

DOI:10.19651/j.cnki.emt.2415653

# 基于 ISSA-CNN-BiGRU-Attention 的 锂电池健康状态评估\*

陈新岗<sup>1,2</sup> 赵龙<sup>1</sup> 马志鹏<sup>1,2</sup> 李松<sup>1</sup> 张知先<sup>1</sup>

(1.重庆理工大学电气与电子工程学院 重庆 400054; 2.重庆市能源互联网工程技术研究中心 重庆 400054)

**摘要:** 健康状态(SOH)预测对于电池管理系统至关重要。针对电池健康状态评估建模复杂、预测误差大等问题,准确的 SOH 预测仍需要改进。本文结合容量增量分析(ICA)和差分电压分析(DVA)方法,提出了一种改进麻雀优化算法(ISSA)-卷积神经网络(CNN)-双向门控递归单元(BiGRU)-注意力机制(Attention)的锂电池健康状态评估方法。通过对容量增量(IC)曲线和差分电压(DV)曲线进行高斯滤波处理,避免了噪声的影响。通过马里兰大学先进的生命周期工程中心(CALCE)数据进行处理,从滤波后的 IC 和 DV 曲线上提取一组新的电池老化特征,所提 4 个老化特征与 SOH 之间的 Pearson 相关系数在 0.9 以上。使用 ISSA-CNN-BiGRU-Attention 方法来构建电池 SOH 的预测模型,将所提方法与 CNN、BiGRU、CNN-BiGRU 等方法进行比较,实验结果表明,该方法的 MAE 与 RMSE 误差最大值分别为 0.005 44 和 0.007 17,对比其他模型,具有优秀的鲁棒性和准确性,具有更好的实际使用价值。

**关键词:** 锂离子电池;SOH;容量增量分析;差分电压分析;CNN;BiGRU

**中图分类号:** TM912;TN98 **文献标识码:** A **国家标准学科分类代码:** 530.4130

## State of health assessment of lithium batteries based on ISSA-CNN-BiGRU-Attention

Chen Xingang<sup>1,2</sup> Zhao Long<sup>1</sup> Ma Zhipeng<sup>1,2</sup> Li Song<sup>1</sup> Zhang Zhixian<sup>1</sup>

(1. School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China;

2. Chongqing Engineering Research Center of Energy Interconnection, Chongqing 400054, China)

**Abstract:** State of health (SOH) predictions are critical for battery management systems. Due to the complexity of battery health assessment modeling and large prediction errors, accurate SOH prediction still needs to be improved. In this paper, Improved sparrow search algorithm (ISSA)-Convolutional neural network (CNN)-Bidirectional Gated Recurrent Unit (BiGRU)-Attention mechanism for lithium battery health status assessment is proposed by combining capacity increment analysis (ICA) and differential voltage analysis (DVA) methods. Firstly, the capacity increment (IC) curve and differential voltage (DV) curve are processed by Gaussian filtering to avoid the influence of noise. A set of new battery aging features were extracted from the filtered IC and DV curves through the center for advanced life cycle engineering Advanced Life Cycle Engineering (CALCE) data processing. The Pearson correlation coefficient between the four aging features and SOH was above 0.9. ISSA-CNN-BiGRU-Attention method was used to construct a prediction model of battery SOH, and the proposed method was compared with CNN, BiGRU, CNN-BiGRU and other methods. Experimental results showed that the maximum MAE and RMSE errors of the proposed method were 0.005 44 and 0.007 17, respectively. Compared with other models, it has excellent robustness and accuracy, and has better practical use value.

**Keywords:** lithium-ion battery; SOH; incremental capacity analysis; differential voltage analysis; CNN; BiGRU

## 0 引言

锂离子电池由于其具有充电速度快、能量密度高、循环

寿命长、无记忆效应等优点,已被广泛应用于电子、电动汽车和储能系统等领域<sup>[1]</sup>。对于锂电池来说,安全性和可靠性在使用过程中非常重要,作为锂离子电池管理系统(battery

收稿日期:2024-03-18

\* 基金项目:重庆市自然科学基金(CSTB2023NSCQ-MSX0337)、重庆市教育委员会科学技术研究项目(KJZD-K202101103)、重庆理工大学研究生教育高质量发展项目(gzlcx20233151)资助

management system, BMS)的重要组成部分,健康状态(state of health, SOH)反映了锂离子电池的老化和损坏情况,因此,有效的健康状态监控直接影响了系统的性能<sup>[2]</sup>。

目前,这些方法被分为两大类,基于机理模型和基于数据驱动的方法<sup>[3]</sup>。基于机理模型的方法旨在通过分析电池内部的反映机理,建立一个复杂的老化机理模型来描述电池的退化现象<sup>[4-7]</sup>。赵月荷等<sup>[4]</sup>提出建立基于二阶 RC 电路模型的分阶电池模型,结合遗传算法和卡尔曼滤波进行参数更新与 SOH 估算,常春等<sup>[5]</sup>提出了一种基于阻抗谱中频部分等效电路模型的锂离子电池健康状态估计方法,只选用阻抗谱中频部分作为模型的搭建基础,基于固体电解质界面(solid electrolyte interphase, SEI)电阻估计电池容量。Bartlett 等<sup>[6]</sup>提出将复合电极电池的降阶电化学模型应用于双观测器算法用以估计容量,Xiong 等<sup>[7]</sup>提出一种基于分数阶阻抗模型的退化行为识别方法,但锂离子电池机理复杂,一直难以建立准确的预测模型。

数据驱动的方法由于不需要建立复杂的化学模型,仅依靠历史老化数据来描述锂离子电池的老化过程而备受关注<sup>[8]</sup>。支持向量机(support vector machine, SVM)<sup>[9]</sup>,高斯回归过程(gaussian process regression, GPR)<sup>[10]</sup>和人工神经网络<sup>[11]</sup>是常用的数据驱动方法。锂电池 SOH 的预测可分为直接预测和间接预测,直接预测法必须通过历史容量数据建立模型,但容量再生往往会影响模型的预测效果,因此,一些研究者用间接特征来代替容量数据,包括电流、电压和温度等。近年来,循环神经网络(recurrent neural network, RNN)、长短期记忆神经网络(long short-term memory, LSTM)和门控循环单元神经网络由于其在时间序列预测中的优势,在电池 SOH 预测中受到越来越多的关注。You 等<sup>[12]</sup>在工作中使用了 RNN 模型对锂离子电池 SOH 的健康状态评估。由于传统的 RNN 在训练过程中存在梯度消失和扩张问题,在实际应用中很难处理长期依赖性问题。王庭华等<sup>[13]</sup>通过使用电流、电压作为健康特征,通过 LSTM 映射健康因子(health indicator, HI)与 SOH 的关系,然而单一的 LSTM 忽略了反向信息的影响,随着时间序列长度的增加,预测精度会响应降低。毛百海等<sup>[14]</sup>使用 LSTM&GRU-Attention 模型对输入的健康特征进行了深度挖掘,实现了更准确的锂电池 SOH 估计。叶震等<sup>[15]</sup>改进了上述问题,使用电流、电压作为 HI,并结合 SE-SAE 特征融合和双向长短期记忆神经网络(BiGRU)来实现 SOH 预测。刘少卿等<sup>[16]</sup>提出了一种基于 TCN-BiGRU 网络的锂电池健康状态评估方法,实现了锂电池 SOH 的准确评估,预测模型相较于单一模型具有更高的拟合度和准确性。除了通过分析直接可测量的参数来获得特征之外,还可以通过转换电压曲线来提取特征,容量增量和差分电压曲线随电池老化衰退的变化反映了电池动力学与热力学特征的变化<sup>[17]</sup>。

上述方法仍然存在健康因子提取和预测模型的问题,

为此,本文提出了容量增量分析(incremental capacity analysis, ICA)和差分电压分析(differential voltage analysis, DVA)的锂电池特征提取方法,由 IC 曲线和 DV 曲线分析其老化特征,并提取出一组新的健康因子,运用 Person 相关性判别健康因子与容量的相关性程度,运用改进麻雀优化算法(improved sparrow search algorithm, ISSA)对神经网络模型对隐藏层节点数,初始学习率和正则化系数进行优化,结合卷积神经网络(convolutional neural network, CNN)的特征提取能力与时间注意力机制的双向门控递归单元(bidirectional gated recurrent unit, BiGRU)的预测模型,不仅考虑了序列的反向信息,而且突出了关键特征的影响,实现电池 SOH 的预测,进一步提高了 SOH 评估的准确性与可靠性。

## 1 电池老化数据与健康因子提取

### 1.1 电池老化数据集介绍

电池数据集来源于马里兰大学高级生命周期工程中心(CALCE),并在室温(25 °C)下使用 Arbin BT2000 测试设备进行测试<sup>[18]</sup>。这些电池被标记为 CS35、CS36、CS37、CS38。电池的阴极为 LiCoO<sub>2</sub>,额定容量为 1.1 Ah。所有电池都包括恒流(CC)、恒压(CV)充电和恒流放电过程。充放电操作的具体参数设置如表 1 所示,不同电池的 SOH 衰减曲线如图 1 所示。根据锂电池的充放电循环使用过程,当 CALCE 电池测得的容量分别下降到初始容量的 80%时,认为电池以达到寿命终止(EOL)。

表 1 实验电池数据集充放电阶段具体参数

参数	数值
充电截至电压	4.2 V
放电截至电压	2.7 V
充电电流	0.5 C
放电电流	1 C
温度	25 °C
额定容量	1.1 Ah




图 1 马里兰大学 SOH 衰减轨迹

## 1.2 容量增量和差分电压原理

容量增量分析(ICA)<sup>[19]</sup>和差分电压分析(DVA)<sup>[20]</sup>可以分析电池的老化机理,通过利用曲线的波峰和波谷,提取电池老化信息作为健康指标,进行 SOH 预测。如式(1)所示,ICA 的方法可以将电压曲线中的电压平台转换为 IC 曲线上的清晰可辨的峰值。

$$dQ/dV \approx \Delta Q/\Delta V \quad (1)$$

如式(2)所示,DVA 曲线可以将电压曲线上的电压平台转换为 DV 曲线的峰谷。

$$dV/dQ \approx \Delta V/\Delta Q \quad (2)$$

可以通过 IC 和 DV 曲线的变化来分析电池的退化状况:IC 曲线中峰高和峰面积的减小,并向高电压偏移。DV 曲线中峰谷的减小,并且向低容量偏移。电池的退化模式通常分为 3 类:电导率的损失(CL),活性材料损失(LAM)和锂离子库存损失(LLI)<sup>[21]</sup>。在充电过程中,峰高或者峰面积的减小可以反应 LAM 这一现象。出现 LLI 的情况,其表现为 IC 曲线的峰值降低并向高电压移动,DV 曲线向低容量移动。由上所述,锂电池的老化信息可以由 IC/DV 曲线中每个峰值特性反应出来。包括 IC 曲线中的峰值、峰值位置(对应于峰值的电压)、峰值面积(两个电压区间之间的电池容量差值),如式(3)所示。DV 曲线中的峰值可以将曲线划分为几个区域。每个区域对应于反应中相变的容量(Q<sub>i</sub>)。

$$Area = \int_{u_1}^{u_2} ICA(u) du = \int_{u_1}^{u_2} \frac{dQ(u)}{du} du = Q(u_2) - Q(u_1) \quad (3)$$

## 1.3 基于 IC/DV 曲线的老化分析和特征提取

通过电池恒流充电工况下的端电压-容量数据,在实验过程中,由于测量中噪声的存在,为了降低 IC/DV 曲线的噪声,对曲线采用了高斯滤波处理的方法<sup>[22]</sup>,对于滤波器中的参数设置,其中滤波器半径  $r=20$ ,标准差  $\sigma=5$ 。再通过式(1)和(2)获得 IC 和 DV 曲线。图 2 中的 IC 曲线的峰值和图 3 中 DV 曲线的峰谷分别随着循环次数的增多向着高电压和低容量移动。Wu 等<sup>[23]</sup>研究指出,出现此现象的原因可能与 LLI 有关,结果表明,CS35 电池的退化模式最有可能为 LLI。

如图 2 和 3 所示,由充电过程中 IC/DV 曲线的波峰和波谷的变化分析了电池的退化模式。可见,峰谷的高度、位置和形状是电池老化的重要指标。由此可以由 IC 和 DV 曲线中提取健康特征来间接表示电池的老化。在 IC 曲线中,峰高、峰位置和峰面积随电池老化而增大或者减小,可以选择这几个指标来描述其与 SOH 的关系。在 DV 曲线中,Q1 和 Q2 区域对应于反应中的阶段的转变。因此,Q1 和 Q2 与锂离子电池老化之间的映射关系可用于 SOH 估计。

## 1.4 特征参数的关联性分析

基于以上 IC 和 DV 曲线分析分别提取 IC 曲线中的峰高、峰位置、峰面积及 DV 曲线中 Q1 和 Q2 等 5 个特征量,




图 2 不同周期的 IC 曲线




图 3 不同周期的 DV 曲线

分别表示为 H1~5。两个序列数据随时间或不同变量而变化的关联性大小称为关联度。Pearson 相关系数分析能够实现动态系统特征量的变化趋势,定量分析特征参数与 SOH 的相关性系数。其计算公式如下:

$$\rho_{X,Y} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)} \sqrt{E(Y^2) - E^2(Y)}} \quad (4)$$

式中: $X$  和  $Y$  分别表示特征参数序列与 SOH 序列。 $\rho_{X,Y}$  表示二者之间的相关性系数,相关性系数越大,表明两个变量之间的相关性就越强。

从表 2 的结果可以看出,本文所提取的特征与 SOH 具有较高的线性相关性,特征量 H4 的相关性在 0.83 左右,但低于其余 4 个特征量,故在本研究中,为了获得具有更高准确性和鲁棒性的 SOH 预测,本文基于 IC/DV 曲线提取峰高、峰位置、峰面积和 Q2 作为健康因子来用于模型的训练和测试。

表 2 不同特征量与 SOH 之间的 Pearson 相关系数

电池编号	H1	H2	H3	H4	H5
CS35	0.944 2	0.932 2	0.991 9	0.836 7	0.989 4
CS36	0.946 6	0.958 2	0.995 7	0.846 3	0.986 6
CS37	0.941 8	0.958 8	0.993 7	0.832 5	0.981 7
CS38	0.951 6	0.955 9	0.997 3	0.843 6	0.991 2

## 2 锂电池健康状态预测方法

### 2.1 麻雀搜索算法

麻雀搜索算法 (SSA) 是由 Xue 等<sup>[24]</sup> 于 2020 年提出, 是一种模拟麻雀群的觅食行为与反捕食行为算法。相对于灰狼优化算法 (grey wolf optimizer, GWO)<sup>[25]</sup> 和粒子群优化算法 (particle swarm optimization, PSO)<sup>[26]</sup>, SSA 具有更高的精度、更强的收敛性和更好的寻优能力。在麻雀群里面, 包括发现者、跟随者和反捕食。其中, 发现者的位置更新如下:

$$X_{i,j}^{t+1} \begin{cases} X_{i,j}^t \times \exp\left(\frac{-i}{\alpha \cdot M_{iter}}\right), & R < T \\ X_{i,j}^t + Q \cdot L, & R \geq T \end{cases} \quad (5)$$

式中:  $t$  为当前迭代次数,  $M_{itera}$  为最大迭代次数,  $\alpha$  为  $(0, 1]$  的随机数,  $Q$  为服从正太分布的随机数;  $L$  为元素均为 1 的  $1 \times d$  维矩阵,  $T$  为阈值,  $R \in [0, 1]$  为预警值随机数。加入者的位置更新如下:

$$X_{i,j}^{t+1} \begin{cases} Q \cdot \exp\left(\frac{X_{worst}^t}{i^2}\right), & i < \frac{N}{2} \\ X_{best}^{t+1} + |X_{i,j}^t - X_{best}^{t+1}| \cdot A^+ \cdot L, & i \leq \frac{N}{2} \end{cases} \quad (6)$$

式中:  $X_{worst}^t$  为麻雀最劣位置,  $X_{best}^{t+1}$  为麻雀  $t+1$  次最优位置,  $A$  为  $1 \times d$  维矩阵,  $N$  为种群数量。

反捕食者的位置更新如下:

$$X_{i,j}^{t+1} \begin{cases} X_{best}^t + \beta \cdot |X_{i,j}^t - X_{best}^t|, & f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{worst}^t|}{(f_i - f_w) + \epsilon}\right), & f_i = f_g \end{cases} \quad (7)$$

式中:  $\beta$  为服从均值为 0、方差为 1 的正态分布的随机数,  $K$  为  $[-1, 1]$  的随机数, 正负表示麻雀移动方向, 大小表示步长控制参数,  $f_i$  为当前个体的适应度值,  $f_g$  为当前最大适应度值,  $f_w$  为当前最小适应度值。为避免分母为 0, 引入  $\epsilon$  为一个接近 0 的常数。

### 2.2 改进麻雀搜索算法

由于麻雀搜索算法在优化过程中存在个体麻雀的搜索速度和收敛精度问题, 本文在发现阶段采用自适应权值和 Levy 飞行策略以减少个体陷入局部最优的可能性。

1) 向发现者引入自适应权重

本文在麻雀优化的发现者阶段增加一个随迭代次数变化的惯性权重  $\omega$ , 在算法的初始阶段, 减弱随机初始化的影响, 从而增强算法的局部搜索和全局搜索能力。使其个体能够更快地收敛到最优位置, 总体上加快了收敛速度, 自适应权重的计算公式如下:

$$\omega(t) = 0.2 \cos\left(\frac{\pi}{2} \cdot \left(1 - \frac{t}{M_{iter}}\right)\right) \quad (8)$$

其中,  $\omega$  具有在  $[0, 1]$  之间非线性变化的性质。根据  $\cos$  函数的特点, 算法初始时权值较小, 但寻优速度较快, 后期权值较大, 但变化速度较慢, 从而均衡了算法的收敛

性。改进的发现者位置更新如下:

$$X_{i,j}^{t+1} \begin{cases} \omega(t) \cdot X_{i,j}^t \times \exp\left(\frac{-i}{\alpha \cdot M_{iter}}\right), & R < T \\ \omega(t) \cdot X_{i,j}^t + Q \cdot L, & R \geq T \end{cases} \quad (9)$$

2) Levy 飞行策略

引入 Levy 飞行策略, 提高算法解的随机性, 从而丰富种群位置的多样性, 可以有效提高算法运行效率。

$$\begin{aligned} Levy &= \frac{\mu}{|\nu|^{1/\gamma}} \\ \mu &\sim N(0, \sigma_\mu^2) \\ \nu &\sim N(0, \sigma_\nu^2) \\ \sigma_\mu &= \left\{ \frac{\Gamma(1+\gamma) \sin(\pi\gamma/2)}{\gamma \cdot \Gamma[(\gamma+1)/2] \cdot 2^{\gamma+1/2}} \right\}^{1/\gamma} \end{aligned} \quad (10)$$

式中:  $\sigma_\nu = 1$ ,  $\gamma$  一般为 1.5。Levy 飞行策略的引入使得麻雀在这个阶段更加灵活, 也可以带领其他个体找到更好的位置, 利用 ISSA 算法对 CNN-BiGRU 模型的超参数进行寻优, 以提高 CNN-BiGRU 模型预测时的精准度与平稳性。利用马里兰大学先进的生命周期工程中心 (CALCE) 电池实验数据, 对 ISSA 算法的有效性进行验证, 并与 PSO、GWO、SSA 进行对比分析。优化过程参数设置为: 麻雀种群数量 30 只, 最大迭代次数为 500 次。其结果如图 4 所示。




图 4 ISSA 与 PSO、GWO、SSA 迭代曲线图

由图 4 可知, 随着迭代次数的不断增加, ISSA 算法相比于其另外 3 种, 其适应度值在更短的时间内趋于稳定, 说明 ISSA 算法的寻优速率高于 PSO、GWO、SSA。本文选取最佳隐藏层节点数、最佳初始学习率和最佳 L2 正则化系数。

### 2.3 卷积神经网络

作为神经网络中的关键架构之一, CNN 以其出色的特征提取能力在图像处理中得到广泛应用。与传统的多层感知机相比, CNN 的卷积层通过权值共享显著减少了训练参数, 从而降低了网络复杂度, 有效减轻了过拟合风险<sup>[27]</sup>。如图 5 所示, CNN 的主要组成部分包括卷积层和池化层。

卷积层通过卷积核提取数据特征,而池化层则对卷积层提取的特征进行压缩,从而降低计算负担。




图 5 CNN 结构图

## 2.4 双向门控循环单元

门控循环单元(gated recurrent unit, GRU)是一种循环神经网络(RNN)的变体,设计用于更好地处理序列数据中的长期依赖关系,并防止梯度消失问题,如图 6 所示,给出了 BiGRU 的结构图。GRU 引入了更新门和重置门的概念,这些门允许网络选择性地更新内部状态,并控制信息的传递。GRU 的网络结构表示如下:

重置门(reset gate)在门控循环单元(GRU)中的作用是控制过去隐藏状态对当前时间步输入的影响程度。通过调整重置门的输出,网络可以选择性地遗忘过去的信息,从而灵活地处理序列中的长期依赖关系。重置门的计算公式如下:

$$r_t = \sigma(W_r x_t + U_r h_{t-1}) \quad (11)$$

式中:  $r_t$  是重置门的输出,  $\sigma$  是 *sigmodi* 激活函数,  $W_r$  和  $U_r$  是相应的权重矩阵,  $x_t$  是当前时间步的输入,是过去的隐藏状态。

更新门(update gate)在门控循环单元(GRU)中的作用是控制过去的隐藏状态对当前时间步输入的记忆程度。通过调整更新门的输出,网络可以选择性地保留或遗忘过去的信息,从而适应不同的序列模式。更新门的计算公式如下:

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (12)$$

其中,  $z_t$  是更新门的输出,  $\sigma$  是 *sigmodi* 激活函数,  $W_z$  和  $U_z$  是相应的权重矩阵,  $x_t$  是当前时间步的输入,是过去的隐藏状态。

有效的健康状态预测模型需要提取序列数据中的隐含特征和复杂变化, BiGRU 结构由一个正向和一个反向 GRU 组成,隐含层结合了正向信息和反向信息,使网络能够捕捉信息前后的特征,从而增加了特征信息的多样性, BiGRU 在时间  $t$  的隐藏层的状态可以通过前向隐藏层的状态和反向隐藏层来获得。前向隐藏层的状态由当前输入  $x_t$  和在时间  $t-1$  时的前向隐藏层的状态确定,后向隐藏层的状态由当前输入  $x_t$  和在时间  $t+1$  时的后向隐藏层的状态确定。BiGRU 可以表示为:

$$\vec{h}_t = f(w_1 x_t + w_2 \vec{h}_{t-1})$$

$$\overleftarrow{h}_t = f(w_3 x_t + w_4 \overleftarrow{h}_{t+1})$$

$$h_t = g(w_5 \vec{h}_t + w_6 \overleftarrow{h}_t)$$

(13)

式中:  $w_i$  是每层的权重。




图 6 BiGRU 结构图

## 2.5 时间注意力机制

基于神经网络的锂电池 SOH 预测,预测结果往往依赖于提取的特征。通过将特征输入 CNN-BiGRU 网络,可以得到 SOH 的预测值。但随着时间序列长度的增加,预测精度会响应降低。因此,通过在网络输出端加入时间注意力机制,可以得到不同序列对应的隐藏层状态权值,从而加强关键信息,弱化无用信息,提高模型的预测精度。本文选择点积形式来计算当前隐藏层状态的注意力权重,如式(14)所示。在获得注意力权重之后,使用 *softmax* 函数来获得注意力权重  $\alpha_i$  的归一化结果,如式(15)所示,最后注意力机制的最终输出特征  $Y$  由式(16)计算。

$$e_t = \tanh(Wh_t) \quad (14)$$

$$\alpha_t = \frac{\exp(e_t)}{\sum_{i=1}^n e_i} \quad (15)$$

$$Y = \sum_{i=1}^n \alpha_i h_i \quad (16)$$

## 2.6 ISSA-CNN-BiGRU-Attention 预测模型

如图 7 所示,显示了本文的整体框架结构,将 ICA 与 DVA 分析与 CNN-BiGRU 网络相结合,在数据处理阶段,需要消除噪声的影响,使用高斯滤波之后,从 ICA 与 DVA 曲线中,提取出一组能够反映电池老化的新的特征,将处理提取后的特征值带入网络模型之中,构建的 CNN-BiGRU 网络优化的超参数主要有隐藏层节点数、初始学习率与 L2 正则系数,将这 3 个超参数作为 ISSA 算法寻优的特征,即利用 ISSA 算法寻求这 3 个超参数的最优值。

基于 ISSA-CNN-BiGRU-Attention 模型的锂电池健康状态预测流程如下:

1) 数据处理。在电池老化数据采集过程中,不可避免地收到一些噪声干扰,会对 ICA 和 DVA 分析造成影响,因此,采用高斯滤波的方法对 IC/DV 曲线进行滤波处理,以减少特征提取时的噪声感染。

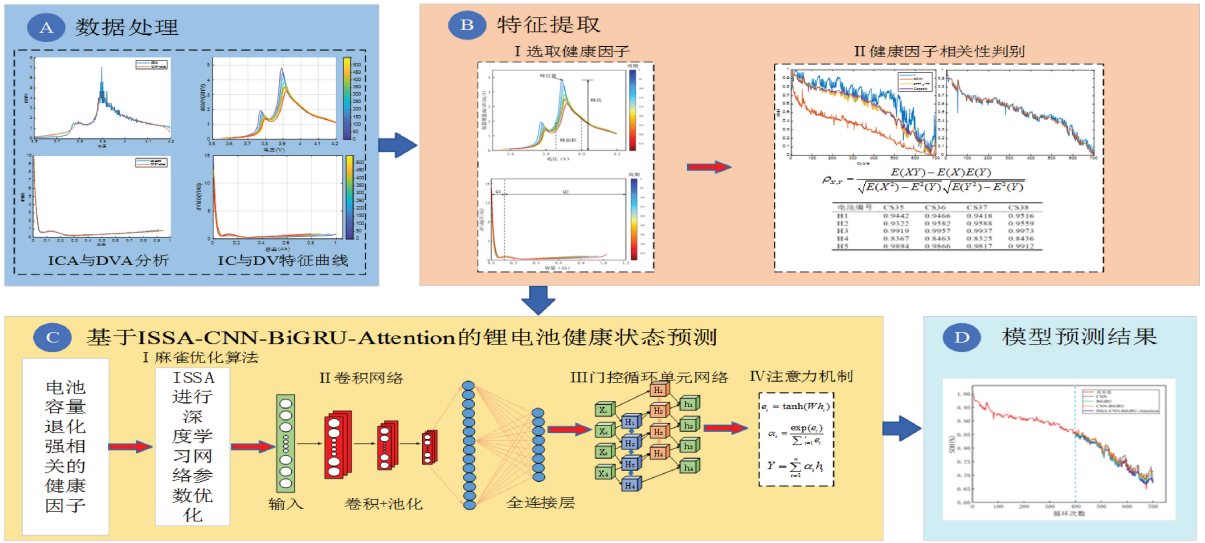


图 7 基于 ISSA-CNN-BiGRU-Attention 锂电池健康状态预测框架

2)特征提取。对 IC 和 DV 曲线进行了滤波处理之后,提取了峰值、峰值位置、峰面积和 Q2 作为表征电池老化的新特征组合。通过 Pearson 相关系数将特征提取结果进行了相关性判断。

3)模型建立。将 CNN-BiGRU 网络的隐藏层节点数、初始学习率和 L2 正则系数作为 ISSA 优化对象,利用 ISSA 算法对 LSTM 网络的 3 个超参数进行寻优,并将优化的后的参数与健康因子放入后续预测模型。

4)SOH 预测。建立基于注意力机制的 CNN-BiGRU 预测模型,将 4 种健康因子作为模型的输入,实现对 SOH 的预测。

### 3 SOH 预测结果对比

在模型训练过程中,最佳隐藏层节点数,最佳初始学习率,最佳 L2 正则化系数作为 ISSA 寻优对象,使用 Adam 求解器求解误差函数。以 37 号电池为例,ISSA 进行优化的结果分别为  $10, 1 \times 10^{-6}, 0.0039$ , 为了实现 SOH 预测,将峰值、峰值位置、峰面积、Q2, 4 个特征作为预测模型的输入,SOH 作为输出,从而建立特征与 SOH 之间的映射关系。选择老化特征的前 400 个循环来训练模型,剩余的 300 个循环用于测试。为了进行比较,将本文方法与 CNN、BiGRU、CNN-BiGRU 模型进行了比较,预测结果如图 7 所示。在表 3 中,使用 M1~4 分别代表 3 种比较模型与本文使用的 ISSA-CNN-BiGRU-Attention 模型做比较。本文采用平均绝对误差与均方根误差来说明模型的预测精度,其公式如下。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i^{\wedge} - y_i| \quad (17)$$


$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - y_i^{\wedge})^2} \quad (18)$$

由表 3 与图 8 所示的结果表明,使用 M4 模型相比与


其他 3 种网络模型,在所有的预测样本中 MAE 与 RMSE 都表现得更优。4 种电池的 RMSE 分别为 0.005 09、0.006 30、0.007 07、0.004 34,均小于其他预测模型的误差。这证明了 ISSA-CNN-BiGRU-Attention 模型在 SOH 预测中的优异性能。以 CS37 号电池为例,M4 模型的 MAE 误差值为 0.005 41,相比于 M3 模型误差值减少了 0.003 83,减少了 41.5% 的误差值,而 RMSE 误差值为 0.007 07,相比于 M3 模型误差值减少了 0.003 06,减少了 30.3% 的误差值。综上所述,M4 模型相比于 M1~3 模型,在鲁棒性和准确度上都有很高的提升,证明了 ISSA-CNN-BiGRU-Attention 模型在 SOH 预测中的优异性能。

表 3 使用不同 SOH 预测模型的性能比较

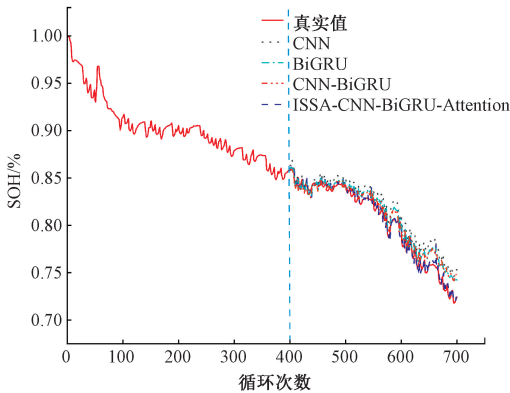
电池	模型	MAE	RMSE
CS35	M1	0.014 23	0.016 42
	M2	0.011 32	0.012 46
	M3	0.005 44	0.007 17
	M4	0.004 43	0.005 09
CS36	M1	0.012 67	0.013 47
	M2	0.010 45	0.013 63
	M3	0.007 26	0.008 47
	M4	0.005 44	0.006 30
CS37	M1	0.013 52	0.013 93
	M2	0.012 33	0.013 42
	M3	0.009 24	0.010 13
	M4	0.005 41	0.007 07
CS38	M1	0.011 24	0.012 73
	M2	0.009 21	0.010 22
	M3	0.006 22	0.006 64
	M4	0.004 03	0.004 34




(a) CS35电池结果对比图结构图



(b) CS36电池结果对比图结构图



(c) CS37电池结果对比图结构图



(d) CS38电池结果对比图结构图

图8 4组电池结果对比图结构图

为了更加直观地分析模型的检测效果,4种电池的平均结果如图9所示,CNN网络平均量结果,MAE值为0.012 92, RMSE值为0.014 14,对比其他模型其误差为最大。单CNN虽然较为简单,但只考虑了单方向的信息,忽略了时间序列较长时一些无用特征对预测结果的影响,相比之下M2和3模型分别考虑了序列的反向信息和突出关键特征的影响,预测结果有所改善。ISSA-CNN-BiGRU-Attention模型的平均绝对误差与均方根误差分别为0.004 83、0.005 7,由图9可以清晰的看出,对比其他模型,本文使用模型的精确度最高,由上述可以看出ISSA-CNN-BiGRU-Attention算法,不仅结合了CNN与BiGRU的优点,而且引入了参数寻优算法与注意力机制,提高了锂离子电池健康状态检测的精度,能够满足锂离子电池健康状态检测需求,具有较高的准确性和可靠性。

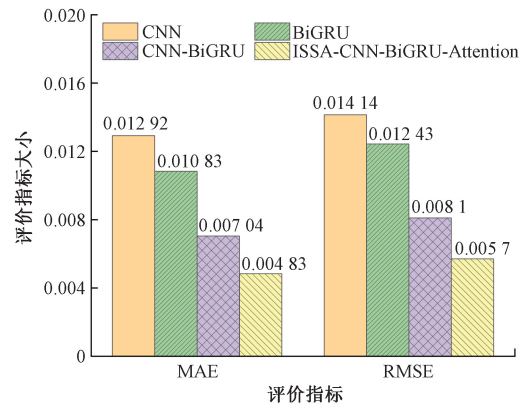


图9 模型性能比较平均结果

## 4 结 论

为了实现锂电池的高精度SOH预测,本文结合了ICA与DVA分析方法,将端电压曲线转换为IC/DV曲线,使电池老化更加直观,通过人工神经网络进行SOH预测,利用CALCE数据集验证了该方法的有效性。为了避免IC与DV曲线中噪声的干扰,采用高斯滤波的方法对IC/DV曲线进行了滤波处理,并且CALCE电池的MAE与RMSE仅在0.005 4和0.007 2以内,均低于3种对比网络的误差结果。从整形后的IC/DV曲线中提取了一组表征电池老化的新健康因子,包括峰高、峰位置、峰面积和Q2。实验结果表明,这4个健康因子与SOH之间的Person相关性都在0.9以上,所选4个健康特征与电池老化具有强相关性,能够表征电池的老化状态。构建了ISSA-CNN-BiGRU-Attention预测模型,实现了对电池SOH的预测,该模型考虑了序列的反向信息,突出了关键特征的影响。实验结果表明,该方法具有性能上的整体提升,具有优秀的鲁棒性和准确性。

## 参考文献

[1] 赵靖英,胡劲,张雪辉,等.基于锂电池模型和分数阶理

- 论的 SOC-SOH 联合估计[J]. 电工技术学报, 2023, 38(17): 4551-4563.
- [2] 丁阳征, 贾建芳. 多组间接参数的锂离子电池剩余寿命预测[J]. 电子测量技术, 2019, 42(17): 111-118.
- [3] 王振新, 秦鹏, 康健强, 等. 基于衰退机理的三元锂离子电池 SOH 的诊断与估算[J]. 电子测量技术, 2020, 43(10): 7-13.
- [4] 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, 2022, 41(10): 136-141.
- [5] 常春, 王少晋, 苏广伟, 等. 改进模型的锂离子电池健康状态估计[J]. 电池, 2022, 52(6): 646-650.
- [6] BARTLETT A, MARCICKI J, ONORI S, et al. Electrochemical model-based state of charge and capacity estimation for a composite electrode lithium-ion battery[J]. IEEE Transactions on Control Systems Technology, 2015, 24(2): 384-399.
- [7] XIONG R, TIAN J, MU H, et al. A systematic model-based degradation behavior recognition and health monitoring method for lithium-ion batteries[J]. Applied Energy, 2017, 207: 372-383.
- [8] 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.
- [9] 张婷婷, 于明, 李宾, 等. 基于 Wavelet 降噪和支持向量机的锂离子电池容量预测研究[J]. 电工技术学报, 2020, 35(14): 3126-3136.
- [10] 韩云飞, 谢佳, 蔡涛, 等. 结合高斯过程回归与特征选择的锂离子电池容量估计方法[J]. 储能科学与技术, 2021, 10(4): 1432-1438.
- [11] 苏振浩, 李晓杰, 秦晋, 等. 基于 BP 人工神经网络的动力电池 SOC 估算方法[J]. 储能科学与技术, 2019, 8(5): 868-873.
- [12] YOU G W, PARK S, OH D. Diagnosis of electric vehicle batteries using recurrent neural networks[J]. IEEE Transactions on Industrial Electronics, 2017, 64(6): 4885-4893.
- [13] 王庭华, 鄢博, 吴静云, 等. 基于 HPO-LSTM 网络的锂电池健康状态估计[J/OL]. 电源学报, 1-11. [2024-05-07]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20231023.1442.006.html>.
- [14] 毛百海, 覃吴, 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.
- [15] 叶震, 李琨, 李梦男, 等. 基于 SE-SAE 特征融合和 BiLSTM 的锂电池寿命预测[J]. 电源技术, 2023, 47(6): 745-749.
- [16] 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.
- [17] 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.
- [18] HE W, WILLIARD N, OSTERMAN M, et al. Prognostics of lithium-ion batteries based on Dempster-Shafer theory and the Bayesian Monte Carlo method[J]. Journal of Power Sources, 2011, 196(23): 10314-10321.
- [19] 杨胜杰, 罗冰洋, 王菁, 等. 基于容量增量曲线峰值区间特征参数的锂离子电池健康状态估算[J]. 电工技术学报, 2021, 36(11): 2277-2287.
- [20] 李练兵, 朱乐, 李思佳, 等. 基于差分电压和 ICS-Elman 神经网络的锂离子电池剩余使用寿命预测方法[J]. 太阳能学报, 2023, 44(12): 433-443.
- [21] 王银飞, 杨铮鑫, 杜进桥, 等. 微过充条件下锂离子电池的老化机理[J]. 电池, 2023, 53(5): 499-503.
- [22] 高萌, 刘吉臻, 王瑞琪, 等. 基于自适应高斯滤波的电站历史数据稳态检测方法[J]. 动力工程学报, 2014, 34(9): 708-713.
- [23] WU W, MA R, LIU J, et al. Impact of low temperature and charge profile on the aging of lithium-ion battery: non-invasive and post-mortem analysis[J]. International Journal of Heat and Mass Transfer, 2021, 170(1): 121024.
- [24] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems science & Control Engineering, 2020, 8(1): 22-34.
- [25] 梁杨, 周永军, 蒋淑霞, 等. 基于改进 GWO-SVR 的锂电池 SOH 估计[J]. 电子测量技术, 2023, 46(7): 13-18.
- [26] 宁雪峰, 石正禄, 许加柱. 基于健康因子和 PSO-LSTM 的锂离子电池健康状态估计[J/OL]. 电源学报, 1-13. [2024-05-07]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20231123.1426.002.html>.
- [27] 尚德良, 赵旭, 李连鹏, 等. 基于 ICEEMDAN-CNN 的非视距识别方法[J]. 电子测量技术, 2023, 46(10): 61-67.

### 作者简介

陈新岗, 教授, 主要研究方向为电气设备状态监测、智能发电运行与控制、信号采集与信号处理。

赵龙, 硕士研究生, 主要研究方向为锂离子健康状态评估。

马志鹏(通信作者), 主要研究方向为绝缘材料状态评估, 电气设备状态在线监测与故障诊断, 供配电设备智能运行与控制。