

## 基于 CNN-Transformer 的锂离子电池健康状态估计

陈国麟, 姚行艳

重庆工商大学 人工智能学院, 重庆 400067

**摘要:**目的 健康状态是评估锂离子电池状态的关键参数,对锂离子电池的安全使用有着十分重要的意义,为了获得准确可靠的健康状态估计结果,建立基于卷积神经网络和 Transformer 的锂离子电池健康状态估计方法,利用不同模型的数据挖掘特性,将健康指标的深层信息和随循环周期增加的时序信息并行提取。方法 从锂离子电池放电过程中的部分电压和温度曲线中提取 3 个与健康状态相关性较强的健康指标作为模型输入,利用卷积神经网络强大的特征提取能力挖掘健康指标的局部特征,利用 Transformer 的顺序处理能力挖掘健康指标的时序特征,将健康指标的局部特征和时序特征进行特征融合,通过卷积和全局平均池化层输出健康状态估计值。结果 本研究使用 MIT 数据集进行实验验证,并与卷积神经网络和长短时记忆神经网络进行对比分析,所提出的方法的均方根误差和平均绝对误差是最低的,为 0.11 和 0.08,最小相对误差为 0.61%。结论 所提出的 CNN-Transformer 健康状态估计采用不同模型挖掘健康指标不同的特征信息,能够充分利用锂离子电池放电数据,且具有良好的估计效果。

**关键词:**锂离子电池;健康状态;卷积神经网络;Transformer

中图分类号:TM912 文献标识码:A doi:10.16055/j.issn.1672-058X.2024.0002.009

### State of Health Estimation of Lithium-ion Battery Based on CNN-Transformer

CHEN Guolin, YAO Xingyan

School of Artificial Intelligence, Chongqing Technology and Business University, Chongqing 400067, China

**Abstract: Objective** The state of health is a key parameter to evaluate the state of lithium-ion batteries, and it is of great significance to the safe use of lithium-ion batteries. To obtain accurate and reliable health state estimation results, a health state estimation method for lithium-ion batteries based on convolutional neural networks and Transformer was developed. Using the data mining characteristics of different models, the deep information of health indicators and the time series information that increases with the cycle period were extracted in parallel. **Methods** Three health indicators with a strong correlation with health status were extracted from the partial voltage and temperature curves of the lithium-ion battery during the discharge process as model inputs. The powerful feature extraction capability of the convolutional neural network was used to mine the local features of health indicators, and the sequential processing capability of the Transformer was used to mine the time series features of health indicators. The local and time-series features of health indicators were fused with features, and the health status estimates were output by convolution and global average pooling

收稿日期:2022-12-27 修回日期:2023-02-16 文章编号:1672-058X(2024)02-0066-08

基金项目:重庆市自然科学基金面上项目(CSTC2020JCYJ-MSXMX0736);重庆市教委科学技术研究项目(KJQN201900808);重庆英才计划创新创业示范团队(CQYC201903246);重庆工商大学研究生教改(2022YJG0210);检测控制集成系统重庆市工程实验室开放基金(KFJJ2021018)。

作者简介:陈国麟(1997—),男,广东罗定人,硕士研究生,从事深度学习、锂离子电池健康状态估计研究。

通讯作者:姚行艳(1984—),女,湖北随州人,副教授,博士,从事智能结构与振动控制、故障预测与诊断研究。Email:yaoxingyan-jsj@163.com

引用格式:陈国麟,姚行艳.基于 CNN-Transformer 的锂离子电池健康状态估计[J].重庆工商大学学报(自然科学版),2024,41(2):66—73.

CHEN Guolin, YAO Xingyan. State of health estimation of lithium-ion battery based on CNN-transformer[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2024, 41(2): 66—73.

layers. **Results** In this study, experimental validation was performed using the MIT dataset, a comparative analysis was performed with convolutional neural network and long and short-term memory neural network, and the root mean square error and mean absolute error of the proposed method were the lowest, which were 0.11 and 0.08, and the minimum relative error was 0.61%. **Conclusion** The experimental results show that the proposed CNN-Transformer health state estimation uses different models to mine different feature information of health indicators, which can make full use of lithium-ion battery discharge data and has a good estimation effect.

**Keywords:** lithium-ion battery; state of health; convolutional neural network; Transformer

## 1 引言

随着能源危机和环境问题日益突出,锂离子电池因其具有高能量密度、长寿命周期和高安全性等优点作为清洁能源在各领域得到广泛的应用,例如电动汽车、储能设备和笔记本电脑等<sup>[1]</sup>。在使用过程中,由于锂离子电池内部发生化学反应,造成了锂离子电池的逐渐老化,且该过程具有不可逆性。同时,过充过放和不恰当的机械操作也会加剧电池老化<sup>[2]</sup>。锂离子电池健康状态(State of Health, SOH)是评价锂离子电池当前健康状况的重要参数,一般是无法通过测量仪器直接获得的,且 SOH 估计方法的精确度高有助于确保锂离子电池的安全运行<sup>[3]</sup>。SOH 目前尚无标准定义,在本研究中,锂离子电池的 SOH 采用当前最大可用容量与额定容量之比来定义,如式(1)所示,当前最大可用容量为  $C_r$ ,初始额定容量为  $C_o$ 。

$$y_{\text{SOH}} = \frac{C_r}{C_o} \quad (1)$$

目前,锂离子电池 SOH 估计方法主要有基于模型的方法<sup>[4]</sup>和基于数据驱动的方法<sup>[5]</sup>。基于模型的方法亦可分为基于电化学模型的方法和基于等效电路模型的方法,通过建立电化学模型或等效电路模型来分析电池 SOH 的变化,考虑了锂离子电池内部原理。其中,电化学模型的方法是建立模型来描述电池的化学和物理过程等效电路模型是根据锂离子电池的电特性,将电池看作电路模型。高仁璟等<sup>[6]</sup>考虑老化对电池正极化学计量比的影响,提出一种实验测量和遗传算法来确定电池伪二维模型参数的 SOH 估计方法;赵月荷等<sup>[7]</sup>以二阶 RC 等效电路模型为基础,利用卡尔曼滤波对荷电状态和内阻进行估计,然后利用电池内阻与 SOH 的关系进行实时估计;Yang 等<sup>[8]</sup>基于一阶等效电路模型推导恒压充电电流的时间常数表达式,通过建立容量和电流时间常数之间的关系来估计锂离子电池的 SOH。这种方法建模和计算过程较为复杂,且模型

中通常包含大量参数需要识别,因此很大程度上模型参数辨识的准确度决定了基于模型的 SOH 估计方法的准确度。此外,基于模型的方法是基于电池内部机理有针对性地建立电化学模型或等效电路模型,结构较为复杂且适应性较差。

基于数据驱动的方法通过从仪器测量的数据(如电流、电压和温度等)提取健康指标,利用数据驱动模型建立健康指标与 SOH 的关系实现 SOH 估计,而无须考虑锂离子电池的内部机理。近年,随着人工智能的应用在锂离子电池领域不断扩展,人工智能算法逐渐成为基于数据驱动的 SOH 估计的研究热点之一<sup>[9]</sup>。孙广明等<sup>[10]</sup>从充电过程的容量增量曲线提取三个电压区域峰的最大值以及面积作为表征电池老化的健康指标,利用 K 近邻算法实现 SOH 估计;韦荣阳等<sup>[11]</sup>基于时间规整图将电压曲线转换成相位差异曲线,并提取 4 个表征电池老化的健康指标,采用线性核函数的支持向量机实现 SOH 估计;魏中宝等<sup>[12]</sup>根据充电电压不同,提取不同的健康指标,使用神经网络算法估计锂离子电池的 SOH;郭琦沛等<sup>[13]</sup>分析增量容量曲线提取的健康指标与电池老化的变化规律确定 6 个健康指标来表征电池的健康状态,构建基于主成分回归的电池 SOH 估计模型。

此外,锂离子电池在整个老化过程中不同循环周期的数据构成时间序列数据,且当前循环周期的 SOH 与历史循环周期密切相关<sup>[14]</sup>。在时序处理方面具备强大优势的递归循环神经网络(Recurrent Neural Network, RNN)备受关注,RNN 保留历史信息,可以提高 SOH 估计精度。长短时记忆(Long Short-Term Memory, LSTM)神经网络是一种可以缓解 RNN 模型训练过程中的梯度消失或梯度爆炸的问题的变种 RNN<sup>[15]</sup>。许多研究人员通过充放电数据作为 LSTM 的输入,利用 LSTM 顺序传播的特点,挖掘充放电数据随循环周期的变化的深层时序特征信息实现 SOH 估计。吴起行

等<sup>[16]</sup>以锂离子电池放电过程的端电压、电流和温度作为 LSTM 的输入,利用 LSTM 提取电池 SOH 值随老化过程的变化特征,实现 SOH 估计;王义等<sup>[17]</sup>利用 SOH 的历史值作为模型的输入数据,使用加速自适应矩估计算法优化函数动态调整模型学习率,通过 BiLSTM 神经网络模型对电池数据分析,实现 SOH 估计;张朝龙等<sup>[18]</sup>从恒流恒压充电阶段的电压和温度数据提取电压熵和平均温度作为健康指标,利用 LSTM 提取健康指标与 SOH 之间的映射关系,建立锂电池 SOH 估计模型,并利用粒子群算法优化模型。

上面所述方法尽管从充放电数据提取健康指标,并选用性能优越的机器学习/深度学习模型可以提高 SOH 的估计准确率,但单一模型在挖掘健康指标的数据特征能力是有限的,还需要对所提取的健康指标数据挖掘更多元的特征信息,如健康指标随循环周期增加的变化趋势信息和健康指标局部关联信息等,进一步提高 SOH 估计精度。因此,如果能构建组合模型挖掘健康指标不同的深层数据特征,并进行特征融合以实现 SOH 估计,将有助于提高 SOH 估计的精确度。

针对上述问题,为进一步提高 SOH 估计精度,提出一种基于健康指标的卷积神经网络(Convolutional Neural Network, CNN)和 Transformer 组合的锂离子电池 SOH 估计方法。首先,从锂离子电池放电过程的部分电压和温度曲线中提取 3 个能反映 SOH 衰减的健康指标。然后,构建 CNN 和 Transformer 的分支网络,利用 CNN 提取健康指标的局部特征,得到特征向量  $H_1$ , Transformer 提取健康指标的时序特征,得到特征向量  $H_2$ , CNN 和 Transformer 是并行对健康指标进行特征提取。最后,将  $H_1$  和  $H_2$  进行特征融合,采用卷积和全局平均池化得到 SOH 估计值。

## 2 锂离子电池健康指标体系设计

### 2.1 锂离子电池数据集

使用 MIT 公开电池数据集<sup>[19]</sup>的 APR18650M1A 的单体锂离子电池(磷酸锂离子(LFP)/石墨)进行实验,该类电池的额定容量为 1.1 Ah,上截止电压为 3.6 V,下截止电压为 2 V。电池按照两步快速充电协议进行充电,该协议格式为“C1(Q1)-C2”,C1 和 C2 分别是第一和第二恒流步长,Q1 为电流切换时的荷电状态(State of Charge, SOC)。第二步电流在 SOC 达到 80% 结束,电池以 1C 进行恒流恒压充电。电池以 4C 恒流进行放电直至达到下截止电压。所有电池均在 30 °C 下进

行充放电测试,论文选取其中 4 个电池,编号为 B01、B02、B03 和 B04,如图 1 所示是电池容量衰减曲线。

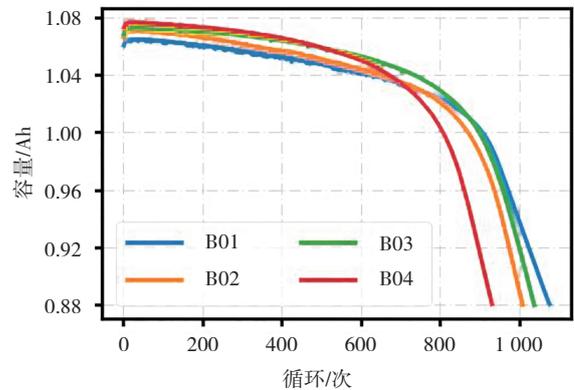


图 1 锂离子电池容量曲线

Fig. 1 Capacity curves of lithium-ion batteries

### 2.2 健康指标提取

在锂离子电池使用过程中,电压和温度是较为容易测量的参数,因此,本研究基于电池放电过程的电压和温度数据提取健康指标。

锂离子电池刚开始的放电时间是最长的,但经过多次充放电循环周期后,内部发生不可逆的电化学反应后,容量损失和内阻增大,后续满充后的放电时间会越来越短,最大可用容量也会逐渐减少<sup>[20]</sup>。如图 2 所示,随着循环周期的增加,电池恒流放电时的内阻增大导致电压下降的速度加快,当前循环周期的电压曲线会逐渐下移至上一次循环周期的电压曲线的下方。根据上述分析,等放电电压差的电压区间可以作为提取第一类健康指标的基础来衡量每次充放电循环的 SOH 衰减。

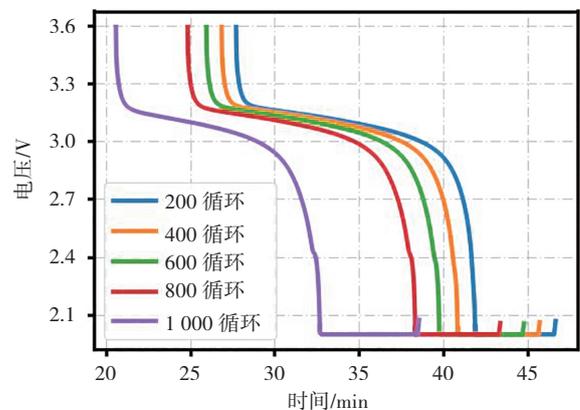


图 2 锂离子电池电压曲线

Fig. 2 Voltage curves of lithium-ion batteries

电池温度的变化主要是电化学反应或焦耳效应产生的内热导致的<sup>[21]</sup>。放电时会因内部的化学和物理反应,电池的温度会升高和下降。随着循环周期增加,内

阻增大,在相同的负载下,根据焦耳定理,温度会升高,最高温度也会逐渐增加。如图 3 所示,放电过程中温度逐渐升高,达到最高点后缓慢下降,直到放电完毕。在锂离子电池整个寿命的循环周期中,温度曲线变化趋势相似,但特定时间范围内的温度分布却存在明显差异。根据上述分析,温度区间也可以作为第二类健康指标来衡量每次充放电循环的 SOH 衰减。

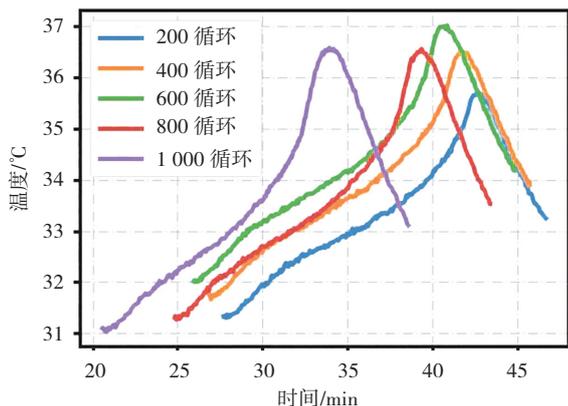


图 3 锂离子电池温度曲线

Fig. 3 Temperature curves of lithium-ion batteries

综上所述,在特定时间内,放电过程的电压和温度存在明显的变化。从预设的某个起始电压/温度达到某个电压/温度预设值的电压/温度区间可以作为健康指标来衡量锂离子电池 SOH 衰减。因此,本文基于放电电压和温度曲线的片段提取了 3 个健康指标作为 CNN-Transformer 模型的输入:

(1) 等放电电压差的时间( $F_1$ ):放电电压从 3.2 V 下降至 2.4 V 所需要的时间;

(2) 等放电电压差的电压与时间的积分( $F_2$ ):放电电压从 3.2 V 下降至 2.4 V 的电压曲线在时间上的积分;

(3) 等放电电压差的温度与时间的积分( $F_3$ ):放电电压从 3.2 V 下降至 2.4 V 的同等时间内放电温度曲线在时间上的积分。

### 3 SOH 估计与分析

#### 3.1 卷积神经网络

CNN 是常见的深度学习模型,通常用于处理图像数据<sup>[22]</sup>,它的局部感知和权值共享的优点可以使参数数量大大降低,提高模型学习效率。但锂离子电池数据是一维的时间序列数据,相比于传统的 CNN,一维 CNN 结构更简单,参数量更少,适用于一维时间序列数据的处理,主要由输入层、卷积层、池化层组成,如图 4

所示。

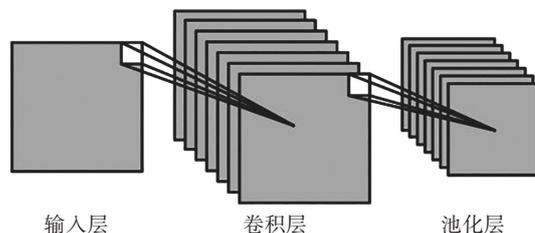


图 4 卷积神经网络结构

Fig. 4 Convolutional neural network structure

CNN 因其卷积层具有强大的局部特征提取能力,卷积层包含了多个卷积核,用于提取输入层数据的深层特征。健康指标输入数据与多个卷积核进行卷积运算,能获得深层更有用的特征信息,激活函数对卷积层的输出进行非线性变换,增强表达能力,如式(2)所示。其中, $h_i$  是通过第  $i$  层卷积提取的特征, $x_i$  是第  $i$  层卷积的输入数据, $\sigma$  是激活函数, $\otimes$  是卷积运算, $w_i$  和  $b_i$  是卷积核权重矩阵和偏置向量。经过卷积后,提取了输入数据的特征,但提取的特征是高维度的。因此,通常在卷积层间添加一个池化层,目的是对卷积层的输出进行特征降维,降低训练网络的成本,有效防止过拟合,一般有最大池化或平均池化,即计算某一区域内特征的平均值或最大值,本研究选用的是最大池化层。

$$h_i = \sigma(w_i \otimes x_i + b_i) \quad (2)$$

#### 3.2 Transformer

不同循环周期的健康指标和 SOH 构成了时间序列数据,捕捉健康指标的时序特征能提高 SOH 估计准确性。与 RNN 和 LSTM 不同,Transformer 是基于注意力机制实现并行处理输入序列,直接获取全局时序信息,是能够捕捉序列的时序特征的特征提取器<sup>[23]</sup>。

Transformer 的编码器主要如图 5(b) 所示,由输入层、位置编码和多头注意力机制、层归一化和前馈神经网络共同构成的编码层,同时加入残差连接。输入层是将输入数据映射为  $d$  维度的向量  $Z \in R^{n \times d}$ ,为后续的特征提取过程做准备。由于 Transformer 不具备 RNN 或 CNN 的顺序传播结构,位置编码是让 Transformer 具备识别序列间的顺序关系的能力。因此,需要将位置信息注入输入序列,使模型能够识别输入序列信息,利用序列的顺序关系。使用不同频率的正弦和余弦函数计算位置编码,如式(3)、式(4)所示。其中, $p$  代表的是位置, $i$  代表的是维度,这样在不同的时间步长中,模型可以学习到相对的位置关系。

$$P_{(p,2i)} = \sin(p/10\,000^{2i/d_{\text{model}}}) \quad (3)$$

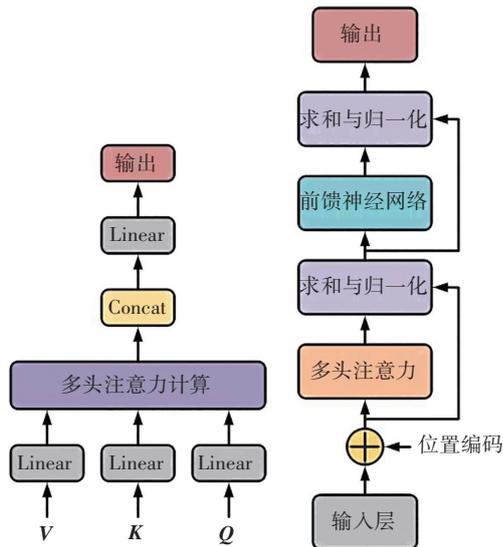
$$P_{(p,2i+1)} = \sin(p/10\,000^{2i/d_{\text{model}}}) \quad (4)$$

注意力机制是 Transformer 最大的亮点,如式(5)、式(6)所示。注意力机制是将具备位置编码的输入数据转换为 Query 矩阵  $Q$ , Key 矩阵  $K$ , Value 矩阵  $V$ , 计算  $Q$  和  $K$  的点积得到关联矩阵,为防止  $Q$  和  $K$  的点积结果较大,除以  $\sqrt{d_k}$ , Softmax 函数将其进行归一化处理,使其均为正数且和为 1,得到对应位置的注意力得分。Softmax 函数是将  $k$  维向量压缩到另一个  $k$  维向量,使得每个元素范围都在  $(0,1)$ ,且各元素和为 1,如式(7)所示,  $x_i$  是第  $i$  维向量。输入注意力得分乘以  $V$  得到自注意力的输出。多头注意力机制让每个注意力机制挖掘序列不同特征部分,让时序特征拥有来自更多元的表达,如图 5(a)所示。通过多次对 Query、Key 和 Value 进行线性变换,将不同的自注意力输出进行拼接,并进行线性变换,得到 Transformer 的多头注意力的输出。与顺序传播的 LSTM 和 RNN 不同,Transformer 没有严格的方向性,其直接计算输入序列,注意力机制使模型能够同时学习当前时间周围的时序信息。

$$Q = ZW^Q, K = ZW^K, V = ZW^V \quad (5)$$

$$O_{Att}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (6)$$

$$\text{Softmax}(x_i) = \frac{\exp(x_i)}{\sum_k \exp(x_k)} \quad (7)$$



(a) 多头注意力机制 (b) Transformer 编码器

图 5 Transformer 结构

Fig. 5 Transformer structure

### 3.3 基于 CNN-Transformer 的 SOH 估计

基于 CNN-Transformer 的锂离子电池 SOH 估计方法流程如图 6 所示,步骤如下:

(1) 获取电池放电电压和温度曲线,并进行数据

处理,提取等放电压差的时间 ( $F_1$ )、等放电压差的时间积分 ( $F_2$ ) 和等放电压差的温度积分 ( $F_3$ ) 作为反映 SOH 衰减的健康指标。

(2) 为了充分发挥不同模型的优势,利用 CNN 和 Transformer 并行处理健康指标数据。因此,将健康指标数据分别作为 CNN 和 Transformer 的输入,两者并行运行,CNN 经过卷积层提取健康指标的局部特征,池化层对其进行下采样数据降维,得到局部特征向量  $H_1$ , Transformer 经过输入层的卷积核大小为  $1 \times 1$  的卷积将数据升维,并与位置编码层的位置注入信息进行相加,得到具备位置信息的健康指标序列。利用多头注意力机制学习到健康指标随循环周期增加的下降趋势,得到时序特征向量  $H_2$ 。

(3) CNN 和 Transformer 的输出分别经过不同的线性变换层,加强特征表达,并拼接  $H_1$  和  $H_2$  得到融合向量,利用大小为  $1 \times 1$  的卷积对其非线性处理,为解决全连接层的参数量大的问题,在卷积层后面采用全局平均池化层得到 SOH 估计值。

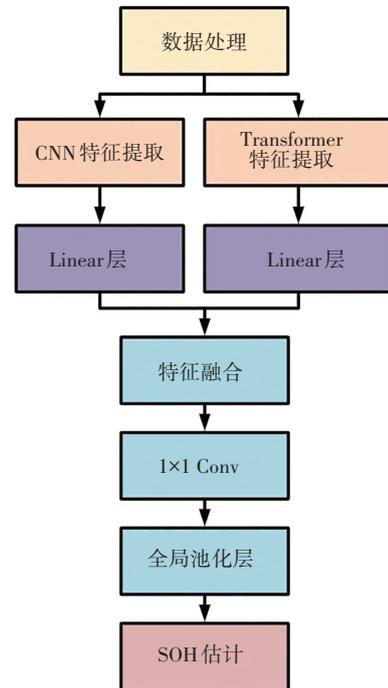


图 6 SOH 估计整体流程框架

Fig. 6 Overall process framework of SOH estimation

## 4 实例验证与分析

### 4.1 实验设置

采用 MIT 公开锂离子电池数据集验证 CNN 和 Transformer 组合的 SOH 估计方法的有效性。通过均方根误差 (Root Mean Square Error, RMSE) 和平均绝对误差 (Mean Absolute Error, MAE) 和相对误差 (Relative

Error RE)对 SOH 估计结果进行评估,计算方法如式(8)一式(10)所示,其中, $\hat{y}_i$  是估计值, $y_i$  是真实值。

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=0}^n (\hat{y}_i - y_i)^2} \times 100\% \quad (8)$$

$$e_{MAE} = \frac{1}{n} \sum_{i=0}^n |\hat{y}_i - y_i| \times 100\% \quad (9)$$

$$e_{RE} = \frac{|\hat{y}_i - y_i|}{|y_i|} \times 100\% \quad (10)$$

选用 Python 作为数据分析工具,深度学习框架 Pytorch 搭建基于 CNN-Transformer 的锂离子电池 SOH 估计模型。在训练过程中,学习率为 0.001,损失函数采用 HuberLoss。Adam 是用来训练深度学习模型的常见优化器,详细的超参数如表 1 所示。

表 1 超参数设置

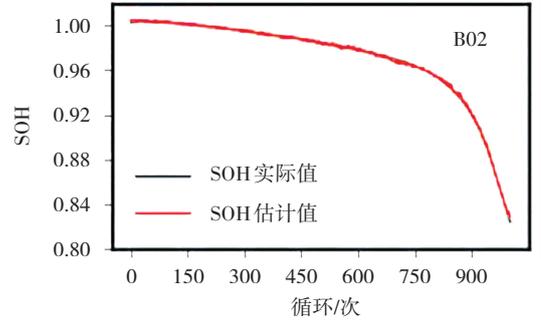
Table 1 Settings of hyperparameters

超参数	设置
输入步长	8
学习率	0.001
损失函数	HuberLoss
批大小	300
优化器	Adam
CNN 特征提取	卷积层:卷积核大小为 3,个数为 64
	激活函数:ReLU
	池化层:池化核大小为 3
Transformer 特征提取	线性层:节点数 64,激活函数 ReLU
	输入层:节点数 64,激活函数为 ReLU
	编码层:层数 2,自注意力头数为 4
输出	线性层:节点数 64,激活函数 ReLU
	1×1 Conv:卷积核大小为 1,卷积核个数 32
	全局池化层:池化核大小为 8
	输出:节点数 1

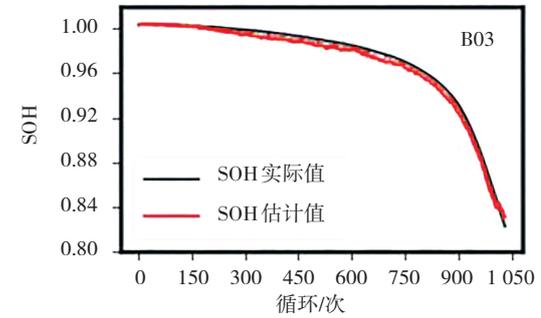
### 4.2 实例分析

利用 B01 号电池的数据进行模型离线训练,B02、B03 和 B04 号电池进行测试验证。CNN-Transformer 模型的输入是 3 个健康指标,输出是 SOH。图 7 是 SOH 估计结果图。表 2 是模型评价指标 RMSE、MAE 和最大相对误差(MaxRE)。图 7 展示了 3 个测试电池的 SOH 估计结果,真实数据和估计数据展现较小误差,估计数据曲线均符合真实数据曲线的下降趋势,说明所提方法能够在 SOH 估计方面取得较为理想的结果。表 2 显示了较低的 RMSE 和 MAE,最低为 0.11(RMSE)和 0.08(MAE),最高仅为 0.49(RMSE)和 0.43(MAE)。在所有测试电池中,最大的相对误差为 2.66%,最小仅为 0.61%,所提方法在

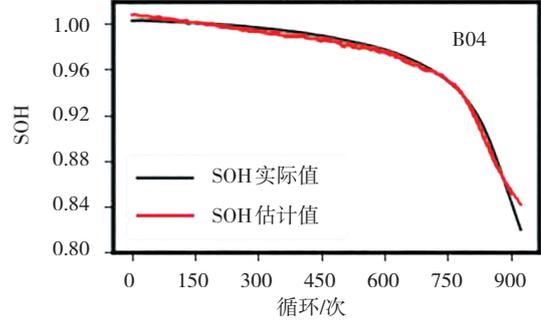
SOH 低于 80%前,3 个测试电池均保证相对误差最高不超过 3%。实验结果证明,CNN-Transformer 的 SOH 估计方法是有效的,且估计效果较好。



(a) B02 号电池测试验证图



(b) B03 号电池测试验证图



(c) B04 号电池测试验证图

图 7 SOH 估计结果图

Fig. 7 Pictures of SOH estimation results

表 2 所提出方法的估计误差

Table 2 Estimation errors of the proposed method

电池编号	方法		
	MAE	RMSE	MaxRE
B02	0.08	0.11	0.61
B03	0.43	0.49	1.22
B04	0.35	0.45	2.66

对所提出的 CNN-Transformer 网络结构分别去掉 CNN(记作 Transformer\*)和 Transformer(记作 CNN\*)组件,其余不变,进行对比实验。3 个健康指标作为模型输入,表 3 是估计误差。由表 3 可知,CNN\*最低误差是 0.18(MAE)和 0.23(RMSE),Transformer\*的最低误差是 0.09(MAE)和 13(RMSE),而 CNN-Transformer

的最低误差是 0.08(MAE)和 0.11(RMSE)。在所有测试电池的 SOH 结果, CNN\* 和 Transformer\* 的误差均比 CNN-Transformer 的高, 证明 CNN 和 Transformer 组件对于 CNN-Transformer 网络结构都是有用的。虽然只有 CNN 提取的局部特征或 Transformer 提取的时序特征, 模型的也能取得不错的 SOH 估计结果, 但是两类深层特征融合的 SOH 估计误差更低。

表 3 去掉不同组件后的估计误差

Table 3 Estimation errors after removing different components

方法	模型	电池编号		
		B02	B03	B04
MAE	CNN*	0.18	0.56	0.40
	Transformer*	0.09	0.43	0.42
	CNN-Transformer	0.08	0.43	0.35
RMSE	CNN*	0.23	0.66	0.49
	Transformer*	0.13	0.56	0.60
	CNN-Transformer	0.11	0.49	0.45
MaxRE	CNN*	0.92	2.03	1.60
	Transformer*	0.57	1.81	2.03
	CNN-Transformer	0.61	1.22	2.66

将所提出方法与 CNN 和 LSTM 进行对比分析, 3 个健康指标作为模型输入, 表 4 是各模型的估计误差。由表 4 可知, LSTM 最低误差是 0.08(MAE)和 0.13(RMSE), CNN 的最低误差是 0.23(MAE)和 0.42(RMSE)。CNN 的最低 MAE 和 RMSE 比 CNN-Transformer 分别高 0.15 和 0.31, 而 LSTM 的最低 MAE 和 CNN-Transformer 是一样的, RMSE 比 CNN-Transformer 高 0.02, CNN 的最大误差在 B03 和 B04 表现最好。虽然 CNN-Transformer 的最大相对误差在部分测试电池比 CNN 的表现差, 但整体 SOH 估计的 RMSE 和 MAE, CNN-Transformer 是最低的。

表 4 对比实验的估计误差

Table 4 Estimation errors of comparative experiments

方法	模型	电池编号		
		B02	B03	B04
MAE	LSTM	0.08	0.54	0.46
	CNN	0.23	0.52	0.37
	CNN-Transformer	0.08	0.43	0.35
RMSE	LSTM	0.13	0.68	0.61
	CNN	0.42	0.58	0.47
	CNN-Transformer	0.11	0.49	0.45
MaxRE	LSTM	1.16	1.89	2.10
	CNN	2.06	1.06	1.71
	CNN-Transformer	0.61	1.22	2.66

### 4.3 实验结论

与去掉 CNN 和 Transformer 组件的对比实验分析, 结果表明 CNN-Transformer 的特征融合组件融合局部特征和时序特征对 SOH 估计是有提升的。与 CNN 和 LSTM 的对比实验分析, CNN 的局部特征提取能力和 LSTM 的时序特征提取的能力, 两者均获得了较好的 SOH 估计效果。但 CNN-Transformer 结合了 CNN 的局部特征提取和 Transformer 的时序特征提取, 并将局部特征和时序特征进行特征融合。结果表明, CNN-Transformer 在挖掘健康指标数据深层信息的能力均比 CNN 和 LSTM 的能力强。同时, 挖掘健康指标的多元深层特征是有助于提高 SOH 估计精度的。

### 5 结束语

本文从部分放电电压和温度数据中提取动态变化的 3 个健康指标用于模型输入, 基于 CNN 和 Transformer 进行多模型特征融合的 SOH 估计。在所有测试电池的 SOH 估计结果, CNN-Transformer 的 RMSE 和 MAE 均优于 CNN 和 LSTM。由此说明, 所提出的基于 CNN 和 Transformer 组合的锂离子电池 SOH 估计方法是有效的, 充分利用不同模型的特征提取能力, 提高了 SOH 估计的准确度。

### 参考文献(References):

- [1] GUO P, CHENG Z, YANG L. A data-driven remaining capacity estimation approach for lithium-ion batteries based on charging health feature extraction[J]. Journal of Power Sources, 2019(412): 442—450.
- [2] SHU X, LI G, SHEN J, et al. A uniform estimation framework for state of health of lithium-ion batteries considering feature extraction and parameters optimization[J]. Energy, 2020(204): 117957.
- [3] LIPU M S H, HANNAN M A, HUSSAIN A, et al. A review of state of health and remaining useful life estimation methods for lithiumion battery in electric vehicles: Challenges and recommendations [J]. Journal of Cleaner Production, 2018(205): 115—133.
- [4] XIONG R, LI L, TIAN J. Towards a smarter battery management system: A critical review on battery state of health monitoring methods[J]. Journal of Power Sources, 2018(405): 18—29.
- [5] YAO L, XU S, TANG A, et al. A review of lithiumion battery state of health estimation and prediction methods[J]. World Electric Vehicle Journal, 2021, 12(3): 113.
- [6] 高仁璟, 吕治强, 赵帅, 等. 基于电化学模型的锂离子电池健康状态估算[J]. 北京理工大学学报, 2022, 42(8): 791—

- 797.
- GAO Ren-jing, LU Zhi-qiang, ZHAO Shuai, et al. Health state estimation of li-ion batteries based on electrochemical model[J]. Transactions of Beijing Institute of Technology, 2022, 42(8): 791—797.
- [7] 赵月荷, 庞宗强. 基于无迹卡尔曼滤波的动力电池健康状态估计[J]. 国外电子测量技术, 2022, 41(10): 136—141.
- ZHAO Yue-he, PANG Zong-qiang. State of health estimation of power batteries based on unscented Kalman filter[J]. Foreign Electronic Measurement Technology, 2022, 41(10): 136—141.
- [8] YANG J, XIA B, HUANG W, et al. Online state-of-health estimation for lithium-ion batteries using constant-voltage charging current analysis[J]. Applied Energy, 2018(212): 1589—1600.
- [9] TAN Y, ZHAO G. Transfer learning with long short-term memory network for state-of-health prediction of lithium-ion batteries [J]. IEEE Transactions on Industrial Electronics, 2019, 67(10): 8723—8731.
- [10] 孙广明, 贾新羽, 陈良亮. 基于 K 近邻回归的锂离子电池健康状态估计[J]. 电源技术, 2022, 46(8): 872—875.
- SUN Guang-ming, JIA Xin-yu, CHEN Liang-liang. State of health estimation of lithium-ion battery based on K nearest neighbour regression and IC curve[J]. Chinese Journal of Power Sources, 2022, 46(8): 872—875.
- [11] 韦荣阳, 毛阆, 高晗, 等. 基于 TWP-SVR 的锂离子电池健康状态估计[J]. 储能科学与技术, 2022, 11(8): 2585—2599.
- WEI Rong-yang, MAO Tian, GAO Han, et al. Health state estimation of lithium ion battery based on TWP-SVR [J]. Energy Storage Science and Technology, 2022, 11(8): 2585—2599.
- [12] 魏中宝, 阮浩凯, 何洪文. 基于充电数据的多阶段锂离子电池健康状态估计[J]. 北京理工大学学报, 2022, 42(11): 1184—1190.
- WEI Zhong-bao, RUAN Hao-kai, HE Hong-wen. Multi-stage state of health estimation based on charging phase for lithium-ion battery[J]. Transactions of Beijing Institute of Technology, 2022, 42(11): 1184—1190.
- [13] 郭琦沛, 张彩萍, 高洋, 等. 基于容量增量曲线的三元锂离子电池健康状态估计方法[J]. 全球能源互联网, 2018, 1(2): 180—187.
- GUO Qi-pei, ZHANG Cai-ping, GAO Yan, et al. Incremental capacity curve based state of health estimation for lnmco lithium-ion batteries [J]. Journal of Global Energy Interconnection, 2018, 1(2): 180—187.
- [14] DENG Z, LIN X, CAI J, et al. Battery health estimation with degradation pattern recognition and transfer learning [J]. Journal of Power Sources, 2022(525): 231027.
- [15] YU Y, SI X, HU C, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. Neural Computation, 2019, 31(7): 1235—1270.
- [16] 吴起行. 基于改进型 LSTM-RNN 的锂离子电池 SOH 估计系统[J]. 电子制作, 2021(9): 72—74.
- WU Qi-xing. Improved LSTM-RNN based SOH estimation system for lithium-ion batteries[J]. Practical Electronic, 2021(9): 72—74.
- [17] 王义, 刘欣, 高德欣. 基于 BiLSTM 神经网络的锂电池 SOH 估计与 RUL 预测[J]. 电子测量技术, 2021, 44(20): 1—5.
- WANG Yi, LIU Xin, GAO De-xin. The SOH estimation and RUL prediction of lithium battery based on BiLSTM [J]. Electronic Measurement Technology, 2021, 44(20): 1—5.
- [18] 张朝龙, 赵筛筛, 何怡刚. 基于信息熵与 PSO-LSTM 的锂电池组健康状态估计方法[J]. 机械工程学报, 2022, 58(10): 180—190.
- ZHANG Chao-long, ZHAO Shai-shai, HE Yi-gang. State-of-health estimate for lithium-ion battery using information entropy and PSO-LSTM[J]. Journal of Mechanical Engineering, 2022, 58(10): 180—190.
- [19] SEVERSON K A, ATTIA P M, JIN N, et al. Data-driven prediction of battery cycle life before capacity degradation[J]. Nature Energy, 2019, 4(5): 383—391.
- [20] DENG Y, YING H, JIAQIANG E, et al. Feature parameter extraction and intelligent estimation of the state-of-health of lithium-ion batteries[J]. Energy, 2019, 176: 91—102.
- [21] ZHOU Y, HUANG M, CHEN Y, et al. A novel health indicator for on-line lithium-ion batteries remaining useful life prediction[J]. Journal of Power Sources, 2016, 321: 1—10.
- [22] 殷浩然, 苗世洪, 韩估, 等. 基于三维卷积神经网络的配电网物联网异常辨识方法[J]. 电力系统自动化, 2022, 46(1): 42—50.
- YIN Hao-ran, MIAO Shi-hong, HAN Ji, et al. Anomaly identification method for distribution internet of things based on three-dimensional convolutional neural network[J]. Automation of Electric Power Systems, 2022, 46(1): 42—50.
- [23] GU X, SEE K W, LI P, et al. A Novel State-of-health estimation for the lithium-ion battery using a convolutional neural network and transformer model [J]. Energy, 2023(262): 1—10.