出老化电池的循环次数、能量均值和表面温度均值等健康特征作为估计模型输入，同时引入一维卷积增强节点改进传统的 BLS 模型，通过提取相邻循环的局部退化信息和 Moore-Penrose 广义逆快速求解输出权重等策略提高估计精度，保留快速求解优势。两组力神 18650 电池数据集的测试结果表明，CBLS 的 MAE 分别为 0.1905% 和 0.2148%，RMSE 分别为 0.2562% 和 0.2851%。与传统 BLS 相比，其 RMSE 分别降低 79.74% 和 85.74%；与 CNN、BiLSTM 和 CNN-BiGRU 相比，RMSE 降幅范围达 83.35%~93.67%，这说明所提方法具有较高的估计精度。同时，CBLS 的多特征消融测试结果显示，三特征融合在两个数据集上均取得最低估计误差；相较于循环次数+能量均值两特征的估计模型，其 RMSE 分别降低 73.35% 和 82.13%，进一步验证了表面温度均值作为健康特征的不可或缺互补作用。

XJTU 公开数据集中 23 个电池的泛化性能测试结果表明，CBLS 的 MAE 和 RMSE 值相较于误差最低的基准模型 CNN-BiGRU 分别降低了 95.68% 和 95.29%；累计测试时间为 0.0030 s，明显低于 CNN、BiLSTM 和 CNN-BiGRU。显然，文中提出的多特征融合 CBLS 方法能够在不同充电条件、循环倍率和电池个体上兼顾 SOH 估计精度与效率，具有良好的泛化性能。未来研究可以进一步验证该

方法在不同环境温度、动态工况和电池化学体系下的适用性。

参考文献

- [1] ELMAHALLAWY M, ELFOULY T, ALOUANI A, et al. A comprehensive review of lithium-ion batteries modeling, and state of health and remaining useful lifetime prediction [J]. IEEE Access, 2022, 10: 119040-119070.
- [2] 蒋帅, 陈钺, 段砚州, 等. 温度和老化影响下的锂离子电池荷电状态和健康状态联合估计方法研究[J]. 机械工程学报, 2024, 60(18): 266-275.
JIANG S, CHEN C, DUAN Y Z, et al. Joint estimation of state-of-charge and state-of-health for lithium-ion batteries under the influence of temperature and aging[J]. Journal of Mechanical Engineering, 2024, 60(18): 266-275.
- [3] 张朝龙, 刘梦玲, 张俊峰, 等. 基于 IEA-T 和 CNN-BiLSTM-SimAM 的锂离子电池健康状态估计[J]. 武汉大学学报(理学版), 2025, 71(3): 385-394.
ZHANG C L, LIU M L, ZHANG Y F, et al. Lithium-ion battery state of health estimation based on IEA-T and CNN-BiLSTM-SimAM [J]. Journal of Wuhan University (Natural Science Edition), 2025, 71(3): 385-394.
- [4] 张欣怡, 伍嘉浩, 张璐平, 等. 锂离子电池健康状态评估方法研究新进展[J]. 河南科学, 2024, 42(12): 1717-1740.
ZHANG X Y, WU J H, ZHANG L P, et al. New research progress of the state of health estimation methods for lithium-ion batteries [J]. Henan Science, 2024, 42(12): 1717-1740.
- [5] WANG Y P, KIM S, CHEN Y F, et al. An SMPS-based lithium-ion battery test system for internal resistance measurement[J]. IEEE Transactions on Transportation Electrification, 2023, 9(1): 934-944.
- [6] PARK J, SON H, GEUM S, et al. Effect of terminal resistance and SOH asymmetry on parallel cell interaction and battery system degradation[J]. Journal of Energy Storage, 2025, 137: 118536.
- [7] LI C F, YANG L, LI Q S, et al. SOH estimation method for lithium-ion batteries based on an improved equivalent circuit model via electrochemical impedance spectroscopy[J]. Journal of Energy Storage, 2024, 86: 111167.
- [8] 李清波, 张懋慧, 罗英, 等. 基于等效电路模型融合电化学原理的锂离子电池荷电状态估计[J]. 储能科学与技术, 2024, 13(9): 3072-3083.
LI Q B, ZHANG M H, LUO Y, et al. Lithium-ion battery state of charge estimation based on equivalent circuit model[J]. Energy Storage Science and Technology, 2024, 13(9): 3072-3083.
- [9] GAO Y Z, LIU K, ZHU C, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model[J]. IEEE Transactions on Industrial Electronics, 2022, 69(3): 2684 - 2696.
- [10] BAGHDADI I, BRIAT O, DELETAGE J, et al. Lithium battery aging model based on Dakin's degradation approach[J]. Journal of Power Sources, 2016, 325: 273-285.

- [11] 巫春玲,王立顶,卢勇,等. 基于白鹭群优化高斯过程回归的锂电池SOH估计方法[J]. 储能科学与技术, 2025, 14(6): 2498-2511.
WU C L, WANG L D, LU Y, et al. Lithium-ion batteries SOH estimation based on gaussian processed regression optimized by egret swarm optimization[J]. Energy Storage Science and Technology, 2025, 14(6): 2498-2511.
- [12] 毛百海,覃昊,肖显斌,等. 基于LSTM&GRU-Attention多联合模型的锂离子电池SOH估计[J]. 储能科学与技术, 2023, 12(11): 3519-3527.
MAO B H, QIN W, XIAO X B, et al. SOH estimation of lithium-ion batteries based on LSTM&GRU-Attention multijoint model[J]. Energy Storage Science and Technology, 2023, 12(11): 3519-3527.
- [13] 张宣梁,何霆,朱文龙,等. 基于多循环特征的储能电池SOH估计模型[J]. 储能科学与技术, 2023, 12(11): 3488-3498.
ZHANG X L, HE T, ZHU W L, et al. A SOH estimation model for energy storage batteries based on multiple cycle features[J]. Energy Storage Science and Technology, 2023, 12(11): 3488-3498.
- [14] XIONG W, MO Y M, YAN C. Online state-of-health estimation for second-use lithium-ion batteries based on weighted least squares support vector machine[J]. IEEE Access, 2021, 9: 1870-1881.
- [15] 车云弘,邓忠伟,李佳承,等. 基于数据驱动的电池系统泛化SOH估计方法[J]. 机械工程学报, 2022, 58(24): 253-263.
CHE Y H, DENG Z W, LI J C, et al. Generalized data-driven SOH estimation method for battery systems[J]. Journal of Mechanical Engineering, 2022, 58(24): 253-263.
- [16] 郭鹏旭,赵理,张丰硕. 基于随机充电片段的锂电池健康状态估计方法[J]. 电源学报, 2024, 1-13.
GUO P X, ZHAO L, ZHANG F S. A method for estimating the State of health of lithium-ion batteries based on random charging segments[J]. Journal of Power Supply, 2024, 1-13.
- [17] 刘富强,刘为国,朱洪波. 基于灰狼算法优化Transformer-BiLSTM的锂电池健康状态预测方法[J]. 重庆工商大学学报(自然科学版), 2025, 1-12.
LIU F Q, LIU W G, ZHU H B. Optimized Transformer-BiLSTM based on gray wolf algorithm for health state prediction of lithium battery[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 1-12.
- [18] 时洪雷,刘喜军,高竞译,等. 基于超参数优化和混合神经网络的锂电池健康状态估计[J]. 储能科学与技术, 2025, 1-11.
SHI H L, LIU X J, GAO J Y, et al. State of health estimation of lithium-sulfur batteries based on hyperparameter optimization and hybrid neural networks[J]. Energy Storage Science and Technology, 2025, 1-11.
- [19] 武骥,方雷超,刘兴涛,等. 基于特征优化和随机森林算法的锂离子电池SOH估计[J]. 机械工程学报, 2024, 60(12): 335-343.
WU J, FANG L C, LIU X T, et al. State of health estimation of lithium-ion battery based on feature optimization and random forest algorithm[J]. Journal of Mechanical Engineering, 2024, 60(12): 335-343.
- [20] 陆继忠,彭思敏,李晓宇. 基于多特征量分析和LSTM-XGBoost模型的锂离子电池SOH估计方法[J]. 储能科学与技术, 2024, 13(9): 2972-2982.
LU J Z, PENG S M, LI X Y. State-of-health estimation of lithium-ion batteries based on multifeature analysis and LSTM-XGBoost model[J]. Energy Storage Science and Technology, 2024, 13(9): 2972-2982.
- [21] 耿陈,孟锦豪,彭乔,等. 基于弛豫过程特征提取的锂离子电池健康状态估计[J]. 储能科学与技术, 2023, 12(11): 3479-3487.
GENG C, MENG J H, PENG Q, et al. Estimation of the state of health of lithium-ion batteries based on feature extraction of the relaxation process[J]. Energy Storage Science and Technology, 2023, 12(11): 3479-3487.
- [22] 许培德,刘康,康龙云,等. 基于弛豫电压和BO-DNN的锂离子电池健康状态估计[J]. 电源学报, 2024, 1-14.
XU P D, LIU K, KANG L Y, et al. State of health estimation of lithium-ion battery based on relaxation voltage and BO-DNN[J]. Journal of Power Supply, 2024, 1-14.
- [23] 郭鹏旭,赵理,马占潮,等. GWO-CNN框架下的锂电池健康状态估计方法[J]. 重庆理工大学学报(自然科学), 2025, 39(4): 9-16.
GUO P X, ZHAO L, MA Z C, et al. Lithium battery health status estimation method under GWO-CNN framework[J]. Journal of Chongqing University of Technology (Natural Science), 2025, 39(4): 9-16.
- [24] CAI L, CUI N M, JIN H Y, et al. A unified deep learning optimization paradigm for lithium-ion battery state-of-health estimation[J]. IEEE Transactions on Energy Conversion, 2024, 39(1): 589-600.
- [25] ZHANG C L, LUO L J, YANG Z, et al. Battery SOH estimation method based on gradual decreasing current, double correlation analysis and GRU[J]. Green Energy and Intelligent Transportation, 2023, 2: 100108.
- [26] GUI X A, DU J R, SONG L, et al. A Transformer-CNN based transferable model for state-of-health prediction of lithium-ion batteries[C]. 2023 Global Reliability and Prognostics and Health Management Conference (PHM-Hangzhou), Hangzhou, China, 2023, 1-8.
- [27] SV M, D R, SUTHA S, et al. Data-driven model for estimation of SOH and internal resistance of lithium-ion battery based on deep neural network[C]. 2024 Tenth Indian Control Conference (ICC), Bhopal, India, 2024, 446-451.
- [28] YU Z W, PAN Z N. Joint estimation of SOH and RUL for lithium-ion batteries using CNN-GRU based on artificial lemming algorithm[C]. 2025 IEEE 3rd International Conference on Power Science and Technology (ICPST), Kunming, China, 2025, 1269-1274.
- [29] YANG S J, ZHANG C P, JIANG J C, et al. Review on state-of-health of lithium-ion batteries: Characterizations, estimations and applications[J]. Journal of Cleaner Production, 2021, 314: 128015.
- [30] CHEN C L P, LIU Z. Broad learning system: an effective and efficient incremental learning system without the need for deep

- architecture[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 29(1): 10-24.
- [31] ZHAO J J, ZHANG X Y, HU C H. Lithium-ion battery state-of-health estimation using voltage-position encoding CNN and incremental capacity analysis with a novel smoothing parameter selection strategy[J]. Journal of Energy Storage, 2025, 130: 117296.
- [32] LI S H, JIANG Z L, ZHU Z W, et al. A framework of joint SOC and SOH estimation for lithium-ion batteries: using BiLSTM as a battery model[J]. Journal of Power Sources, 2025, 635: 236342.
- [33] SHI Z L, XU J Z, IBRAHIM A, et al. Accurate state of health estimation based on the multi-feature extracted and improved MHA assisted CNN-BiGRU model for lithium-ion batteries[J]. Journal of Energy Storage, 2025, 131: 117598.
- [34] Wang F, Zhai Z, Zhao Z, et al. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis [J]. Nature Communications, 2024, 15(1): 4332.