

基于特征提取与NRBO-BiTCN-DTransformer融合模型的锂电池SOH估计

王 平, 杨占山

青海民族大学数学与统计学院, 青海 西宁

收稿日期: 2026年6月27日; 录用日期: 2026年7月19日; 发布日期: 2026年7月29日

摘 要

针对现有锂离子电池健康状态(SOH)估计方法中特征提取维数多、神经网络学习时序数据长期依赖以及计算成本高的问题, 本文提出一种融合特征提取与轻量化BiTCN-Transformer架构的锂离子电池SOH估计方法。首先, 从电池充放电数据中提取并筛选12个静态与动态健康因子, 采用堆叠自编码器进行降维融合, 得到5个高相关性特征。其次, 构建双向时序卷积网络BiTCN与Transformer混合模型, 利用BiTCN捕捉局部波动特征, Transformer建模全局老化趋势。之后将动态通道剪枝(DCP)技术引入Transformer编码器的注意力模块, 使用全连接层替代原Transformer的复杂解码器, 用GELU激活函数替换RELU激活函数以提升性能。并结合NRBO智能优化算法进行超参数自动寻优, 在保证估计精度的同时, 显著提升模型的运行效率与跨电池泛化能力。实验结果表明, 所提模型在独立的测试电池上SOH估计的精度以及计算效率均优于传统RNN、LSTM、Transformer等模型。

关键词

锂离子电池健康状态, 健康特征提取, Transformer, 动态通道剪枝, NRBO优化算法

SOH Estimation of Lithium-Ion Batteries Based on Feature Extraction and NRBO-BiTCN-DTransformer Fusion Model

Ping Wang, Zhanshan Yang

School of Mathematics and Statistics, Qinghai Minzu University, Xining Qinghai

Received: June 27, 2026; accepted: July 19, 2026; published: July 29, 2026

文章引用: 王平, 杨占山. 基于特征提取与 NRBO-BiTCN-DTransformer 融合模型的锂电池 SOH 估计[J]. 统计学与应用, 2026, 15(7): 204-220. DOI: 10.12677/sa.2026.157162

Abstract

To address the issues of high-dimensional feature extraction, long-term dependencies of neural networks learning on time series data, and high computational cost in existing lithium-ion battery state-of-health (SOH) estimation methods, this paper proposes a lithium-ion battery SOH estimation method combining feature extraction and a lightweight BiTCN-Transformer architecture. First, 12 static and dynamic health factors are extracted and selected from battery charge-discharge data and fused by dimensionality reduction via stacked autoencoder into 5 highly correlated features. Then, a hybrid model of bidirectional time series convolution network BiTCN-Transformer is built, where BiTCN captures local fluctuation features and Transformer models global degradation trends. Dynamic channel pruning (DCP) is introduced into the attention modules of the Transformer decoder, the original complex decoder of the Transformer is replaced by a fully connected layer, ReLU activation function is replaced by GELU activation function to improve performance, and NRBO intelligent optimization algorithm is used for automatic hyperparameter optimization to ensure the estimation accuracy while significantly improving the model's running efficiency and cross-battery generalization ability. Experimental results show that the proposed model outperforms traditional RNN, LSTM, and Transformer models in both SOH estimation accuracy and computational efficiency on independent test batteries.

Keywords

SOH of Lithium-Ion Battery, Health Feature Extraction, Transformer, Dynamic Channel Pruning, NRBO Optimization Algorithm

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着全球能源结构转型与“双碳”战略的加速推进,新能源汽车作为绿色交通体系的核心载体,其产业规模与技术成熟度持续提升[1]。锂离子电池凭借其较高的能量密度、长循环寿命及较低的自放电率等特性,已成为新能源汽车领域的核心动力来源[2]。然而,电池在长期使用过程中不可避免地会发生性能衰减,其健康状态直接决定了车辆的续航能力、运行安全与经济价值[3]。其中,健康状态作为量化电池老化程度与预测剩余使用寿命的关键指标,实现其精准、高效的估计,不仅是电池管理系统实现智能预警、优化充放电策略、提升系统可靠性的核心基础,也是保障新能源汽车安全运营与延长电池使用寿命的重要前提[4][5]。

当前,SOH估计方法主要可分为模型驱动与数据驱动两类。模型驱动方法基于电化学机理或等效电路建模,比如Yang等(2021)[6]基于二阶等效电路模型,利用恒压充电段的电流动态特性进行参数辨识,进而估测SOH。程泽等(2018)[7]则提出了基于自适应平方根无迹卡尔曼滤波与扩展卡尔曼滤波的SOC与SOH联合估计算法。在此基础上,李华等(2025)[8]设计了一种双层滤波结构:上层通过自适应扩展卡尔曼粒子滤波实现高动态SOC估计,下层结合自适应无迹卡尔曼滤波辨识欧姆内阻以跟踪SOH变化。

上述方法虽具有明确的物理意义,但普遍存在建模复杂、参数辨识困难、泛化能力有限等问题。近年来,以深度学习为代表的驱动方法因其能够直接从电池运行数据中学习复杂的非线性退化规律,逐渐成为研究主流。其中,冀鹏宇等(2026)[9]通过多元变分模态分解与蜜獾算法优化了LSTM模型,提

升了预测的时序分析能力。梁兆松等(2026) [10]则构建了 CNN-BiLSTM 混合模型, 并引入改进的蜚螂算法进行优化。谢国民等(2025) [11]提出了一种结合增量容量分析、电化学阻抗谱与 CNN-BiGRU-Attention 网络的混合特征提取方法, 提升了不同电池工况下的模型鲁棒性。刘么瑜等(2026) [12]提出了一种基于多阶段特征选择的锂电池 SOH 估计方法, 有效降低了估计误差。王喜阳等(2025) [13]提出了一种有限数据下基于 CNN-RVM 的锂电池 SOH 与 RUL 联合预测方法, 预测精度表现优异。张林等(2025) [14]提出采用容量增量曲线片段的锂电池 SOH 估计方法, 基于门控循环单元模型实现了高精度的电池健康状态估计。随着 Transformer 架构的引入, 其强大的全局依赖建模能力, 为捕捉电池老化过程中的长期趋势提供了新的技术路径。Hannan 等(2021) [15]提出自监督学习与 Transformer 结合方法, 有效缩短了训练时间并提高了 SOC 估计精度。陈欣(2023) [16]通过变分模态分解将容量衰退数据分解, 然后利用 Transformer 和 GRU 分别预测主趋势和高频子序列, 并融合预测结果, 兼顾了容量再生现象。黄紫依(2024) [17]融合了 TCN 和 Transformer 架构, 并用鲸鱼优化算法进行优化, 实现了高精度 SOH 预测。于天剑等(2026) [18]提出了 MLTA-Net, 并结合 LSTM 的短期记忆和 Transformer 的全局注意力机制, 实现了在复杂工况下的 SOC-SOH 联合估计。舒星等(2025) [19]则结合 CNN 提取局部特征和 Transformer 捕捉长期依赖, 并采用贝叶斯优化超参数, 实现 SOH 估计。

然而, 现有方法仍面临特征提取维数高、神经网络难以捕捉时序长期依赖, 以及模型计算成本过高等问题。鉴于此, 本文提出了一种基于特征提取与轻量化 BiTCN-Transformer 混合模型的锂离子电池 SOH 估计方法。该方法的具体创新在于:

(1) 通过特征工程提取并筛选能够全面反映电池退化静态属性与动态趋势的健康因子。

(2) 构建双向时间卷积网络 BiTCN 与 Transformer 编码器混合模型, 融合 BiTCN 的局部特征捕捉能力与 Transformer 的全局依赖建模能力, 实现优势互补。

(3) 在 Transformer 编码器的注意力模块中引入动态通道剪枝技术(DCP)、以全连接层替代原解码器、采用 GELU 激活函数[20]替换 RELU 激活函数, 并结合 NRBO 算法自动寻优, 在保证估计精度的同时提升运行效率与跨电池泛化能力。

2. 数据处理

2.1. 电池数据集介绍

NASA 公开电池数据集由艾姆斯研究中心发布, 采用 18650 型钴酸锂电池, 额定容量 2 Ah, 型号为 B0005、B0006、B0007、B0018, 在 24℃恒温环境下进行充放电测试, 先以 1.5 A 恒流充电至 4.2 V, 再恒压充电至电流衰减, 然后以 2 A 恒流放电至电压 2.7 V 或 2.5 V, 循环记录电压、电流、温度及容量衰减数据。CALCE 数据集由马里兰大学先进生命周期工程中心发布, 是锂离子电池老化研究的另一权威基准。常用电池型号为 CS2 系列, 标称容量 1.1 Ah, 以及 INR18650 系列, 标称容量 2.0 Ah。测试通常在恒温 1℃或室温条件下进行, 采用标准的恒流恒压充电和恒流放电流程, 记录电压、电流、温度及容量衰减数据, 用于评估电池健康状态和寿命预测。

上述两种数据集工况统一、覆盖不同衰减速率, 数据质量高且为领域常用基准。由于电池在长期使用过程中不可避免地会发生性能衰减, 其健康状态 SOH 是评估电池老化程度的核心指标, 通常被定义为电池当前最大可用容量与额定容量的比值。表达式如下所示:

$$\text{SOH} = \frac{C_{\text{current}}}{C_{\text{rated}}} \times 100\% \quad (1)$$

其中, C_{current} 表示电池当前的实际可用容量, C_{rated} 表示电池出厂时标定的额定容量。

以 NASA 数据集为例, 图 1 展现了 B0005、B0006、B0007、B0018 四节电池的健康状态随充放电循环次数增加的整体衰减规律, 其中一次循环代表一次完整的充放电过程。从图中可以看出, 所有电池 SOH 均从初始接近 1.0 的水平持续下降, 其中 B0006 退化速率最快, B0007 和 B0018 的衰减趋势相对平缓; 且发现在曲线下降过程中出现了多处小幅回升的波动, 这一现象称作电池的容量再生, 即电池在循环衰减过程中因电极界面重构、活性物质恢复等因素, 实际可用容量短暂回升, 使得 SOH 出现阶段性小幅反弹。




Figure 1. SOH degradation curves of batteries B0005, B0006, B0007, and B0018

图 1. B0005、B0006、B0007、B0018 电池 SOH 退化曲线

2.2. 数据预处理

缺失值与异常值处理: 识别数据中的缺失值并进行处理; 基于箱线图法检测明显异常点, 对异常点予以剔除; 时间序列数据对齐: 以电压为基准, 对电流、温度等时间序列数据执行线性插值操作, 实现数据维度的对齐; 充放电循环切分: 依据充放电循环的起始电压阈值, 精准切分出每个独立的充放电循环。

2.3. 健康因子提取与筛选

锂离子电池 SOH 估计需综合考虑内外部影响因素。由于电池内部电化学机制具有“黑箱”特性, 当前研究普遍采用由外及内的路径, 提取与容量衰减高度相关的健康因子。而健康因子的选取直接影响预测模型的效果, 不同组合会导致显著差异。因此, 本文以 B0005 型号锂离子电池为例, 分别在第 80、90、100、120 次循环下, 基于温度、电压、电流及容量增量等关键参数提取静态和动态健康因子, 为后续预测模型建立提供数据基础。

2.3.1. 静态健康因子提取

根据图 2~4, 在充电过程中随着电池充放电循环次数增加, 电池内阻增大副反应加剧, 导致充电产热增多, 温度峰值显著上升, 因此将充电温度峰值作为 HF1。cc 阶段, 随着充放电循环次数增加, 活性物质会逐渐衰减, 锂库存损失, 恒流充电时间在逐渐缩短, 充电容量(即曲线下方所围成面积)也逐渐下降, 因此将其作为 HF2 和 HF3。cv 阶段, 随充放电循环次数增加, 电池内阻增大引发恒流阶段结束时的极化电压升高、电压平台发生偏移, 恒压充电时间逐渐增加, 等压差充电时间逐渐缩短, 因此将这两个特征作为 HF4 和 HF5。




Figure 2. Temperature curves under different cycles
图 2. 不同循环下温度曲线




Figure 3. Current curves under different cycles
图 3. 不同循环下电流曲线




Figure 4. Voltage curves under different cycles
图 4. 不同循环下电压曲线

增量容量分析法(Incremental Capacity Analysis, ICA)是基于电池充放电电压 - 容量曲线, 通过计算容量增量来刻画电池老化特征, 进而实现对 SOH 的精准预测。其表达式如下:

$$\frac{dQ}{dV} \approx \frac{\Delta Q}{\Delta V} = \frac{Q_t - Q_{t-1}}{V_t - V_{t-1}} \quad (2)$$

其中: Q_t 、 Q_{t-1} 和 V_t 、 V_{t-1} 为第 t 和 $t-1$ 时刻已充入的电池容量与端电压。不同循环次数的 IC 曲线有明显差异, 因此可考虑从 IC 曲线上提取出电池老化特征。由于 IC 曲线基于离散采样数据生成, 其中包含的噪声与测量误差可能导致曲线出现明显波动与不平滑现象。这种不稳定性会影响健康因子提取的准确性, 因此采用 Savitzky-Golay 滤波器[21]对原始 IC 曲线采用窗口进行平滑处理, 经多组阶数与窗口对比测试, 最终确定 Savitzky-Golay 滤波器的窗口大小为 15, 多项式阶数为 3。这里以 B0005 电池为例给出平滑后曲线如图 5 所示, 发现平滑处理有效抑制了原始曲线中的噪声波动, 使其走势更为平缓, 同时关键形态特征得以保留, 整体变化趋势与原始曲线保持一致。且随着充放电循环次数的增加, IC 曲线的峰值呈现持续下降趋势, 峰值对应的电压值逐步降低, 曲线所围面积逐渐减小, 副峰个数逐渐增加, 峰宽逐渐变大, 这是因为电池长期循环引发活性物质衰减、内阻上升与反应动力学变差, 直观体现在 IC 曲线形态异变, 因此将这 5 个特征作为 HF6~HF10。




Figure 5. Smoothed IC curves of B0005 battery under different cycles

图 5. B0005 电池不同循环下平滑后 IC 曲线

2.3.2. 动态健康因子提取

以 B0005 为例, 基于平滑后的 IC 曲线, 采用固定滑动窗口法以 10 个连续循环为窗口, 对窗口内的 IC 曲线的峰值作线性拟合, 取拟合直线的斜率作为 HF11, 该指标能够量化电池内部活性物质损耗与锂库存衰减的整体速率, 反映电池容量的退化速率, 该斜率越陡, 表明电池退化速率越快; 同时对窗口内 IC 曲线峰值求标准差, 得到 HF12, 反映电池退化过程的局部波动性, 该数值越大, 说明 IC 曲线波动剧烈, 电池内部反应一致性变差, 本质是电极老化、界面阻抗不均引发的电化学反应失稳, 可能伴随着活性物质流失、内阻不均等老化问题。

2.3.3. 相关性分析

相较于皮尔逊相关系数, 斯皮尔曼秩相关系数不依赖于数据分布的正态性假设, 而是依据变量的秩次信息进行计算。该方法不仅适用于连续数据, 也可处理有序分类变量, 且对异常值与数据噪声具有更

强的稳健性。计算公式如下所示:

$$\rho=1-\frac{6\sum d_i^2}{n(n^2-1)}$$

(3)

其中, n 表示变量 x 和 y 的总数据样本量, d_i 表示变量 x 与 y 第 i 个数据对的秩次差。该统计量的取值范围在-1 到 1 之间。

根据表 1 数据, 所提取的 12 个健康因子与 SOH 均呈现高度相关($|r| > 0.8$)。然而, 若将其全部输入模型, 不仅会增加模型复杂度和训练参数量、延长训练时间, 还可能引发过拟合问题。因此, 需对健康因子进行特征压缩与降维处理。

Table 1. Correlation coefficients between HF_s and SOH

表 1. HF_s 与 SOH 的相关系数

特征	Feature	Correlation
HF1	充电温度峰值	0.9020
HF2	恒流充电时间	0.9574
HF3	恒流充电阶段电流曲线所围面积	0.9452
HF4	恒压充电时间	-0.9386
HF5	等压差充电时间	0.9454
HF6	IC 曲线峰值	0.8974
HF7	IC 曲线峰值对应电压	0.8777
HF8	IC 曲线峰面积	0.8301
HF9	IC 曲线副峰个数	-0.8799
HF10	IC 曲线峰宽	-0.8851
HF11	IC 曲线窗口内序列一阶导数(斜率)	-0.8233
HF12	IC 曲线窗口内序列标准差	0.8217

本文采用堆叠自编码器(SAE)对 12 个健康因子进行深层特征提取, 在保留关键信息的前提下将其压缩至更低维度, 以实现有效降维。在每个隐藏层中, 选择 Sigmoid 函数作为激活函数, 选用 Adam 优化器, 损失函数选择均方根误差 RMSE。如表 2 所示, 融合降维后的 5 个新健康因子与 SOH 仍保持高度相关, 相关系数绝对值均在 0.7 以上, 说明它们能够有效替代原始健康因子, 对电池容量衰退过程具备良好的表征能力。为提升模型的可解释性, 对降维特征与原始健康因子进行了相关性分析, 结果发现: 每个新特征都与特定类别的原始健康因子, 如电压平台、温度峰值、IC 曲线变化等显著相关, 这说明新特征既保留了原始老化信息, 也使得降维后仍保留了一定的物理可解释性。

Table 2. Correlation coefficients between HF_{snew} and SOH after dimensionality reduction and fusion

表 2. 降维融合后的 HF_{snew} 与 SOH 的相关系数

融合后健康因子	Correlation
HF1new	0.8032
HF2new	-0.7546
HF3new	0.8764
HF4new	0.8365
HF5new	-0.7145

在训练模型之前, 采用最小 - 最大归一化方法, 对融合降维得到的 5 个新健康因子和电池的 SOH 共 6 个特征做标准化处理, 将所有特征的取值范围压缩至 0~1 之间, 以此作为模型的输入特征进行训练, 具体计算公式如下所示:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

其中, x' 为参数标准化后的数值, x 为参数标准化前的原始数值, $x_{\min}$ 与 $x_{\max}$ 分别表示该参数的最小值和最大值。

2.4. 模型评价指标

采用均方根误差、平均绝对误差、平均相对误差衡量模型真实值与预测值的偏差程度, 用决定系数衡量模型的拟合程度, 其中各个公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

3. 基本原理与方法介绍

3.1. BiTCN 模型

双向时间卷积网络(BiTCN)是一种用于时间序列数据处理的深度学习模型, 它由两个独立的单向卷积神经网络组成, 一个从左到右处理输入序列以提取过去信息, 另一个从右到左处理输入序列来提取未来信息, 之后将两个单向网络的输出连接并送入全连接层进行最终预测。这种双向结构使得 BiTCN 能够充分利用时间序列的上下文信息, 提高预测精度, 并且它还通过膨胀卷积等技术扩大感受野, 能有效捕捉时间序列中的长短期依赖关系。其中的因果扩张卷积的数学表达式如下:

$$y(t) = \sum_{k=0}^{K-1} \omega(k) \cdot x(t - d \cdot k) \quad (9)$$

其中, $\omega(k)$ 是卷积核的第 k 个元素, d 是扩张因子, k 为卷积核大小。

3.2. Transformer 模型

Transformer 模型[22]是摒弃传统 RNN 序列依赖、以自注意力机制为核心的深度学习架构, 它通过多头注意力并行计算输入序列中所有元素的关联权重, 再结合前馈神经网络处理特征。其结构包含编码器(Encoder)和解码器(Decoder): 编码器通过多层注意力与前馈网络, 将输入转化为富含全局上下文的特征向量; 解码器则增加掩码注意力, 基于编码器输出生成目标序列。

位置编码方法是引入正弦函数和余弦函数进行处理, 具体的计算公式如下所示:

$$PE(pos, 2i) = \sin\left(\frac{pos}{10000^{2i/d}}\right) \quad (10)$$

$$PE(pos, 2i+1) = \cos\left(\frac{pos}{10000^{2i/d}}\right) \quad (11)$$

其中, pos 表示序列中词语的位置, i 表示位置编码向量的维度索引, d 表示词嵌入向量的维度。

多头注意力机制由多个并行的自注意力模块组成。每个模块使用独立的权重矩阵, 将输入序列分别映射为查询、键和值矩阵, 然后计算自注意力。公式如下:

$$Q = XW^Q, L = XW^K, V = XW^V \quad (12)$$

$$Attention(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (13)$$

其中, W^Q 、 W^K 、 W^V 是可训练的权重矩阵, Q 、 K 、 V 分别表示查询矩阵、键矩阵和值矩阵, 点积得到的结果除以 $\sqrt{d_k}$ 是为了防止数值过大引起的梯度消失问题。

前馈神经网络的核心功能是依托注意力机制完成特征的深度提取, 以此强化模型的特征表达能力, 它由两个全连接层构成, 会对输入序列进行两次线性变换处理与一次 ReLU 非线性变换, 计算公式如下所示:

$$FFN(x) = \max(0, xw_1 + b_1)w_2 + b_2 \quad (14)$$

其中, w_1 和 w_2 是线性变换对应的权重矩阵, b_1 和 b_2 则是线性变换层的偏置向量。

残差连接和层归一化: 残差连接目的是增强模型的稳定性, 避免出现梯度消失和梯度爆炸的问题。层归一化则是使数据分布更加均匀, 进而加速模型收敛并提升稳定性。

本文采用全连接层代替解码层, 直接接收编码器的输出, 通过线性变换和激活函数, 一次性生成完整的预测结果, 并将动态通道剪枝技术引入编码器的注意力模块, 改进后的模型结构如图 6 所示。




Figure 6. Improved Transformer model
图 6. 改进后的 Transformer 模型

3.3. 动态通道剪枝技术(DCP)

与模型训练完成后进行一次性静态剪枝不同, 动态通道剪枝[23]通常通过引入门控机制或周期性的迭代剪枝与微调来实现。动态通道剪枝流程如下:

(1) 初始化: 在模型训练初始阶段, 通常保留所有通道, 不进行任何剪枝。此时, 模型拥有最大的容量来学习特征。

(2) 在训练迭代中:

1) 前向传播: 模型正常进行前向传播, 计算输入数据通过各层的输出。

2) 计算重要性: 根据预设的策略计算每个通道的重要性分数。常用的指标包括 L1 或 L2 范数等。

3) 应用门控或掩码: 基于计算出的重要性分数, 对通道进行选择保留或裁剪。

硬门控: 如果某个通道的重要性低于预设的阈值, 将其“硬性”删除。即该通道的权重会被置零, 或者乘以一个趋近于零的极小的数值, 使其在后续计算中基本不起作用。

软门控: 将通道的重要性度量输入到一个 Sigmoid 函数或其他激活函数中, 得到一个介于 0 到 1 之间的连续值。这个值代表了通道被保留的“强度”。然后, 将计算出的特征图乘以对应的值进行加权, 从而实现通道的平滑裁剪。

4) 梯度传播与更新: 在反向传播过程中, 梯度会流经未被剪枝的通道。被“剪掉”的通道, 其相关参数将不会或极少接收到梯度更新, 从而阻止其继续学习。

5) 动态调整剪枝策略: 根据模型在训练集上的表现, 动态调整需要剪枝的通道数量或阈值。

(3) 性能恢复: 执行剪枝后, 模型性能有时会受到一定影响。为恢复性能, 可引入“知识蒸馏”。

(4) 最终微调: 在完成剪枝并可能进行蒸馏之后, 会对最终的模型进行一次短时间的“微调”。

3.4. NRBO 算法

NRBO (Newton-Raphson-Based Optimizer)算法[24]是一种于 2024 年提出的元启发式优化算法。该算法通过融合基于二阶导数的牛顿-拉夫逊搜索规则, 显著加速了局部搜索与收敛过程; 同时, 引入陷阱避免算子与自适应扰动机制, 有效提升算法在复杂空间中的全局探索能力, 避免陷入局部最优。算法流程如下:

(1) 种群初始化: 随机生成初始种群个体位置:

$$x_i = l_h + c_x \times (u_h - l_h) \quad (15)$$

式中, x_i 表示种群个体位置, l_h 与 u_h 分别表示优化参数的上下限, c_x 表示(0, 1)之间的随机数。

(2) 牛顿-拉夫逊搜索规则

通过以下公式更新位置:

$$K_{NRSR} = c_{randn} \times \frac{(y_u - y_h) \times \Delta x}{2 \times (y_u + y_h - 2 \times x_b^T)} \quad (16)$$

$$F_a^T = x_a^T - K_{NRSR} + (a \times (X_r - x_a^T) + b \times (x_b - x_a^T)) \quad (17)$$

$$S_a^T = x_a - K_{NRSR} + (a \times (X_r - x_a^T) + b \times (x_b - x_a^T)) \quad (18)$$

$$R_a^T = x_a^T - \delta \times (S_a^T - F_a^T) \quad (19)$$

$$x_a^{T+1} = r_1 \times (r_2 \times F_a^T + (1 - r_2) \times S_a^T) + (1 - r_1) \times R_a^T \quad (20)$$

式中, K_{NRSR} 为 NRSR 搜索结果, c_{randn} 表示均值为 0、方差为 1 的正态分布随机数, Δ_x 为扰动量, F_a^T 、 S_a^T 、 R_a^T 分别为由当前位置更新得到的 3 个候选位置, x_a^{T+1} 和 x_a^T 分别为 NRSR 搜索规则所得到的新位置与当前位置, r_1 和 r_2 为随机整数, a 和 b 分别为 $(0, 1)$ 区间内的随机数, δ 为自适应参数, δ 的值在 $(-1, 1)$ 间变化。

(3) 陷阱避免算子

若随机数小于决策因子, 则通过组合当前最优位置与随机位置跳出局部最优。

3.5. SOH 估计流程

图 7 系统展示了从数据预处理、特征工程、模型构建、超参数寻优到实验验证的全流程, 直观呈现电池健康状态预测的核心研究框架与实施步骤。




Figure 7. Flowchart of SOH estimation
图 7. SOH 估计流程图

4. 实验设计与数据分析

4.1. 模型实验环境与参数设置

本文所有基于深度学习的锂离子电池健康状态预测实验均在同一台操作系统为 Windows 10 的计算机上完成, 使用 Python 语言编写, 在 Pytorch 框架下搭建模型。

模型训练过程中, 超参数的取值会对最终预测性能产生显著影响。因此, 本文用 NRBO 算法对编码器头数、学习率和 Dropout 率等超参数寻优。预测模块的具体参数如表 3 所示, 主要展示了参数寻优范围和结果, 以及其他参数设置。

Table 3. Model hyperparameter settings
表 3. 模型超参数设置

参数名称	寻优范围	值
学习率	[0.0001, 0.01]	0.001
卷积核大小	—	2
卷积核数量	[64, 512]	122
输入嵌入层维度	[32, 256]	44
动态剪枝比例	—	0.5
编码器中多头注意力头数	—	4
编码器堆叠层数	[4, 16]	4
编码器中前馈网络维度	[64, 256]	84
Dropout 率	[0, 0.5]	0.1
优化器	—	Adam
激活函数	—	Gelu
损失函数	—	MSE

4.2. SOH 测试结果

采用按电池划分的策略用来严格评估模型的泛化能力, 选取 NASA 数据集中 B0005、B0006 和 B0007 的全部数据作为训练集, 将 B0018 作为独立测试集。这种固定划分方式确保了测试集是完全独立的电池个体, 与训练集无任何交集, 从而严格模拟模型在真实场景下面临全新电池时的 SOH 估计性能与泛化能力。由图 8 可知, 通过构建 NRBO-BiTCN-DTTransformer 模型, 得出在测试集 B0018 上的 SOH 估计结果。可以看出模型预测结果与真实数据的匹配度较高, 整体预测偏差控制在较低水平。这充分证明了本文所构建的融合模型在锂离子电池健康状态预测任务时具备出色的准确性与可靠的预测能力。




Figure 8. SOH prediction curve of B0018 battery
图 8. B0018 电池 SOH 预测曲线

4.3. 对比实验

4.3.1. 不同剪枝率下的模型性能比较

为验证动态通道剪枝技术(DCP)应用于 Transformer 模型注意力头剪枝的实际效果, 本实验选取 0% (未剪枝)、20%、50%和 70%四种剪枝率, 评估模型在 SOH 估计任务中的性能表现, 具体结果如表 4 所示。结果表明, 相较于未剪枝(0%)的原始 Transformer 模型, 所有剪枝率下的模型在 MAE、RMSE、MRE 指标上均实现下降。在计算效率方面, 观察到虽然随着剪枝率的提高, 计算时间在不断缩小, 但过高的剪枝率会影响到 SOH 的估算精度。因此, 通过综合精度与计算时间的表现, 最终选定了 50%的剪枝率为 SOH 估计的最优选择。它在保证模型精度的前提下, 实现了显著的计算效率提升。

从图 9 也可以观察到, 在剪枝率达到 50%时, 模型在平均绝对误差(MAE)、均方根误差(RMSE)、平均相对误差(MRE, 单位%)这三个关键评估指标上均呈现出最小值, 表明此时模型精度最优。

Table 4. Model performance under different pruning rates
表 4. 不同剪枝率下模型性能

剪枝率	MAE	RMSE	MRE (%)	计算时间/s
0%	0.035	0.042	0.044	576
20%	0.032	0.038	0.041	484
50%	0.025	0.031	0.023	343
70%	0.029	0.037	0.034	254




Figure 9. Comparison of model performance under different pruning rates
图 9. 不同剪枝率下模型性能对比图

4.3.2. 本文模型与传统模型性能比较

为验证 NRBO-BiTCN-DTransformer 模型的有效性, 在同一实验环境下, 本文将其与 RNN、LSTM、GRU、CNN 及标准 Transformer 等经典深度学习模型进行对比, 各模型性能指标如表 5 所示。可以看出, 提出的 NRBO-BiTCN-DTransformer 模型在预测精度与计算效率上显著优于 RNN、LSTM、GRU、传统 Transformer 等单一模型及各类融合深度学习模型。就预测误差而言, 该模型 MAE 与 RMSE 分别低至 0.017 和 0.021, 相较于次优的 CNN-Transformer 模型进一步降低, 体现出更强的预测准确性; 在拟合效果方面, 其 R^2 达到 0.930, 在所有模型中最高, 体现出对数据规律的更深层捕捉; 而在计算效率层面,

该模型不仅在计算复杂度上远低于 LSTM 和传统 Transformer，相比于 CNN-Transformer 等融合模型也表现出更优的运行效率。

Table 5. Comparison of NRBO-BiTCN-DTransformer model and model performance
表 5. NRBO-BiTCN-DTransformer 模型与模型性能比较

模型	MAE	RMSE	R ²	计算时间/s
RNN	0.038	0.051	0.816	1186
LSTM	0.032	0.040	0.853	1418
GRU	0.027	0.038	0.865	1087
传统 Transformer	0.035	0.042	0.821	1465
LSTM-Transformer	0.025	0.036	0.896	1073
BiTCN-GRU	0.023	0.034	0.889	1185
CNN-Transformer	0.020	0.029	0.914	953
本文模型	0.017	0.021	0.930	806

综合来看，上述实验结果充分验证了所构建的 NRBO-BiTCN-DTransformer 模型的有效性与优势，该模型在误差控制、拟合能力与计算效率上的整体表现，充分证明了其架构设计的合理性与实用性。

从图 10 也可以清晰地看到，相较于单一模型及其他融合模型，所构建的 NRBO-BiTCN-DTransformer 模型在预测精度上展现出明显优势。




Figure 10. Performance comparison of each model
图 10. 各模型性能对比图

4.3.3. 不同数据集对比实验

为进一步验证模型的泛化能力与鲁棒性，开展不同数据集对比实验(见表 6)。实验保证网络结构、超参数与评价指标等完全一致，以 CALCE 数据集 CS2-34、CS2-35、CS2-36 为训练集，CS2-37 为测试集。

Table 6. Comparison experiments with different datasets
表 6. 不同数据集对比试验

评价指标	NASA 数据集		CALCE 数据集	
	训练集	测试集	训练集	测试集
MAE	0.008	0.017	0.011	0.019
RMSE	0.010	0.021	0.014	0.023
R ²	0.981	0.930	0.972	0.921

结果表明, 两种数据集训练集与测试集的评价指标差距均较小, 且测试集精度相近, 不存在过拟合现象, 表明所提模型在 CALCE 数据集上仍能保持较低的预测误差, 充分证明模型具备良好的跨数据集泛化能力。

4.4. 模型消融实验

模型消融实验是验证模型各模块有效性的核心实验方法, 其核心思路是先构建性能最优的基准模型, 再通过逐一移除或替换模型的某个部分, 对比移除前后模型的性能变化, 从而判断该模块对模型效果的贡献度。为进一步验证所提 NRBO-BiTCN-DTTransformer 模型的高效性, 在同一实验环境下对数据进行消融实验。

根据表 7 可以看出, 本文为实现续航更持久、性能更强的 SOH 估计模型, 基于 Transformer 构建了一系列改进方式并对其性能进行了对比评估。作为基准的纯 Transformer 模型在所有模型中表现最弱, MAE 为 0.035, RMSE 为 0.042, R² 为 0.821, 为后续改进提供了明确起点。在 Transformer 基础上引入 DCP 模块后, 模型性能显著提升, MAE 降至 0.025, RMSE 降至 0.031, R² 升至 0.888, 证实了该模块对模型效果的正向贡献。而单独增加 BiTCN 模块的模型虽然优于纯 Transformer, 但弱于 DTTransformer, 表明 BiTCN 也能独立提升模型能力, 但其效果相对有限。当同时引入 BiTCN 与 DCP 模块时, 模型性能进一步提升, MAE 降至 0.021, RMSE 为 0.028, R² 达到 0.917, 显示出双模块的协同增益效应。在此基础上, 进一步引入 NRBO 对模型参数进行优化, 最终模型的性能达到最优, MAE 为 0.017, RMSE 为 0.021, R² 提升至 0.93。

综上, DCP、BiTCN 与 NRBO 模块均能有效提升模型精度, 且多模块组合展现出更强的性能增益, 其中 NRBO 的引入使模型达到当前最佳状态。

Table 7. Comparison results of ablation experiments
表 7. 消融实验对比结果

模型	MAE	RMSE	R ²
Transformer	0.035	0.042	0.821
DTTransformer	0.025	0.031	0.888
BiTCN-Transformer	0.030	0.037	0.874
BiTCN-DTTransformer	0.021	0.028	0.917
NRBO-BiTCN-DTTransformer	0.017	0.021	0.930

5. 结论

本文针对 SOH 估计中存在的特征提取维数多、神经网络模型学习时序数据长期依赖以及计算成本高等问题, 提出一种基于特征提取与轻量化 BiTCN-Transformer 混合模型的 SOH 估计方法。通过对两种公

开数据集中多节电池的充放电数据进行系统分析, 提取了 12 个与 SOH 高度相关的健康因子, 并利用堆叠自编码器进行降维融合, 有效减少了特征维度并保留了关键退化信息。

在模型构建方面, 设计了一种融合双向时序卷积网络 BiTCN 与 Transformer 的混合模型。利用 BiTCN 捕捉局部波动特征, Transformer 建模全局老化趋势。将动态通道剪枝 DCP 技术引入 Transformer 编码器的注意力模块, 以全连接层替代原 Transformer 架构中复杂的解码器, 同时采用 GELU 激活函数替换 RELU 激活函数。并引入 NRBO 智能优化算法完成模型超参数的自动寻优, 进一步提升了模型的拟合能力与跨样本泛化性能。

实验结果表明, 所提 NRBO-BiTCN-DTransformer 模型在独立测试电池(B0018)上表现出优异的 SOH 估计性能, 其 MAE、RMSE 和 R^2 分别为 0.017、0.021 和 0.930, 显著优于 RNN、LSTM、GRU、传统 Transformer 及其他融合模型。消融实验验证了 DCP 剪枝、BiTCN 模块和 NRBO 优化各自对模型性能的积极贡献, 尤其是动态通道剪枝技术在 50%剪枝率下, 在几乎不影响精度的前提下大幅提升了计算效率。换算为单一样本推理时间, 模型平均推理耗时较传统 Transformer 模型降低 45%以上, 可满足车载 BMS 平台的算力限制与实时性要求。

综上所述, 本文提出的方法在 SOH 估计任务中实现了高精度、高效率与强泛化能力的平衡。然而, 当前模型验证仍基于实验室理想工况数据, 但真实车载场景中复杂工况、传感器噪声、电池个体差异等因素仍会对模型泛化性带来挑战, 实际部署前还需结合目标车型的真实数据进行适配与微调。未来工作将进一步结合真实车载运行数据开展跨数据集、跨工况的泛化性研究, 优化模型在噪声、极端工况下的性能表现, 推动该方法向车载端实际部署的转化。

基金项目

青海省自然科学基金(No. 2025-ZJ-902T)。

参考文献

- [1] 李威, 池梦娜, 张孟亚. 政府激励政策对新能源汽车企业突破性创新影响研究[C]//中国科学学与科技政策研究会. 第二十一届中国科技政策与管理学术年会论文摘要集. 天津: 河北工业大学, 2025: 104.
- [2] 吕媛媛, 洪颖, 丁斌, 等. 新能源锂离子电池热失控性能研究[J]. 储能科学与技术, 2026, 15(2): 391-397.
- [3] Tang, X., Zou, C., Wik, T., Yao, K., Xia, Y., Wang, Y., et al. (2020) Run-To-Run Control for Active Balancing of Lithium Iron Phosphate Battery Packs. *IEEE Transactions on Power Electronics*, **35**, 1499-1512. <https://doi.org/10.1109/tpel.2019.2919709>
- [4] Yi, L., Wang, J., Fu, Y., Zhang, Z., Jiang, R. and Li, J. (2025) Aging Mechanism Analysis under Different Charging Voltages and Online SOH Estimation of Li-Ion Batteries. *Journal of Renewable and Sustainable Energy*, **17**, Article ID: 014104. <https://doi.org/10.1063/5.0243019>
- [5] Ke, Y., Long, M., Yang, F. and Peng, W. (2023) A Bayesian Deep Learning Pipeline for Lithium-Ion Battery SOH Estimation with Uncertainty Quantification. *Quality and Reliability Engineering International*, **40**, 406-427. <https://doi.org/10.1002/qre.3424>
- [6] Yang, J., Cai, Y. and Mi, C.C. (2022) State-Of-Health Estimation for Lithium-Ion Batteries Based on Decoupled Dynamic Characteristic of Constant-Voltage Charging Current. *IEEE Transactions on Transportation Electrification*, **8**, 2070-2079. <https://doi.org/10.1109/tte.2021.3125932>
- [7] 程泽, 杨磊, 孙幸勉. 基于自适应平方根无迹卡尔曼滤波算法的锂离子电池 SOC 和 SOH 估计[J]. 中国电机工程学报, 2018, 38(8): 2384-2393, 2548.
- [8] 李华, 周纯燕, 马倩怡. 基于 AEKPF-AUKF 的电动汽车电池 SOC/SOH 联合估计方法研究[J]. 机械设计与制造, 2025, 416(10): 55-60.
- [9] 冀鹏宇, 乔钢柱, 姬钰培, 等. 多元变分模态分解的 HBA-LSTM 锂离子电池 SOH 预测[J]. 中国测试, 2026, 52(5): 137-146.
- [10] 梁兆松, 田恩刚, 李磊. 基于 IDBO-CNN-BiLSTM 锂电池剩余使用寿命预测[J]. 电子科技, 2026, 39(1): 18-24.

-
- [11] 谢国民, 刘澳. 基于混合特征提取和机器学习的锂离子电池健康状态估计[J]. 电力系统自动化, 2025, 49(21): 120-130.
- [12] 刘△瑜, 李硕, 柴静, 等. 基于多阶段特征选择策略的锂电池 SOH 估计[J/OL]. 电源学报: 1-10. <https://link.cnki.net/urlid/12.1420.TM.20260317.0958.002>, 2026-04-26.
- [13] 王喜阳, 苏垚, 李辉, 等. 有限数据下的锂离子电池 SOH 与 RUL 联合预测[J/OL]. 电源学报: 1-14. <https://link.cnki.net/urlid/12.1420.tm.20250827.1129.006>, 2026-04-26.
- [14] 张林, 宋展鹏, 黄鑫蓉, 等. 采用容量增量曲线片段的锂离子电池健康状态估计[J/OL]. 电源学报: 1-12. <https://link.cnki.net/urlid/12.1420.tm.20250704.1023.002>, 2026-04-26.
- [15] Hannan, M.A., How, D.N.T., Lipu, M.S.H., Mansor, M., Ker, P.J., Dong, Z.Y., *et al.* (2021) Deep Learning Approach Towards Accurate State of Charge Estimation for Lithium-Ion Batteries Using Self-Supervised Transformer Model. *Scientific Reports*, **11**, Article No. 19541. <https://doi.org/10.1038/s41598-021-98915-8>
- [16] 陈欣. 基于模态分解的 Transformer-GRU 联合电池健康状态估计[J]. 储能科学与技术, 2023, 12(9): 2927-2936.
- [17] 黄紫依. 基于 WOA-TCN-Transformer 的锂离子电池健康状态预测[D]: [硕士学位论文]. 武汉: 华中科技大学, 2024.
- [18] 于天剑, 曾笑颜, 冯恩来, 等. 基于 LSTM-Transformer 多通道特征融合的锂电池 SOC-SOH 联合估计[J]. 铁道科学与工程学报, 2026, 23(1): 301-313.
- [19] 舒星, 杨浩, 刘西, 等. 融合 CNN 与 Transformer 的锂离子电池健康状态估计[J]. 重庆理工大学学报(自然科学), 2025, 39(7): 1-8.
- [20] Hendrycks, D. and Gimpel, K. (2016) Gaussian Error Linear Units (Gelus). arXiv: 1606.08415.
- [21] Savitzky, A. and Golay, M.J.E. (1964) Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*, **36**, 1627-1639. <https://doi.org/10.1021/ac60214a047>
- [22] Vaswani, A. (2017) Attention Is All You Need. arXiv: 1706.03762.
- [23] 易见兵, 胡雅怡, 曹锋, 等. 融合动态通道剪枝的轻量级 CT 图像肺结节检测网络设计[J]. 广西师范大学学报(自然科学版), 2025, 43(6): 92-106.
- [24] Sowmya, R., Premkumar, M. and Jangir, P. (2024) Newton-Raphson-Based Optimizer: A New Population-Based Metaheuristic Algorithm for Continuous Optimization Problems. *Engineering Applications of Artificial Intelligence*, **128**, Article ID: 107532. <https://doi.org/10.1016/j.engappai.2023.107532>