

# 基于冠豪猪优化器-改进双向时间卷积网络-长短期记忆网络和注意力机制的动力锂电池健康状态预测

邢泽铭<sup>1</sup>, 龚家元<sup>1</sup>, 陈鸿洋<sup>2</sup>, 陈安庆<sup>1</sup>

<sup>1</sup> (湖北汽车工业学院汽车工程师学院, 十堰 442002)

<sup>2</sup> (汉江国家实验室, 武汉 430000)

**摘要:** 为了更好的监测动力锂电池健康状态。提出一种基于改进双向时间卷积网络、长短期记忆网络和注意力机制的锂电池健康状态预测方法。使用冠豪猪优化器对所提方法的超参数进行寻优。在马里兰大学锂电池充放电数据集中进行测试, 提取和容量相关健康特征, 通过皮尔逊相关系数筛选相关度较高的健康特征作为神经网络算法的输入。提出的方法在所有电池健康状态预测的均方根误差均不超过 0.020, 平均绝对误差不超过 0.017, 决定系数在 0.995 以上。在锂电池健康状态预测可以实现较高的精度。

**关键词:** 健康状态; 长短期记忆网络; 动力锂电池; 双向时间卷积网络; 冠豪猪优化器

**中图分类号:** TM912; TP183 **文献标志码** A **doi:** 10.12146/j.issn.2095-3135.20241207001

## Prediction of state of health of power lithium battery based on CPO-IBiTCN-LSTM and attention mechanism

XING Zeming<sup>1</sup>, GONG Jiayuan<sup>1</sup>, CHEN Hongyang<sup>2</sup>, CHEN Anqing<sup>1</sup>

<sup>1</sup> (Hubei University of Automotive Technology Institute of Automotive Engineers, Shiyan, 442002, China)

<sup>2</sup> (Hanjiang National Laboratory, Wuhan, 430000, China)

**Corresponding Author:** Hongyang Chen. Hanjiang National Laboratory, Wuhan, 430000, China.

**Email:** dr.chenhongyang@outlook.com.

**Abstract:** In order to better monitor the health state of power lithium batteries. A lithium battery health state prediction method based on Improved Bidirectional Temporal Convolutional Network, Long Short Term Memory Network and Attention Mechanism is proposed. The hyperparameters of the proposed method are optimized using Crested Porcupine Optimizer. Tests were conducted on the University of Maryland lithium battery charge/discharge dataset to extract capacity-related health features, and the health features with higher correlation were screened by Pearson correlation coefficient as inputs to the neural network algorithm. The Root Mean Squard Error of the proposed method is no more than 0.020, the Mean Absolute Error is no more than 0.017, and the R-Square is above 0.995 for all battery health state predictions. Higher accuracy can be achieved in lithium battery health state prediction.

来稿日期: 2024-12-07 修回日期: 2025-03-20

基金项目: 湖北省自然科学基金计划(十堰创新发展联合基金) 培育项目(2024AFD116); 湖北省教育厅科学技术研究计划重点项目(D20231805); 湖北汽车工业学院博士科研启动基金(BK202307, BK201604); 湖北省自然科学基金(青年项目)(2023AFB481)

作者简介: 邢泽铭, 硕士研究生在读, 研究方向为深度学习、电池管理系统、数值优化; 龚家元, 副教授, 研究方向为信息物理系统、高性能计算、数据科学以及人工智能; 陈鸿洋(通讯作者), 博士, 研究方向为声振状态监测及预报, E-mail: dr.chenhongyang@outlook.com; 陈安庆, 高级工程师, 研究方向为智能电网、电网云计算。

---

**Key words:** State Of Health; Long Short Term Memory Network; Power lithium battery; Bidirectional Temporal Convolutional Network; Crested Porcupine Optimizer

**Funding:** This work is supported by Natural Science Foundation of Hubei Province of China (Joint Fund for Innovation and Development of Shiyuan) (2024AFD116); Key Project of Science and Technology Research Plan of Hubei Provincial Department of Education (D20231805); Doctoral Research Start-up Fund of Hubei University of Automotive Technology (BK202307, BK201604); Natural Science Foundation of Hubei Province of China (2023AFB481).

## 1 引言

新能源汽车动力电池主要是锂电池,主要原因是锂电池能量密度高、污染低、寿命长。由于电池在使用过程中,伴随着充放电循环次数的增多,电池内部发生了一些不可逆的化学反应,导致内阻增大,实际容量降低<sup>[1]</sup>。电池管理系统(Battery Management System, BMS)对于锂电池安全稳定运行至关重要, BMS 可以合理控制锂电池运行状态,对每个电池单元进行智能管理,延长使用寿命,确保安全。锂电池的健康状态(State Of Health, SOH)和剩余使用寿命(Remaining Useful Life, RUL)预测是 BMS 的重要组成部分。

锂电池 SOH 预测方法主要包括模型驱动和数据驱动<sup>[2]</sup>。基于模型的方法主要包括电化学模型和等效电路模型,孙等人<sup>[3]</sup>基于一阶 RC 等效电路模型,提出基于多维数据特征融合的锂电池预测方法。Miniguan 等人<sup>[4]</sup>对于汽车应用的三种不同等效电路模型进行了比较研究,得出戴维南模型较为符合电池的电化学模型。

然而,建模和计算过程是复杂的,且电池的老化过程是非线性的,常常伴随着副反应的发生,所以很难找到合适的模型。基于数据驱动的方法主要包括机器学习、深度学习和多种方法融合进行预测。数据驱动的方法不需要考虑电池内部复杂的反应,只需对电池充放电循环的历史数据进行处理,被国内外众多学者广泛应用。郭等人<sup>[5]</sup>提出基于注意力机制和 SOA-LSTM 的锂电池建立状态估计方法,该方法在 CALCE 锂电池数据集中进行测试,提取 4 种健康特征,均方根误差为 0.011,模型拟合度达到 98%以上。刘等人<sup>[6]</sup>提出改进粒子群优化算法优化 LSTM 网络 (IPSO-LSTM),在 NASA 锂电池数据中进行实验,均方根误差低于 0.03,相较于 BP、LSTM、PSO-LSTM 模型,IPSO-LSTM 算法的误差更小。刘等人<sup>[7]</sup>提出一种基于 TCN 和 BiGRU 的锂电池健康状态估计方法,并在模型中添加 Dropout 层,有效防止模型过拟合。时间卷积网络(Temporal Convolutional Network, TCN)适合处理时序预测问题,但 TCN 参数较多,训练较为困难,且预测精度需要进一步提高。现有研究中多使用单一网络模型,不同模型融合的方法往往可以得到更好的性能和效果。

数据驱动的方法更依赖于特征的选择和算法参数的设置。提取的特征与预测值的相关度不足会造成预测误差较大,算法参数选择不当会导致模型不收敛,预测效果差<sup>[8]</sup>。为了解决神经网络算法参数选择问题,使用智能优化算法对神经网络算法的超参数进行优化。智能优化算法,又称元启发式算法,是人工智能领域的一个子集,在现实生活中的工程问题、资源分配、调度和利润最大化,智能优化算法都发挥着重要作用<sup>[9]</sup>。

针对以上问题,本文提出基于改进双向时间卷积网络(Improved Bidirectional Temporal Convolutional Network, BiTCN)-注意力机制 SE(Squeeze-and-Excitation)模块-长短期记忆网络(Long Short Term Memory Network, LSTM)锂电池健康状态估计算法。使用深度可分离卷积替换 TCN 中的原有卷积,减少 TCN 的模型参数。将 SE 注意力机制添加到 TCN 网络的输出,使模型更加关注和锂电池健康状态有关的特征。引入双向机制来处理序列数据,进一步提高 TCN 网络的性能。添加 LSTM,对特征进一步提取。同时,使用冠豪猪优化器对所提

算法的超参数进行寻优，提高模型的精度。使用马里兰大学先进生命周期工程中心(Center for Advanced Life Cycle Engineering, CALCE)锂电池数据集中的四个电池进行实验，只使用一个的电池的部分数据进行训练，在其他电池中也取得较好的预测结果，决定系数 (R-Square, R2) 在 4 个电池中均达到了 0.995 以上，均方根误差均(Root Mean Squard Error, RMSE)和平均绝对误差 (Mean Absolute Error, MAE)都在 0.02 以下，表现出较高的 SOH 预测精度。

本文分为以下几个部分。第一部分介绍了冠豪猪优化器以及 IBitCN-SE-LSTM 方法，第二部分介绍了实验所用数据集以及健康特征提取(Health Features, HF)。第三部分使用实验证明所提的 IBitCN-SE-LSTM 方法可以更准确估计锂电池的 SOH, 最后对全文进行了总结。

## 2 方法

### 2.1 冠豪猪优化器

冠豪猪优化器 (Crested Porcupine Optimizer, CPO) 是 Mohame 等人<sup>[10]</sup>提出的一种新型的群智能优化算法, CPO 包含了探索和开发阶段, 其中开发和探索阶段包含了四种不同的保护机制, 从攻击性最小到攻击性最强分别为: 视觉、声音、气味和物理攻击。

#### 2.1.1 探索阶段

根据冠豪猪(Crested Porcupine, CP)的防御行为, 当捕食者较远时, CP 会采用两种防御手段警告捕食者, 即视觉策略和声音策略。

第一种防守策略。当 CP 察觉到捕食者与自己的距离过于接近时, 它开始举起并摆动羽毛, 给捕食者一种它很大的错觉。对这一行为进行建模。

$$X_i(t+1) = X_i(t) + \lambda_1 \times |2 \times \lambda_2 \times X_{cp}(t) - Y_i(t)| \quad (1)$$

其中  $X_{cp}(t)$  是迭代  $t$  次的最优解,  $Y_i(t)$  是通过当前时刻的 cp 和随机位置的 cp 杂交得到的,  $X_i(t)$  代表迭代  $t$  次时捕食者的位置,  $\lambda_1$  是随机生成的数, 且符合正态分布,  $\lambda_2$  是 0 和 1 之间内的随机值。生成  $Y_i(t)$  的数学公式如下:

$$Y_i(t) = \frac{X_i(t) + X_r(t)}{2} \quad (2)$$

其中  $r$  是  $[1, N]$  之间随机生成的整数。

第二种防守策略, CP 通过制造刺耳的声音警告捕食者, 当捕食者靠近时, CP 会发出更大的声音警告捕食者。这一阶段进行建模如下。

$$\overline{x}_i^{t+1} = (1 - \overline{U}_1) \times \overline{x}_i^t + \overline{U}_1 \times \left( \overline{y} + \tau_3 \times \left( \overline{x}_{r_1}^t - \overline{x}_{r_2}^t \right) \right) \quad (3)$$

$$X_i(t+1) = (1 - U_1) \times X_i(t) + U_1 \times \left( Y_i(t) + \lambda_3 \times (X_{r_1}(t) - X_{r_2}(t)) \right) \quad (4)$$

其中  $r_1$  和  $r_2$  是区间  $[1, N]$  内随机生成的两个整数,  $\lambda_3$  是区间  $[0, 1]$  内生成的随机值。二元向量  $\overline{U}_1$  取值在 0 和 1 之间, 用于模拟该策略中可能出现的情况, 即捕食者听到 CP 发出声音的反应, 逃离、停止接近, 或者声音较弱对捕食者没有造成太大影响而继续靠近, 此时 CP 发出的声音也会变大。

#### 2.1.3 开发阶段

根据 CP 的防御行为, 当捕食者与 CP 的距离继续接近时, CP 会采用释放臭气或者物理攻击的策略。

第三种防守策略, CP 会散发一种恶臭味, 阻止捕食者靠近。对这一阶段进行建模。

$$\overline{x}_i^{t+1} = (1 - \overline{U}_1) \times \overline{x}_i^t + \overline{U}_1 \times \left( \overline{x}_{r_1}^t + S_i^t \times \left( \overline{x}_{r_2}^t - \overline{x}_{r_3}^t \right) - \tau_3 \times \overline{\delta} \times \gamma_i \times S_i^t \right) \quad (5)$$

$$\vec{\delta} = \begin{cases} +1, \overline{rand} \leq 0.5 \\ -1, \overline{rand} > 0.5 \end{cases} \quad (6)$$

$$\gamma_t = 2 \times rand \times \left(1 - \frac{t}{t_{max}}\right)^{\frac{t}{t_{max}}} \quad (7)$$

$$S_t^i = \exp\left(\frac{f(x_t^i)}{\sum_{k=1}^N f(x_t^k) + \varepsilon}\right) \quad (8)$$

其中  $r_3$  是 1 和 N 之间随机生成的整数。 $\overline{rand}$  是一个包含  $[0,1]$  之间随机生成的数值的向量。 $\vec{\delta}$  用于控制方向,  $\gamma_t$  为防御因子, 是在区间  $[0,1]$  内生成的随机值,  $S_t^i$  是气味扩散因子。其中  $f(\cdot)$  表示第当前个体的适应度值。 $\varepsilon$  是一个小值。 $rand$  是一个变量, 为 0 和 1 之间的随机数。与第二种防守策略类似,  $\overline{U}_1$  向量用于模拟该策略中可能出现的三种情况。

第四种防守策略, 即物理攻击, 当捕食者非常接近时, CP 会采用攻击手段, 保护自己。对这一阶段进行建模。

$$\vec{x}_{cp}^{t+1} = \vec{x}_{cp}^t + (\alpha(1-\tau_4) + \tau_4) \times (\delta \times \vec{x}_{cp}^t - \vec{x}_i^t) - \tau_5 \times \delta \times \gamma_t \times \vec{F}_i^t \quad (9)$$

其中  $\vec{x}_{cp}^t$  是当前迭代次数的最优位置, 代表 CP,  $\alpha$  是收敛速度因子,  $\tau_4$  是在 0 和 1 范围内生成的随机值,  $\vec{F}_i^t$  是影响第  $i$  个捕食者的 CP 的平均力。

$$\vec{F}_i^t = \vec{\tau}_6 \times m_i \times (\vec{v}_i^{t+1} - \vec{v}_i^t) \quad (10)$$

其中  $m_i$  是当前迭代次数第  $i$  个捕食者的质量,  $\vec{v}_i^{t+1}$  是第  $i$  个捕食者在下一次迭代时的最终速度,  $\vec{v}_i^t$  是当前迭代次数第  $i$  个捕食者的初始速度,  $\vec{\tau}_6$  是在区间  $[0,1]$  内生成的随机值向量。

## 2.2 加性注意力机制

加性注意力机制使用全连接层来计算注意力, 通过引入可学习的权重后, 注意力机制可以使网络在输入序列上分配不同的注意力权重。可以使得网络可以更高效的处理数据, 提取更多的信息。wu 等人<sup>[11]</sup>将加性注意力机制应用于 transformer 中, 使得 transformer 的参数量更少。

## 2.3 改进双向时间卷积网络

### 2.3.1 时间卷积网络

TCN<sup>[12]</sup>是一种处理时间序列数据的深度学习算法, 采用扩张卷积来增加感受野, 使得 TCN 通常具有更少的参数;TCN 通过扩张卷积来捕捉长期依赖, 避免了顺序依赖, 使得 TCN 在大规模数据集上的训练更加有效。TCN 主要由因果卷积、扩张卷积和残差块三部分构成。

因果卷积可以使 TCN 在处理时间序列任务时, 仅对过去时间步骤的数据执行运算, 保持因果性。扩张卷积使模型能够捕获更多对长输入数据的依赖关系。残差块可以提高网络的性能, 一个残差块有两个非线性扩张因果卷积层, 权重归一化层 WeightNorm, 激活函数为 ReLU。TCN 中引入了 Dropout 层, 防止模型过拟合。

### 2.3.2 双向时间卷积网络

双向时间卷积网络 (Bidirectional Temporal Convolutional Network. BiTCN) 由前向层和反向层组成, 前向的 TCN 从前向后处理数据, 反向的 TCN 从后向前对数据进行处理<sup>[13]</sup>。将两个 TCN 的输出进行叠加, 可以提高整个网络对数据的处理能力, 从而提高预测的精度。

### 2.3.3 改进残差块结构

将 BiTCN 中的 WeightNorm 去掉, 使用深度可分离卷积替换原本的因果卷积, 深度可分离卷积由深度卷积和逐点卷积组成, 可以大大减少参数的数量。采用 LeakyReLU 作为激活函数, 可以提高网络的鲁棒性<sup>[14]</sup>, 将残差块中卷积层数缩减为 1 层, 在残差块中添加加性注意力机制, 使得在残差网络中分配不同的权重以获得全局和局部关系。可以更好的学习输入特征与容量之间的关系。改进后的残差网络如图 1 所示。

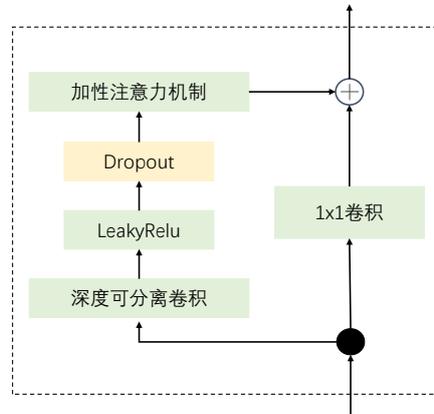


图 1 改进残差块结构图

Fig. 1 Improved residual block structure diagram

## 2.4 长短期记忆网络

LSTM 由遗忘门、输入门、输出门组成, 能够处理较长的序列数据<sup>[15]</sup>, LSTM 结构如图 2 所示。

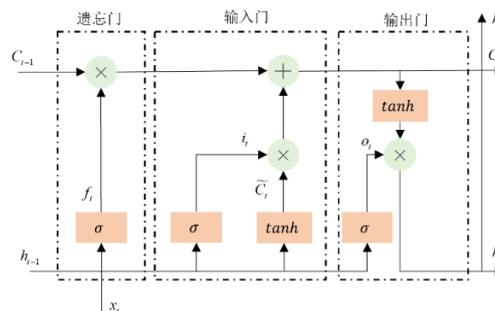


图 2 LSTM 网络结构图

Fig. 2 LSTM network structure diagram

## 2.5 通道注意力机制

SE 通道注意力机制参数数量少、结构简单、通道数和输入数据大小没有变化, 可以作为子网络嵌入到任何神经网络中<sup>[16]</sup>。SE 通道注意力机制的结构如图 3 所示。

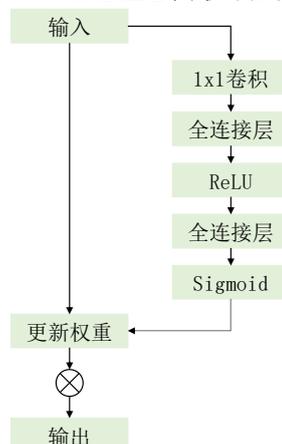


图3 SE注意力机制结构图

Fig. 3 SE Attention Mechanism Structure Diagram

## 2.6 改进双向时间卷积网络-通道注意力机制-时间卷积网络方法

为了提高预测的准确度，将之前所提的方法进行组合，提出 IBiTCN-SE-LSTM 方法，在 IBiTCN 后添加 SE 注意力机制，可以提高网络的数据处理能力。与其他从空间维度提升网络性能的注意力机制相比，SE 注意力机制从特征和通道之间的关系考虑问题，从而避免了加深网络层数的不良影响。IBiTCN-SE-LSTM 方法的结构如图 4 所示。其中 FC 为全连接层，Dropout 为随机丢失层，可以防止模型过拟合。

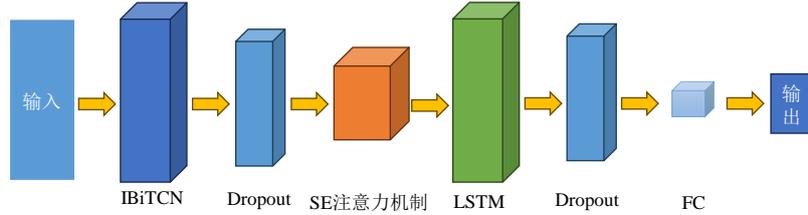


图4 IBiTCN-SE-LSTM 方法结构图

Fig. 4 Structure of the IBiTCN-SE-LSTM method

## 2.7 锂电池健康状态定义及计算方法

SOH 是检验动力电池性能的重要指标，SOH 可以使用电池容量来表示<sup>[17]</sup>。电池 SOH 的具体方程如下。

$$SOH = \frac{C_i}{C_o} \times 100\% \quad (11)$$

其中  $C_i$  为电池循环  $i$  次的容量， $C_o$  为电池的初始容量。

## 3 数据介绍及数据处理

本文选用 CALCE 开源锂电池充放电数据集。采用该数据集中编号为 CS2\_35、CS2\_36、CS2\_37 和 CS2\_38 的电池进行测试，4 个电池在同样的条件中进行充放电实验，该实验采用的锂电池额定容量为 1.1Ah，额定电压为 4.2V。采用标准的恒流恒压充电方式，充电实验首先用 0.5C 的恒定电流充电至 4.2V，然后按照 4.2V 的恒定电压进行模式充电，直到充电电流降到 0.05A；放电实验按照 1C 电流放电至 2.7V<sup>[18]</sup>。

对实验数据进行处理，部分充放电循环中进行了充电或只进行了放电实验，或者充放电只维持了很短的时间，这些数据可能会造成干扰，应被舍弃。对容量数据进行清洗，每 40 个数据作为一个子数据，计算子数据的标准差和平均值，数据不在平均值加减两倍标准差范围内的值为异常值，应舍弃。处理后的电池容量退化曲线如图 5 所示。

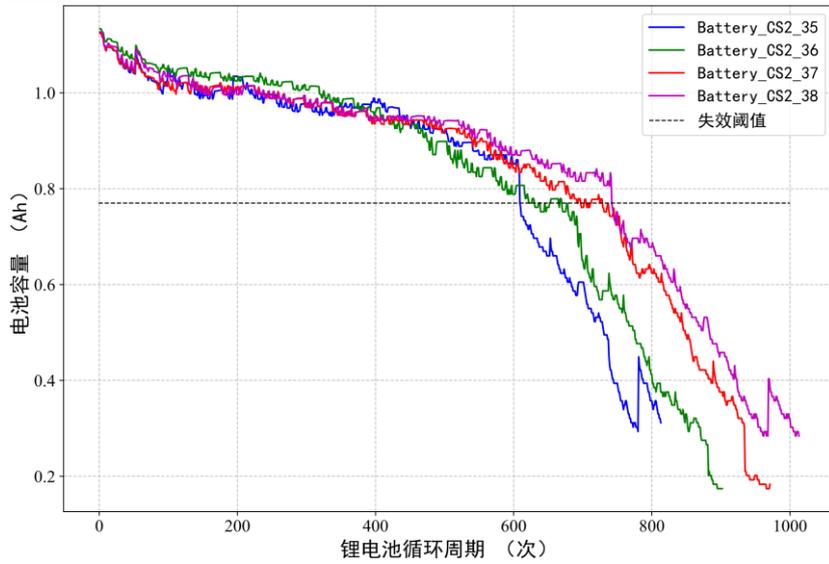


图 5 电池容量退化曲线

Fig. 5 Battery Capacity Degradation Curve

以 CS2\_35 电池为例，获取数据集中每个充放电循环测得的电压、电流和内阻，提取的健康特征曲线如图所示。

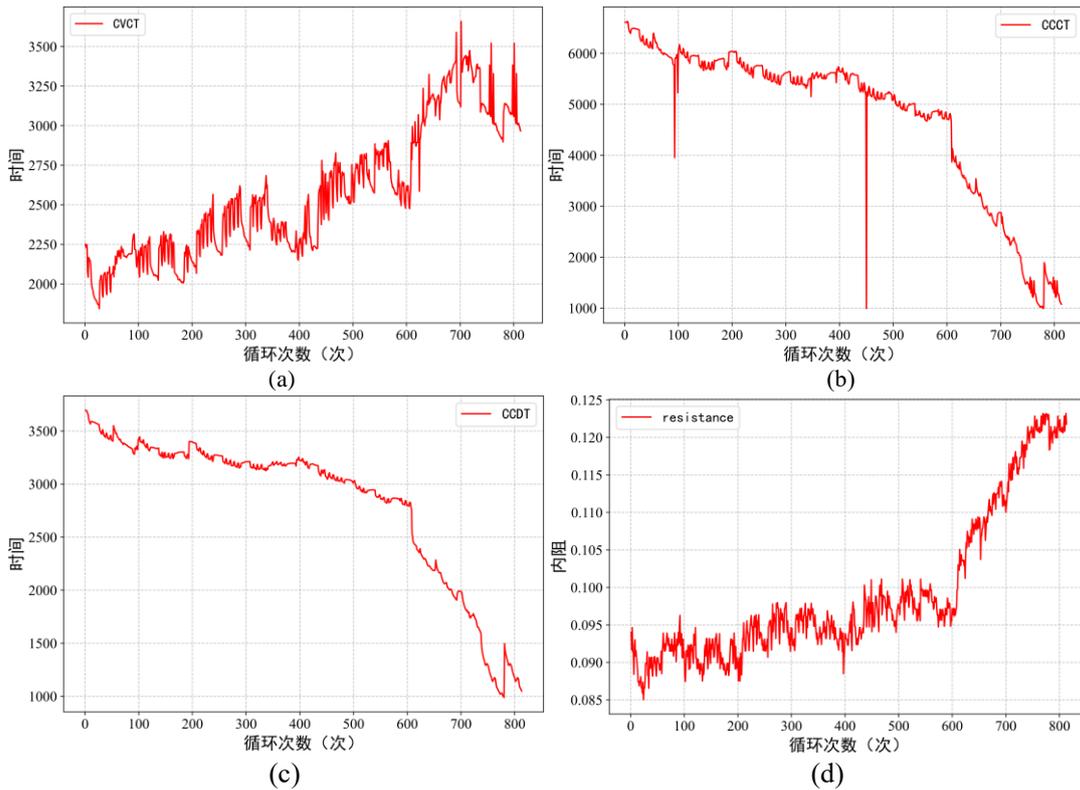


图 6 提取 CS2\_35 锂电池健康特征

Fig. 6 Extracting CS2\_35 Lithium Battery Health Characteristics

恒压充电时间(CVCT): 从图 6(a)中可以看出，随着充放电循环次数的增加，恒压充电时间逐渐减小。将 CVCT 作为健康特征，即为 HF1。

恒流充电时间(CCCT): 如图 6(b)所示，恒流充电时间随着充放电次数的增加而逐渐减少，记为 HF2。

恒流放电时间(CCDT): 如图 6(c)所示，恒流放电时间随着充放电次数增加而减少，记为 HF3。

内阻(resistance): 如图 6(d)所示, 随着充放电循环次数的增加, 电池的平均内阻呈现逐渐增大的趋势, 由于内阻在实际中不易测得, 故不将内阻作为健康特征。

使用皮尔逊相关系数分析健康特征与容量的相关度如表 1 所示。

表 1 使用皮尔逊相关系数分析健康特征与容量的相关度

Table 1 Using Pearson's correlation coefficient to analyze the correlation between health characteristics and capacity

健康特	HF1	HF2	HF3
皮尔逊相关系	-0.790442	0.987776	0.999961

从表中可以看出 HF1 与容量有较强的负相关性, HF2 和 HF3 与容量有较强的正相关性, 故将提取的三种健康特征作为所提方法的输入。

## 4 实验

本实验采用 64 位 Window 11 操作系统, 算法基于 python3.8 和 tensorflow2.9 进行开发。

由于锂电池的 SOH 和电池容量相关, 故本实验对电池容量进行预测。将实验数据按照样本数、时间步长、特征维度的方式进行重新排列, 本实验中样本数为每次放入网络中的批大小, 时间步长为 1, 对当前时刻的一个健康状态进行估计, 输入特征为 3 个健康特征, 维度为 3 维。输出为当前时刻的容量。

使用 CPO 算法对所提 IBiTCN-SE-LSTM 方法的 IBiTCN 隐藏层层数、IBiTCN 卷积核大小、IBiTCN 残差块数量、IBiTCN Dropout 等超参数进行优化, 具体参数设置如表 2 所示。CPO 算法种群数目设置为 20, 迭代次数为 30。为了防止过拟合, 将 CS2\_35 号电池的前 70% 数据作为训练数据, 其余部分作为验证数据, 并以决定系数 (R2) 作为目标函数进行优化。

表 2 待优化的 IBiTCN-SE-LSTM 算法的超参数范围

Table 2 Hyperparameter range of the IBiTCN-SE-LSTM algorithm to be optimized

优化参数名称	优化参数范围
IBiTCN 隐藏层层数	[10,128]
IBiTCN 卷积核大小	[1,5]
IBiTCN 残差块数量	[1,7]
IBiTCN Dropout	[0,0.5]
LSTM 隐藏层层数	[10,128]
学习率	[0.001,0.11]
训练轮数	[100,1000]
批大小	8,16,32

使用 CPO 优化得到的最优参数: IBiTCN 隐藏层层数为 40, 卷积核大小为 2, 残差块数量为 1, Dropout 为 0.011, LSTM 隐藏层层数为 51, 学习率为 0.0081, 训练轮数为 400, 批大小为 32。保存最优模型。

将所提算法与 TCN、BiTCN、LSTM、IBiTCN 算法进行对比, TCN、BiTCN、IBiTCN 的隐藏层层数设为 40, LSTM 的隐藏层层数设为 51, 训练轮数为 400, 优化器为 Adam, 学习率为 0.011, 训练数据均为 CS2\_35 电池总数据的 70%。对比实验结果如图 6 所示, 虚线为预测起点, 为 40% 的数据点处。

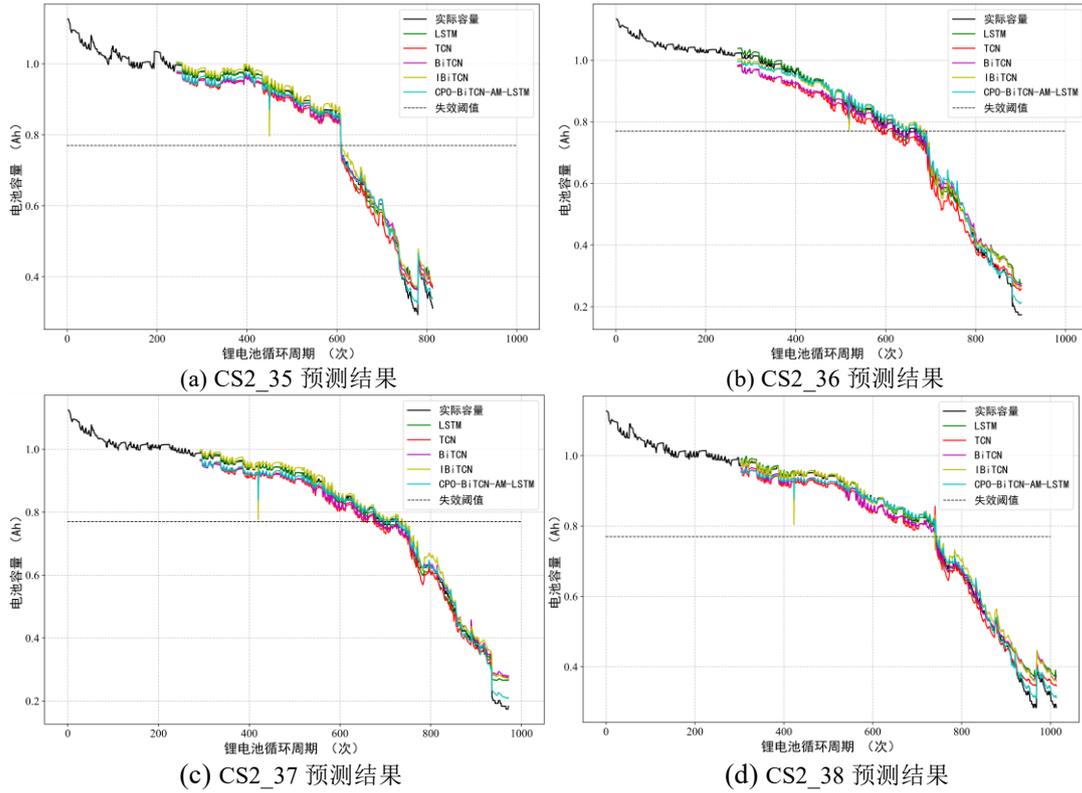


图7 不同算法在CALCE锂电池数据集的SOH预测结果

Fig. 7 SOH prediction results of different algorithms on the CALCE lithium battery dataset

从图7中可以看出提出的算法更加贴合原始容量曲线。为了进一步对比几种算法的预测精度，计算神经网络输出的预测结果与真实容量值之间的均方根误差（Root Mean Square Error, RMSE）、平均绝对误差（Mean Absolute Error, MAE）和决定系数（R-Square, R<sup>2</sup>），这些评价指标的计算公式如下。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (C_i - \hat{C}_i)^2} \quad (12)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |C_i - \hat{C}_i| \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (C_i - \hat{C}_i)^2}{\sum_{i=1}^N (C_i - \bar{C})^2} \quad (14)$$

其中  $C$  代表电池容量的实际值， $\hat{C}$  代表电池容量的预测值， $\bar{C}$  代表实际电池容量的均值。

使用不同算法预测四种电池的SOH的评价指标如表3所示。

表3 不同算法在CALCE锂电池数据集的评价指标

Table 3 Evaluation metrics of different algorithms on the CALCE lithium battery dataset

电池	算法	RMSE	MAE	R2
CS2_35	CPO-IBiTCN-SE-LSTM	<b>0.0181</b>	<b>0.0157</b>	<b>0.9965</b>
	IBiTCN	0.0313	0.0220	0.9804
	BiTCN	0.0327	0.0284	0.9886
	TCN	0.0350	0.0329	0.9840
	LSTM	0.0270	0.0155	0.9922
CS2_36	CPO-IBiTCN-SE-LSTM	<b>0.0198</b>	<b>0.0167</b>	<b>0.9951</b>
	IBiTCN	0.0288	0.0205	0.9897

	BiTCN	0.0386	0.0320	0.9814
	TCN	0.0453	0.0424	0.9744
	LSTM	0.0299	0.0182	0.9889
	CPO-IBiTCN-SE-LSTM	<b>0.0185</b>	<b>0.0147</b>	<b>0.9957</b>
	IBiTCN	0.0330	0.0221	0.9863
CS2_37	BiTCN	0.0363	0.0283	0.9834
	TCN	0.0393	0.0338	0.9805
	LSTM	0.0260	0.0150	0.9915
	CPO-IBiTCN-SE-LSTM	<b>0.0199</b>	<b>0.0164</b>	<b>0.9959</b>
	IBiTCN	0.0364	0.0220	0.9861
CS2_38	BiTCN	0.0406	0.0324	0.9831
	TCN	0.0385	0.0359	0.9850
	LSTM	0.0377	0.0210	0.9855

从表中可以看出所提出的 CPO-IBiTCN-SE-LSTM 方法的三种评价指标均优于其它的深度学习方法, 在所有电池的 RMSE 均不超过 0.020, MAE 不超过 0.017, R2 在 0.995 以上, IBiTCN 方法对比 BiTCN 方法, 预测精度有一定提高, RMSE 降低了 0.005-0.01, 说明对 BiTCN 方法的改进是有效果的, 且 IBiTCN 的参数更少。

## 5 结论

本文提出一种基于 IBiTCN-SE-LSTM 的锂电池健康状态预测方法, 并使用 CPO 对所提算法的超参数进行寻优。在 CALCE 锂电池数据集中进行实验, 使用皮尔逊相关系数提取与容量相关性高的健康特征作为算法的输入。将所提方法与 IBiTCN、BiTCN、TCN 和 LSTM 方法进行对比实验, 所提方法的预测结果与原始值更加接近, 在四个电池的预测结果均优于其他方法, RMSE 较其他方法降低了 0.0089-0.0255, R2 提高了 0.0043-0.207, 说明所提方法可以更准确的预测锂电池健康状态。然而, 目前研究主要集中于单体电池的单一工况下进行的 SOH 预测, 未来工作将致力于开发多种工况下的电池组的 SOH 预测, 实现更广泛的应用。

## 参考文献

- [1] Cui J, Zhao J, Cui X, et al. Remaining useful life prediction of aviation lithium-ion battery based on SVR-MC[C]//2022 34th Chinese Control and Decision Conference (CCDC). IEEE, 2022: 505-510.
- [2] 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, PP(99):1-1. DOI:10.1109/ACCESS.2020.2981261.
- [3] 孙冬, 许爽. 梯次利用锂电池健康状态预测 [J]. 电工技术学报, 2018, 33(09): 2121-2129. DOI:10.19595/j.cnki.1000-6753.tces.170107.  
Sun D, Xu S. State of Health Prediction of Second-Use Lithium-Ion Battery [J]. Transactions of China Electrotechnical Society, 2018, 33(09): 2121-2129. DOI: 10.19595/j.cnki.1000-6753.tces.170107.
- [4] Miniguano H, Raga C, Barrado A, et al. A comparative study and parameterization of electrical battery models applied to hybrid electric vehicles[C]//2016 International Conference on Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles & International Transportation Electrification Conference (ESARS-ITEC). IEEE, 2016. DOI:10.1109/ESARS-ITEC.

---

2016. 7841345.

[5] 郭海龙,杨康,吉龙军,等.基于注意力机制的改进 LSTM 锂电池健康状态估计方法[J].三峡大学学报(自然科学版),2023,45(04):95-100.DOI:10.13393/j.cnki.issn.1672-948x.2023.04.015.

Guo HL, Yang K, Ji LJ, et al. Method of Improved LSTM Lithium Battery Health Estimation Based on Attention Mechanism[J]. Journal of China Three Gorges University(Natural Sciences), 2023,45(04):95-100.DOI:10.13393/j.cnki.issn.1672-948x.2023.04.015.

[6] 刘丹,王瑞虎,吕伟,等.基于 IPSO-LSTM 的新能源汽车锂电池健康状态监测[J].中国安全科学学报,2023,33(09):94-102.DOI:10.16265/j.cnki.issn1003-3033.2023.09.1250.

Liu D, Wang RH, Lv W, et al. SOH monitoring of new energy vehicle lithium batteries based on IPSO-LSTM [J], China Safety Science Journal, 2023, 33(09):94-102.DOI:10.16265/j.cnki.issn 1003- 3033.2023.09.1250.

[7] 刘少卿,李帅,苗建国,等.基于 TCN-BiGRU 的锂离子电池健康状态评估[J].电子测量技术,2023,46(23):68-76.DOI:10.19651/j.cnki.emt.2313745.

Liu SC, Li S, Miao JG, et al. Lithium-ion battery state of health estimation based on TCN-BiGRU [J]. Electronic Measurement Technology, 2023, 46(23): 68-76. DOI: 10. 19651 /j.cnki.emt. 2313745.

[8] Li Q , Li D , Zhao K ,et al.State of health estimation of lithium-ion battery based on improved ant lion optimization and support vector regression[J].Journal of Energy Storage, 2022.DOI:10.1016/j.est.2022.104215.

[9] Tang J, Liu G, Pan Q. A review on representative swarm intelligence algorithms for solving optimization problems: Applications and trends[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(10): 1627-1643.

[10] Mohamed A ,Reda M ,Mohamed A . Crested Porcupine Optimizer: A new nature-inspired metaheuristic[J]. Knowledge-Based Systems,2024,284.

[11] Wu C , Wu F , Qi T ,et al.Fastformer: Additive Attention Can Be All You Need[J]. 2021.DOI:10.48550/arXiv.2108.09084.

[12] Bai S, Kolter JZ, and Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. arxiv preprint arxiv, 2018:1803.01271.

[13] Jingyi G ,Dongfang Y ,Shi W , et al. State of health estimation of lithium-ion batteries based on Mixers-bidirectional temporal convolutional neural network[J]. Journal of Energy Storage,2023,73(PD).

[14] 刘业峰,王帅,刘晶晶,等.基于 TCN-SA 和 Bi-GRU 的轴承剩余寿命预测[J/OL].计算机集成制造系统,1-11[2024-09-15].<https://doi.org/10.13196/j.cims.2024.0260>.

Liu YF, Wang S, Liu JJ, et al. Bearing remaining life prediction based on TCN-SA and Bi-GRU [J/OL]. Computer Integrated Manufacturing Systems, 2019: 1-11.

[15] Lijun Z ,Tuo J ,Shihao Y , et al. Accurate Prediction Approach of SOH for Lithium-Ion Batteries Based on LSTM Method[J]. Batteries,2023,9(3).

[16] Hu J , Shen L , Sun G ,et al.Squeeze-and-Excitation Networks[J].IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, PP(99).DOI:10.1109/TPAMI.2019.2913372.

[17] Zhu Z, Yang Q, Liu X, et al. Attention-based CNN-BiLSTM for SOH and RUL estimation of lithium-ion batteries. Journal of Algorithms & Computational Technology, 2022. DOI: 10.1177/17483026221130598.

[18] Lijun Z ,Tuo J ,Shihao Y , et al. Accurate Prediction Approach of SOH for Lithium-Ion Batteries Based on LSTM Method[J]. Batteries,2023,9(3).