

DOI:10.19651/j.cnki.emt.2313745

# 基于 TCN-BiGRU 的锂离子电池健康状态评估

刘少卿<sup>1</sup> 李帅<sup>2</sup> 苗建国<sup>1,3</sup> 苗强<sup>1</sup>

(1. 四川大学电气工程学院 成都 610065; 2. 四川公路桥梁建设集团有限公司勘察设计分公司 成都 610041;

3. 重庆邮电大学自动化学院 重庆 400065)

**摘要:** 准确估算锂离子电池的健康状态可以有效保障锂离子电池的安全使用,但现有锂离子电池 SOH 评估方法存在评估精度不理想等问题。为此,本文提出了一种基于 TCN 和 BiGRU 相结合的电池 SOH 评估方法。首先,从电池充电数据中提取构建健康因子,并验证其与电池容量之间的相关关系;然后,利用 TCN 模型处理长序列依赖数据并开展特征提取,同时在该模型中添加 Dropout 层以防止过拟合,提升了模型的泛化性;最后,通过 BiGRU 模型进行历史数据特征建模并对数据退化趋势进行估计,最终实现对锂离子电池 SOH 的精确评估。利用实验室搭建的电池退化试验台获取的四组电池退化数据进行方法验证,结果表明所提模型所估计的 SOH 在决定系数、绝对平均误差以及均方根误差 3 个指标上的均值分别为 0.990 4、0.017 1、0.022 3,明显优于其他对比方法。

**关键词:** 锂离子电池;健康状态估计;TCN;BiGRU

**中图分类号:** TM912      **文献标识码:** A      **国家标准学科分类代码:** 530.4130

## Lithium-ion battery state of health estimation based on TCN-BiGRU

Liu Shaoqing<sup>1</sup> Li Shuai<sup>2</sup> Miao Jianguo<sup>1,3</sup> Miao Qiang<sup>1</sup>

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, China; 2. Survey and Design Company of Sichuan Road &amp; Bridge(Group) Co. Ltd, Chengdu 610041, China; 3. College of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract:** Accurate estimation of the state of health (SOH) of lithium-ion batteries is the critical to ensure the safety of lithium-ion batteries. However, the existing methods for SOH estimation of lithium-ion batteries exist unsatisfactory evaluation accuracy. To solve this problem, this paper proposes a battery SOH estimation method based on the combination of temporal convolutional network (TCN) and bidirectional gated recurrent unit (BiGRU). Firstly, the health factor is extracted from the battery charging data and its correlation with the battery capacity is discussed. Then, the TCN model is used to process the long series dependent data and carry out feature extraction, and also a Dropout layer is added to the model to prevent overfitting and improve the generalization. Finally, the BiGRU model is used to model the historical data features and predict the data degradation trend. In addition, the BiGRU model is used to model the historical data characteristics and estimate the data degradation trend to achieve an accurate assessment of the SOH of lithium-ion batteries. The results show that the proposed method obtains the better average of coefficient of determination (0.990 4), absolute mean error (0.017 1), and root mean square error (0.022 3) than other comparative methods under four batteries.

**Keywords:** li-ion batteries; state of health estimation; TCN; BiGRU

## 0 引言

锂离子电池作为一种高能蓄电池,具有输出电压高、循环寿命长、能量密度大、自放电率低、工作温度范围广等优点<sup>[1]</sup>,现已广泛应用于便携式电子设备、电动汽车和无人机等领域。锂离子电池在使用过程中的安全性和可靠性非常

重要,而健康状态(state of health, SOH)从本质上反映了锂离子电池的老化程度和损坏情况,故如何有效估计锂离子电池的 SOH,并依据评估结果在电池出现故障或失效行为前采取运维措施具有重要意义<sup>[2]</sup>。

目前,国内外学者对电池 SOH 评估的研究大致分为两个方向:一是根据机理进行建模评估的模型驱动方

收稿日期:2023-05-26

法<sup>[3-6]</sup>;二是根据测量数据进行评估的数据驱动方法<sup>[7-18]</sup>。模型驱动方法主要包括建立电化学模型和等效电路模型。其中,电化学模型<sup>[3-4]</sup>主要是通过研究电池内部的电化学反应来计算准确的 SOH,然而电化学模型的 SOH 建模较为复杂。等效电路模型<sup>[5-6]</sup>通过电子元器件组成的电路系统达到模拟电池特性的效果,该方法虽降低了建模难度,但由于等效电路的本质是近似处理,故任何参数的偏差都可能导致最终的 SOH 计算值存在较大的误差。总的来说,模型驱动方法现存的问题是没有合适的模型可以准确模拟锂离子电池的所有老化行为<sup>[19]</sup>。数据驱动方法则不需要掌握电池退化机理等相关领域内知识,可根据历史监测数据去估计未来电池的退化趋势,从而得到了广泛的研究。用于电池 SOH 评估的数据驱动方法包括高斯过程、支持向量机等机器学习方法<sup>[7-8]</sup>。郑雪莹等<sup>[7]</sup>提出了一种能量加权高斯过程回归方法对电池 SOH 进行估计。刘微等<sup>[8]</sup>在对电池进行特性分析和特征选择的基础上,利用支持向量机算法模型对电池进行了 SOH 预测。

随着深度学习的发展,一系列深度学习算法在各个领域得到了广泛应用。循环神经网络(recurrent neural network, RNN)、长短期记忆网络(long short-term memory, LSTM)以及门循环单元(gate recurrent unit, GRU)凭借其在时间序列数据预测方面的优势,已经在电池 SOH 预测中得到了越来越多的关注。Eddahech 等<sup>[9]</sup>在工作中利用 RNN 模型实现了对高功率密度锂离子电池 SOH 的监测评估。传统的 RNN 由于在训练阶段存在梯度消失和爆炸的问题,因此在实际应用中很难处理时间序列的长期依赖问题,而作为 RNN 变体的 LSTM 和 GRU 则可以解决这个问题。刘伟霞等<sup>[10]</sup>则结合了 LSTM 神经网络和安时法来映射健康指标和 SOH 之间的关系,进而对电池 SOH 进行了预测建模。Cui 等<sup>[11]</sup>提出了一种基于动态时空注意力的 GRU 模型,该模型结合了空间注意力和时间注意力对电池 SOH 开展评估建模。但是, LSTM 和 GRU 模型的输出只考虑了当前时刻的历史信息,且随着时间序列长度的增加,预测精度会相应下降。王凡等<sup>[12]</sup>对上述不足进行了改进,提出了一种基于注意力改进的双向循环门控单元(bidirectional gated recurrent unit, BiGRU)的锂离子电池 SOH 估计方法,进而实现了较高精度的 SOH 估计。相比 LSTM 和 GRU, BiGRU 不仅能够从历史时刻信息中学习,更重要的是能够从未来时刻信息中学习当前时刻数据<sup>[13]</sup>。卷积神经网络(convolutional neural network, CNN)作为出色的深度学习算法,同样被广泛应用于电池 SOH 估计,并取得了准确度较高的结果。李超然等<sup>[14]</sup>将锂离子电池充电过程中的电压、电流和温度曲线作为 CNN 模型的输入,实现了锂离子电池容量的估算。时序卷积网络(temporal convolutional network, TCN)作为 CNN 模型的变体在 2018 年被提出,该模型已被证明在自然语音处理和音频合成等许多时序问题上达到了最先进

的水平,与 LSTM、GRU 等标准循环神经网络相比, TCN 具有更简单的结构和更准确的输出结果。Zhou 等<sup>[15]</sup>建立 TCN 模型提高了电池的整体预测精度。张孝远等<sup>[16]</sup>也进一步提出了一种基于改进 TCN 的评估方法,进一步提升了电池 SOH 评估的精度以及训练速度。然而仅使用单一的网络模型进行电池 SOH 评估往往会导致如易收敛至局部最优、计算时间长等问题,在很大程度上限制了其在电池 SOH 估计方面的应用<sup>[20]</sup>。戴彦文等<sup>[17]</sup>通过 CNN-LSTM 模型对输入的健康特征进行了深度挖掘,并与 GRU 联合实现了更准确锂电池 SOH 估计。朱振宇等<sup>[18]</sup>提出一种基于 CNN-BiLSTM 网络的锂电池健康状态检测方法对电池容量进行预测,实现锂离子电池健康状态检测,预测结果优于单一神经网络模型,预测拟合度和准确性更高。将多种神经网络模型进行有效组合能够在一定程度上克服单一模型难于实现更高的估计精度的问题。

TCN 模型很大程度上缓解了梯度消失或梯度爆炸的影响,能够更好地捕捉长期的时序关系,而 BiGRU 模型能够同时利用过去和未来的上下文信息,能够更全面地理解时序数据的模式和趋势。因此本文的策略是利用两种网络的优势将其进行融合,提出了一种基于 TCN-BiGRU 的电池 SOH 估计方法。首先,使用 TCN 对电池时序数据进行特征提取, TCN 能够捕捉不同时间尺度的特征和更长期的时序依赖关系,这有助于更好地捕捉时序数据的结构和模式。接着,将提取的特征输入到 BiGRU 中进行 SOH 的估计,该模型能够充分利用当前时刻完整的过去和未来时间信息,从而全面地理解时序数据的模式和趋势。为了防止过拟合,本方法在 TCN 模块与 BiGRU 模块之间加入了 Dropout 层,它可以随机地将部分神经元的输出置 0,减少神经网络的复杂性,并提高模型的泛化能力。最后,通过实验证明了所提方法能够有效地提取特征并进行高精度的 SOH 评估,同时保证了模型的鲁棒性和泛化能力。

## 1 理论基础

### 1.1 时序卷积神经网络

TCN 模型在一维因果卷积的基础上加入了膨胀卷积和残差连接,利用卷积并行处理数据,从而跨时间步提取特征,其完整结构如图 1 所示。因果膨胀卷积是由因果卷积和膨胀卷积组成的,结构如图 2 所示。其中因果卷积是由一维卷积组成的,其输出是由上一层中此时的输入和更早时刻的输入联合得到的,是一种严格的时间约束模型,适用于时序数据潜在特征的挖掘。膨胀卷积最初是为了解决图像领域在采样过程中的信息丢失问题而提出的,与传统的卷积层只关注局部邻域的特点不同,膨胀卷积可以在更大的感受野内获取信息,从而更好地捕捉序列中的长期依赖关系。其表达式如下:

$$F(i) = \sum_{k=1}^K f(i + d \cdot k) \cdot h(k) \quad (1)$$

其中,  $i$  是序列中的第  $i$  个元素,  $k$  是过滤器的大小,  $f(i)$  是输入序列,  $F(i)$  是输出序列,  $h(k)$  是长度为  $k$  的过滤器,  $d$  为扩张因子。




图 1 时序卷积神经网络基本结构




图 2 因果膨胀卷积

跳跃连接是深度学习一种常用的技术,它可以提高模型的运行速度,保证网络性能不退化。例如模型的输入为  $x$ ,  $F(x)$  是  $x$  经过一层线性变换和激活函数之后的输出,经过第 2 层线性变换后,将  $F(x)$  加到上一层的输入  $x$  中,然后被重新激活输出为  $o$ ,如式 (2):

$$o = \text{Activation}(x + F(x)) \quad (2)$$

在 TCN 网络中,膨胀卷积、因果卷积以及跳跃连接加上激活函数和 Dropout 模块构成了一个残差块。在网络结构加深时,为避免梯度消失等问题的发生,TCN 利用残差块来代替卷积层,在网络内部跨层传递信息,具有更强的泛化能力。

### 1.2 双向门控循环网络

GRU 属于 LSTM 的一种变体,它能够更好地捕捉时间序列中时间步距较大的依赖关系,有力解决了反向传播中的长期记忆和梯度等问题。传统的 LSTM 通过 3 个门结构—输入门、遗忘门、输出门来控制网络的输出,而 GRU 只有更新门和重置门两个门,典型的 GRU 单元如图 3 右侧所示。其中,  $x_t$  为  $t$  时刻的输入,  $r_t$  为  $t$  时刻的重置门,  $z_t$  为  $t$  时刻的更新门,  $\tilde{h}_t$  为  $t$  时刻的候选隐藏状态,  $h_t$  为  $t$  时刻的隐藏状态,  $h_{t-1}$  为前一时刻的隐藏状态

GRU 是沿单一方向传输信息的,它获取的信息仅仅是当前时间之前的历史信息,这就导致了对未来信息的忽略,从而造成丢失重要信息的后果。为了充分利用输入序列中历史信息和未来信息进而提出了 BiGRU 网络,其结构如图 3 所示。BiGRU 由一个前向 GRU 隐藏层和一个后向 GRU 隐藏层组成,具有捕获先前和未来信息特征的功能,充分利用序列信息,便于特征提取。这两个隐藏层都与输出层相连接,分别在时间维度上对输入序列进行前向和

向计算,从而得到两个不同的隐层状态,然后将两个向量相加得到最终的输出,同时将每个时间步的输出也连接到最终的输出层,计算公式如式(3)~(5):

$$\vec{H}_t = \text{GRU}(X_t, \vec{H}_{t-1}) \quad (3)$$

$$\overleftarrow{H}_t = \text{GRU}(X_t, \overleftarrow{H}_{t-1}) \quad (4)$$

$$H_t = \alpha_t \vec{H}_t + \beta_t \overleftarrow{H}_t + b_t \quad (5)$$

其中,  $H_t$  表示隐藏层在时间  $t$  的状态,  $X_t$  表示时间  $t$

的输入,  $\vec{H}_t$  和  $\overleftarrow{H}_t$  分别表示隐藏层在时间  $t$  前向和反向传播时的输出,  $\alpha_t$  和  $\beta_t$  分别表示隐藏层在前向和反向传播时的输出权重,  $b_t$  是隐藏层在时间  $t$  的偏置时间。




图 3 双向门控循环网络结构

## 2 基于 TCN-BiGRU 的电池 SOH 评估方法

由于 TCN 模型和 BiGRU 模型都可以从时间序列信息中提取特征并挖掘相关性,已被大量用于时间序列检测任务。为了充分发挥这两种网络的优势,本文设计了一种基于 TCN-BiGRU 的电池 SOH 的评估方法,充分利用了 TCN 的局部特征提取和捕捉时序数据中较远距离的依赖关系的能力和 BiGRU 的全局上下文理解能力和双向信息流,从而更全面地捕捉时序数据中的相关信息的同时更好地建模时序数据中的长期依赖关系,进而达到提高预测精度的目的。整体流程如图 4 所示,其包含健康因子选取、评估模型构建及 SOH 评估 3 个部分。

SOH 评估模型由输入层、TCN 模块、Dropout 层、BiGRU 模块和全连接层组成,模型具体配置如表 1 所示。第 1 阶段,原始序列在经过一定的特征提取并选取与容量之间相关系数绝对值最大且均大于 0.85 的特征作为健康因子进行模型训练。在第 2 阶段,在 TCN 模块中执行特征提取,得到一系列特征表示,本文中 TCN 模块由 4 个如表 1 中的残差块组成。在第 3 阶段,将经过 Dropout 层随机舍弃一部分神经元之后的输出作为 BiGRU 网络的输入,用于提取时间序列中的长期相关性以及未来信息与当前信息之间的相关性,最后通过全连接层输出 SOH 的估计值。

## 3 数据集及实验设计

### 3.1 数据集介绍

本文采用实验室搭建的锂离子电池退化试验台的电池



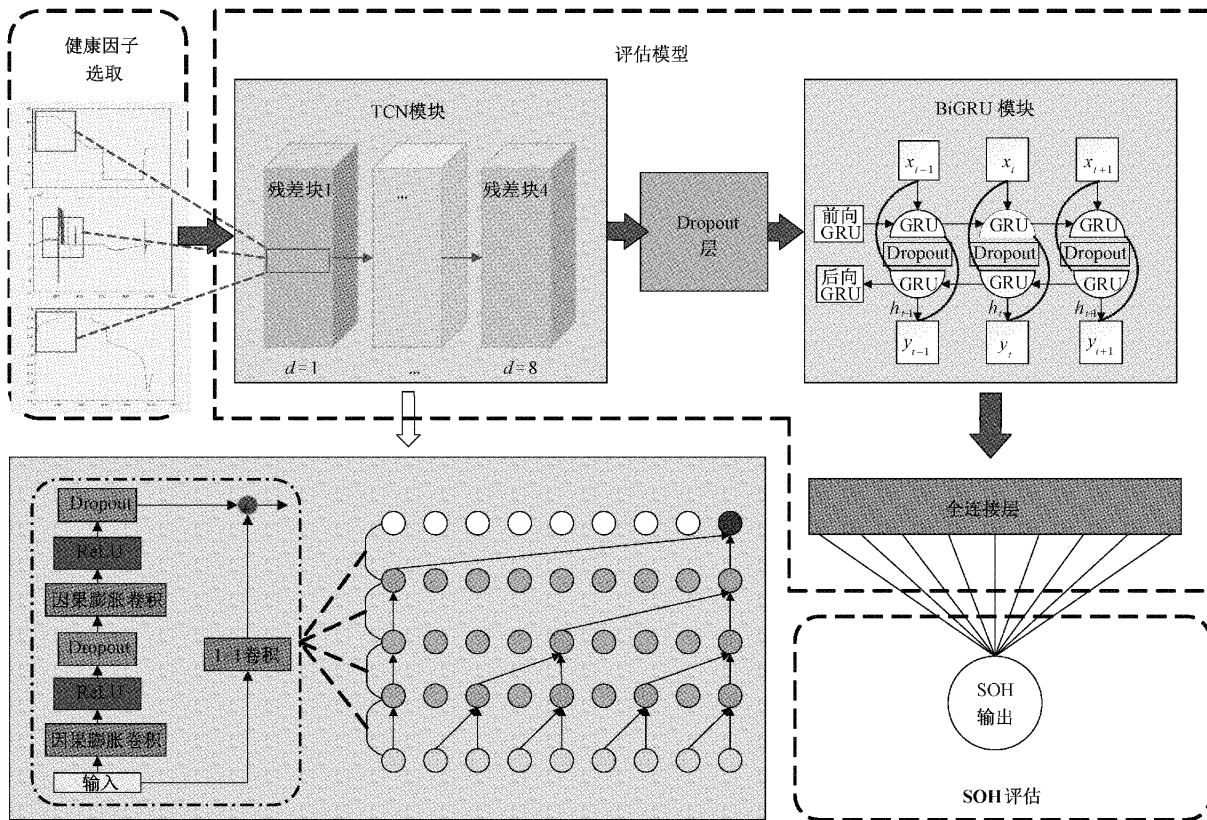


图 4 基于 TCN-BiGRU 的 SOH 评估方法流程

表 1 模型配置

模块名称	层名称	参数
TCN 残差块	一维卷积层	卷积核数量:128 卷积核大小:5
	一维卷积层	卷积核数量:128 卷积核大小:5 扩张因子:[1,2,4,8]
	一维卷积层	卷积核数量:128 卷积核大小:5
	Dropout 层	灭活比例:0.1
	双向 GRU 层	单元数:64
BiGRU	批归一化层	-
	双向 GRU 层	单元数:64
	批归一化层	-
输出层	展平层	-
	全连接层	激活函数:Sigmoid

池电压达到 3.6 V 后以恒定电压(CV)模式继续充电,直至电池电流降至 0.5。电池的失效条件为:当电池达到寿命终止标准——容量衰减到额定容量的 80%,即衰减到 0.96 Ahr。各电池实验信息如表 2 所示。




图 5 实验台装置

退化数据对各类方法开展实验验证,图 5 为实验台装置。数据集包括 4 个电池,分别为 Battery1、Battery2、Battery3 和 Battery4。实验环境温度恒定为 25 °C,测试工况为恒流恒压充电-恒流恒压放电,充放电电流均为 10 C(12 A)。测量的主要参数包括电压、电流、电池电荷量等。电池充电过程为:先以 12 A 的恒定电流(CC)模式进行充电,至电

从该数据集中筛选出容量、电流和电压等关键信息,并绘制锂电池充放电时的容量衰减曲线及电流、电压曲线和 IC 曲线,结果如图 6~8 所示。从图 6 中可以看出,随着循环次数的增加,各个电池的容量均呈下降趋势,但不同的电池其容量下降的情况略有不同。图 7 中展示了电池 Battery2 在不同循环次数下的电压和电流曲线,可以看出

表 2 电池实验信息

电池编号	容量/Ah	充放电模式	总循环次数	有效循环次数
Battery1	1.2	恒流恒压	561	457
Battery2	1.2	恒流恒压	692	548
Battery3	1.2	恒流恒压	528	431
Battery4	1.2	恒流恒压	552	422

在不同循环下其电流电压曲线存在一定的规律性变化,其中 B 点为电压变为 3.6 V 的点,C 点为电流开始下降的点, D 点为电流下降为 0 的点。图 8 中展示了电池 Battery2 的 IC 曲线,其中由于原始的 IC 曲线存在错误值等问题,故本文对其进行滤波处理,所用滤波方法为高斯滤波。






图 6 电池容量退化曲线



(a) 电压变化曲线



(b) 电流变化曲线

图 7 不同循环次数下电压和电流变化曲线

### 3.2 实验设计

#### 1) 健康因子选取

本实验台采用的试验工况为恒流恒压充电—恒流恒




图 8 原始 IC 曲线以及滤波后的 IC 曲线

压放电,其充电过程采用固定模式,便于采集健康因子,因此本文利用充电过程中的监测参数进行健康因子的提取。

拟提取的输入量有:充放电时电压曲线在 A 点、B 点(如图 7 所示)以及两点中点处的斜率,即 3 个点对应时刻电池的电阻值,记为 Slope1、Slope2 以及 Slope3;电流曲线在 C 点、D 点(如图 7 所示)以及两点中点处的斜率,记为 Slope4、Slope5 以及 Slope6;电流曲线在充电过程中由 12 A 降为 1.2 A 的时间,即等电流下降时间,记为 delta-t;以及 IC 曲线中的峰值(如图 8 所示),记为 IC\_peak。

为计算出上述输入量与电池 SOH 的相关程度,采用皮尔逊相关系数计算各输入量与 SOH 之间的相关性系数  $r$ ,当  $r$  绝对值接近于 1 时,表明两个变量呈现强相关;当  $r$  接近于 0 时,表明两个变量相关性越弱甚至无关。计算结果如表 3 所示,可以看出 Slope1、delta-t 以及 IC\_peak 与电池 SOH 数据的相关性系数最高,且其绝对值均超过了 0.85,故本文在后续实验中采这 3 个参数作为健康因子,分别记为 HI1、HI2 和 HI3。

表 3 相关系数

特征	电池序号			
	Battery1	Battery2	Battery3	Battery4
Slope1	-0.887 4	-0.923 1	-0.852 2	-0.931 1
Slope2	-0.623 9	-0.816 3	-0.565 6	-0.821 0
Slope3	-0.322 4	-0.269 1	-0.174 5	-0.310 1
Slope4	0.854 1	0.842 0	0.856 8	0.828 9
Slope5	-0.922 6	-0.479 9	-0.851 6	-0.940 6
Slope6	-0.699 6	-0.655 4	-0.729 0	-0.702 1
delta-t	-0.976 8	-0.967 4	-0.973 9	-0.973 7
IC_peak	0.991 3	0.997 5	0.992 4	0.988 1

#### 2) 模型参数设置及训练

实验采用 Python 作为开发语言, Tensorflow 作为深度学习框架搭建模型。在 TCN 模块中,首先构造一个残差块,其中卷积层使用 Conv1D 函数,卷积层中采用 128 个大小为 5 的一维卷积核;激活函数采用 ReLU,可以减少参数之间的依赖关系,进而加快模型的学习速度。完整的 TCN 模块由 4 个残差块组成,其中扩张因子  $d$  取值分别为

[1,2,4,8]。在BiGRU模块中,该模块每层的单元数为64。全连接层采用Sigmoid作为激活函数。同时网络中添加了灭活率为0.1的Dropout层来防止过拟合。实验训练过程中设置epoch的个数为100, Batch\_Size的大小为64;优化器采用学习率为0.0001的Adam优化器。

为进一步验证本文所提方法的泛化性,将数据集分为4组,如表4所示,分别使用前3个电池的数据作为训练集,第4个电池数据作为测试集。

表4 实验组设置

实验组名称	训练集	测试集
Task1	Battery2、Battery3、Battery4	Battery1
Task2	Battery1、Battery3、Battery4	Battery2
Task3	Battery1、Battery2、Battery4	Battery3
Task4	Battery1、Battery2、Battery3	Battery4

### 3) 实验评价指标

为验证本文所提方法对电池SOH评估的准确性,采用决定系数(coefficient of determination,  $R^2$ )、绝对平均误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)对评估结果进行定量评价,如式(6)~(8)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

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

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

式中: $y$ 和 $\hat{y}$ 分别为真实值和估计值。当MAE和RMSE越小以及 $R^2$ 越大时,可认为模型精度越高。

## 4 实验结果与分析

本文分别从所选取的健康因子对评估精确度的提升、所加入的Dropout层对评估精确度的提升以及与当前广泛使用的LSTM、TCN、BiGRU等方法的对比3个方面展开了对所提方法评估结果的精确性进行了实验验证。

首先,对本文所提取的健康因子与常见的健康因子进行比较。本文提取了新的健康因子HI1,因此将仅使用HI2和HI3作为健康因子的实验结果与使用HI1、HI2和HI3作为健康因子的实验结果进行对比,所用模型均为本文所提TCN-BiGRU模型。实验结果如图9所示,可以看出在4组实验中,包含了健康因子HI1的实验结果均比未使用HI1的实验结果曲线更贴近真实值,证明本文所提健康因子对SOH评估结果具有很好的提升效果。

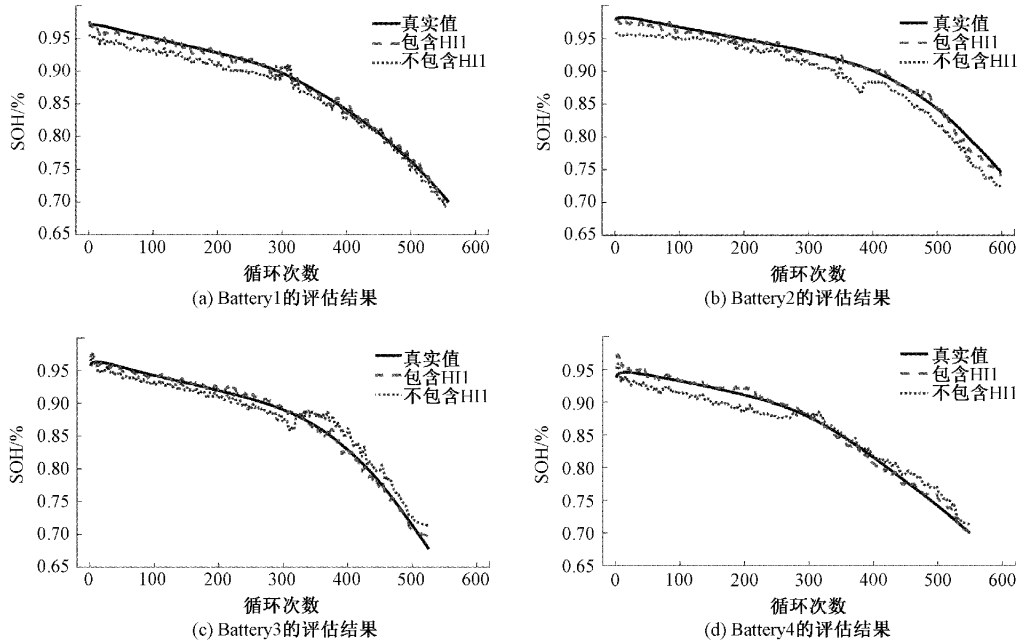


图9 不同健康因子下电池的评估结果

其次,对本文所提出模型在TCN模块与BiGRU模块之间所加Dropout层的效果进行了实验验证,所用模型均为本文所提TCN-BiGRU模型。实验结果如图10所示,可以看出在4组实验中,加入了Dropout层的实验结果比未使用Dropout层的实验结果曲线与真实值曲线之间的距

离更近,说明本模型中所加入的Dropout层对SOH评估结果具有很好的提升效果。

最后,为证明本文所提模型的有效性,与对比方法进行比较。按照上述实验中健康因子选取方法,分别使用TCN-BiGRU、TCN、BiGRU和LSTM模型,以及组合模型

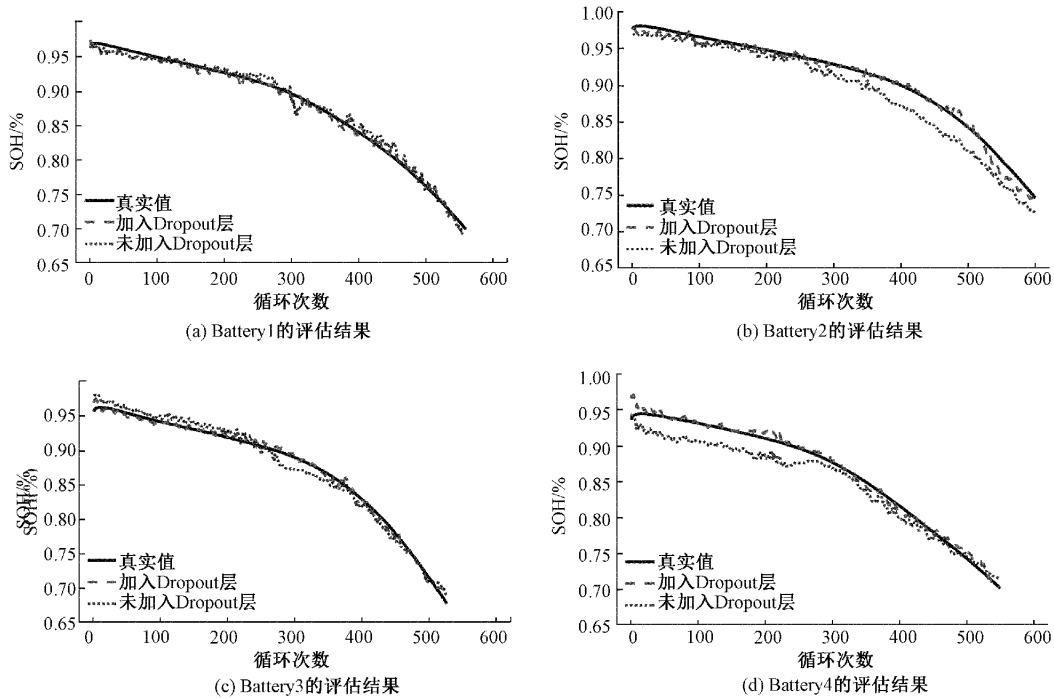


图 10 Dropout 层对电池的评估结果的影响

CNN-BiLSTM<sup>[18]</sup>对 4 组电池的 SOH 评估, 并对评估结果进行误差对比。实验结果如图 11 所示。从图中可以

看出: 1) 电池 Battery1 在评估初期 TCN 和 LSTM 的评估结果均较靠近真实值, 第 70 次循环之后只有 TCN-BiGRU

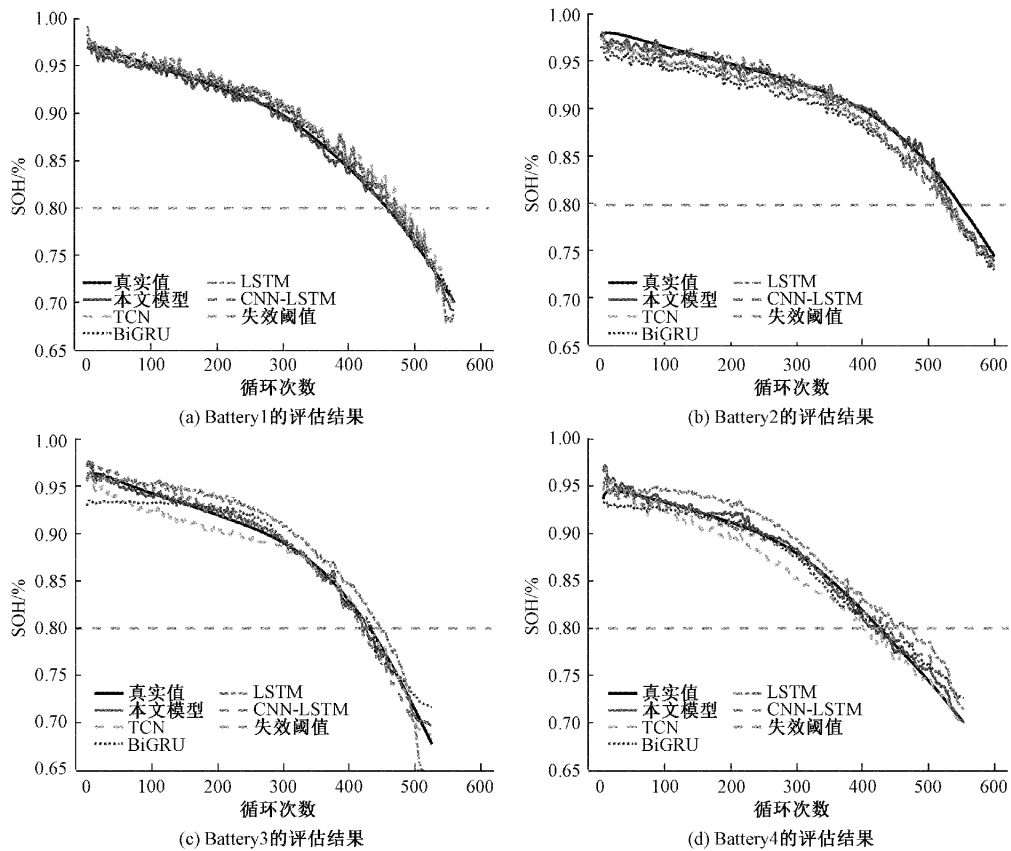


图 11 4 组电池的评估结果



的估计结果与真实值保持了较近的距离,对比方法 LSTM、TCN、BiGRU 和 CNN-LSTM 效果均较差;2) 电池 Battery2 在全部循环中 TCN-BiGRU 的评估结果均为几种方法中与真实值之间的距离最近的;3) 电池 Battery3 和电池 Battery4 在评估初期 TCN-BiGRU、CNN-LSTM 和 LSTM 的估计结果与真实值距离更近,BiGRU 和 TCN 方法略差,随着循环次数的增加,仅有本文方法和 CNN-LSTM 保持住了较优的估计结果,评估结果与真实值之间的误差较小,其余方法预测均逐渐远离真实曲线,但本文方法的评估结果仍为最优的。综合来看本文所提方法在 4 组电池数据中所取得的结果相比所对比的方法的结果其曲线均更贴近真实值,评估效果为最好的。

将本文所提方法与所对比方法进行定量比较。由表 5 可以看出,在相同电池对象上,本文所提方法的决

定系数大于其他所选对比方法,并且绝对平均误差和均方根误差均小于其他所选对比方法。在 4 组实验中,SOH 评估值的  $R^2$  均值为 0.990 4,相对于 LSTM (0.961 8)、TCN (0.964 7)、BiGRU (0.967 3)、CNN-LSTM (0.976 0) 模型分别提升了 2.89%、2.59% 和 2.33%、1.45%;MAE 的均值为 0.017 1,相对于 LSTM (0.033 2)、TCN (0.033 8)、BiGRU (0.033 6)、CNN-LSTM (0.028 2) 模型分别降低了 48.49%、49.41% 和 49.11%、39.36%;RMSE 的均值为 (0.022 3),相对于 LSTM (0.042 1)、TCN (0.042 0)、BiGRU (0.037 2)、CNN-LSTM (0.035 2) 模型分别降低了 47.03%、46.90% 和 40.05%、36.65%,可以看出在数值上均明显优于对比方法。因此,可以说明本文所提方法在针对锂离子电池 SOH 的评估上具有更高的精度。

表 5 电池 SOH 性能评估结果

对比方法		评价指标 $R^2$				
实验组	Task1	Task2	Task3	Task4	均值	
LSTM	0.980 1	0.959 1	0.981 5	0.926 5	0.961 8	
TCN	0.968 7	0.953 1	0.980 8	0.956 2	0.964 7	
BiGRU	0.988 2	0.914 0	0.989 9	0.977 1	0.967 3	
CNN-BiLSTM	0.981 2	0.961 3	0.981 6	0.979 8	0.976 0	
本文模型	0.992 8	0.984 2	0.994 0	0.990 6	0.990 4	
对比方法		评价指标 MAE				
实验组	Task1	Task2	Task3	Task4	均值	
LSTM	0.028 1	0.037 8	0.021 4	0.045 3	0.033 2	
TCN	0.035 2	0.040 8	0.021 5	0.037 6	0.033 8	
BiGRU	0.021 0	0.057 9	0.026 8	0.028 7	0.033 6	
CNN-BiLSTM	0.028 9	0.032 5	0.027 2	0.024 1	0.028 2	
本文模型	0.015 8	0.018 7	0.016 2	0.017 5	0.017 1	
对比方法		评价指标 RMSE				
实验组	Task1	Task2	Task3	Task4	均值	
LSTM	0.034 4	0.040 8	0.036 3	0.056 7	0.042 1	
TCN	0.043 2	0.043 7	0.037 0	0.044 1	0.042 0	
BiGRU	0.026 5	0.059 2	0.026 8	0.036 1	0.037 2	
CNN-BiLSTM	0.033 7	0.041 6	0.031 8	0.033 8	0.035 2	
本文模型	0.020 5	0.025 1	0.020 6	0.023 1	0.022 3	

## 5 结 论

本文提出了一种基于 TCN-BiGRU 的电池 SOH 的评估方法及框架。该混合网络融合了 TCN 和 BiGRU,捕捉时间序列的长期信息,实现更准确的预测。本方法首先通过分析电池充电过程的数据提取了新的健康因子;然后采用 TCN-BiGRU 进行 SOH 评估,捕捉充电过程中不同时间尺度的特征,同时充分利用过去和未来时刻的信息,最终实现高精度的 SOH 估计;同时在训练过程中使用

Dropout 层防止过拟合,提高效率和泛化能力。基于该评估方法,本文在搭建的锂离子电池退化试验台所获取的电池退化实验数据集上进行了大量实验,首先证明了本文所提健康因子以及所加入的 Dropout 层均对 SOH 评估结果具有很好的提升效果。其次,将本文所提方法与其他对比方法的实验结果进行了比较,在相同的评价指标上明显优于对比算法。综上,本文所提出的基于 TCN-BiGRU 的电池 SOH 的评估方法能够进行较高精度的 SOH 估计,具有较高应用价值。本文工作仅集中于对锂离子电池的 SOH



进行评估,而没有涉及对未来时刻的 SOH 进行预测,此后将会进一步研究 SOH 的预测方法。

### 参考文献

- [1] 刘大同,周建宝,郭力萌,等. 锂离子电池健康评估和寿命预测综述[J]. 仪器仪表学报, 2015, 36(1):1-16.
- [2] 张文华,毛荣军,刘平,等. 锂离子动力电池健康状态评估方法的研究进展[J]. 电源技术, 2016, 40(6): 1315-1317.
- [3] 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.
- [4] 邓昊. 基于电化学机理模型的锂离子电池参数辨识及电池 SOC 估计方法研究[D]. 上海:上海交通大学, 2018.
- [5] 孙鹏宇,李建良,陶知非,等. 动态工况电池在线参数辨识及 SOC 估计研究[J]. 电子测量技术, 2021, 44(1): 10-17.
- [6] 颜湘武,邓浩然,郭琪,等. 基于自适应无迹卡尔曼滤波的动力电池健康状态检测及梯次利用研究[J]. 电工技术学报, 2019, 34(18):3937-3948.
- [7] 郑雪莹,邓晓刚,曹玉苹. 基于能量加权高斯过程回归的锂离子电池健康状态预测[J]. 电子测量与仪器学报, 2020, 34(6):63-69.
- [8] 刘徽,杨慧婕,刘守印. 基于 ACCA-FCM 和 SVM-RFE 的蓄电池 SOH 特征选择算法[J]. 计算机与现代化, 2018, 269(1):11-18.
- [9] EDDAHECH A, BRIAT O, BERTRAND N, et al. Behavior and state-of-health monitoring of Li-ion batteries using impedance spectroscopy and recurrent neural networks[J]. International Journal of Electrical Power & Energy Systems, 2012, 42(1): 487-494.
- [10] 刘伟霞,田勋,肖家勇,等. 基于混合模型及 LSTM 的锂电池 SOH 与剩余寿命预测[J]. 储能科学与技术, 2021, 10(2):689-694.
- [11] CUI S, JOE I. A dynamic spatial-temporal attention-based GRU model with healthy features for state-of-health estimation of lithium-ion batteries [J]. IEEE Access, 2021, 9: 27374-27388.
- [12] 王凡,史永胜,刘博亲,等. 基于注意力改进 BiGRU 的锂离子电池健康状态估计[J]. 储能科学与技术, 2021, 10(6): 2326.
- [13] YAN J, LIU J, YU Y, et al. Water quality prediction in the luan river based on 1-DRCNN and bigru hybrid neural network model[J]. Water, 2021, 13(9): 1273.
- [14] 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.
- [15] ZHOU D, LI Z, ZHU J, et al. State of health monitoring and remaining useful life prediction of lithium-ion batteries based on temporal convolutional network[J]. IEEE Access, 2020, 8: 53307-53320.
- [16] 张孝远,张金浩,蒋亚俊. 基于改进 TCN 模型的动力电池健康状态评估[J]. 储能科学与技术, 2022, 11(5):1617-1626.
- [17] 戴彦文,于艾清. 基于健康特征参数的 CNN-LSTM&GRU 组合锂电池 SOH 估计[J]. 储能科学与技术, 2022, 11(5):1641-1649.
- [18] 朱振宇,高德欣. 基于 CNN-BiLSTM 网络的锂离子电池健康状态检测方法[J]. 电子测量技术, 2023, 46(3): 128-133.
- [19] YANG D, ZHANG X, PAN R, et al. A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve[J]. Journal of Power Sources, 2018, 384: 387-395.
- [20] 李东洋,吕明泽,郭艳蓉,等. ALO 优化下 1DCNN-BiLSTM-Attention 锂电池 SOH 预测[J]. 电工技术, 2023, 586(4):33-40.

### 作者简介

刘少卿, 硕士, 主要研究方向为装备故障诊断。

E-mail: shaoqingliu1999@163.com

苗强(通信作者), 教授, 主要研究方向为装备智能健康评估。

E-mail: mqiang@scu.edu.cn