

采用格拉姆角场-卷积神经网络-时序卷积网络混合模型的锂离子电池健康状态估计

赵扬¹, 耿莉敏¹, 胡循泉¹, 胡兵², 巫春玲¹, 张文博³, 山世玉¹, 陈昊¹

(1. 长安大学陕西省交通新能源开发、应用与汽车节能重点实验室, 710064, 西安;

2. 新疆工程学院控制工程学院, 830023, 乌鲁木齐; 3. 陕西重型汽车有限公司汽车工程研究院, 710200, 西安)

摘要: 针对现有电池健康状态(SOH)估计存在估计精度低、时序特征捕捉不足的问题,提出了一种格拉姆角场-卷积神经网络-时序卷积网络(GAF-CNN-TCN)混合模型。利用 GAF 算法将不同长度的容量增量(IC)曲线转换成图像数据,并采用卷积神经网络从中提取特征;提出一种特征融合网络,将二维卷积神经网络从图像中提取的图片特征与一维卷积神经网络从 IC 序列中提取的时序特征进行融合;将提取的综合特征输入时序卷积网络模型中进行训练,实现了 SOH 的准确估计。利用美国国家航空航天局和牛津大学的锂离子电池数据集进行模型验证,结果表明:相较于长短期记忆(LSTM)模型,GAF-CNN-TCN 混合模型输出的 SOH 与真实 SOH 之间的平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)分别降低了 85.65%、86.12%、84.0%;相较于 CNN-LSTM 模型,所提模型的 MAE、MAPE 和 RMSE 分别降低了 83.24%、83.75%、82.27%;相较于 TCN 模型,所提模型的 MAE、MAPE 和 RMSE 分别降低了 76.92%、77.19%、76.01%。

关键词: 锂离子电池;电池健康状态;格拉姆角场;卷积神经网络;时序卷积网络

中图分类号: TM912.8 **文献标志码:** A

DOI: 10.7652/xjtuxb202411003 **文章编号:** 0253-987X(2024)11-0027-12

State of Health Estimation of Lithium-Ion Batteries Using a Gramian Angle Field-Convolutional Neural Network-Temporal Convolution Network Hybrid Model

ZHAO Yang¹, GENG Limin¹, HU Xunquan¹, HU Bing², WU Chunling¹,

ZHANG Wenbo³, SHAN Shiyu¹, CHEN Hao¹

(1. Shaanxi Key Laboratory of New Transportation Energy and Automotive Energy Saving, Chang'an University,

Xi'an 710064, China; 2. School of Control Engineering, Xinjiang Institute of Engineering, Urumqi 830023, China;

3. Automotive Engineering Research Institute, Shaanxi Heavy Vehicle Co., Ltd., Xi'an 710200, China)

Abstract: To address the issues of low estimation accuracy and insufficient capture of time series features in the existing battery state of health (SOH) estimation, a Gramian angle field-convolutional neural network-temporal convolution network (GAF-CNN-TCN) hybrid model is proposed. The model converts incremental capacity (IC) curves of varying lengths into image data using the GAF algorithm and extracts features from them through a convolutional neural

收稿日期: 2024-04-30。 作者简介: 赵扬(1999—),男,博士生;耿莉敏(通信作者),女,教授,博士生导师。 基金项目: 陕西省重点研发计划资助项目(2022GY-1930);西安市重点产业链技术攻关一般资助项目(24ZDCYJSG0048);长安大学中央高校基本科研业务费资助项目(300102384201)。

网络出版时间: 2024-05-29

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20240528.1159.007>

network. Additionally, a feature fusion network is introduced to integrate the image features extracted from the image by a two-dimensional convolutional neural network with the temporal features extracted from the IC sequence by a one-dimensional convolutional neural network. The integrated features are fed into the temporal convolutional network model for training, leading to precise SOH estimation. Validation of the model is conducted using lithium-ion battery data sets from NASA and University of Oxford. The results show that in comparison to the long short-term memory (LSTM) model, the GAF-CNN-TCN hybrid model reduces the mean absolute error (MAE), mean absolute percentage error (MAPE), and root mean square error (RMSE) between the estimated SOH and the true SOH by 85.65%, 86.12%, and 84.0%, respectively. Similarly, compared to the CNN-LSTM model, the reductions in MAE, MAPE, and RMSE are 83.24%, 83.75%, and 82.27%, respectively. Furthermore, compared to the TCN model, the reductions in MAE, MAPE, and RMSE are 76.92%, 77.19%, and 76.01%, respectively.

Keywords: lithium-ion batteries; battery state of health; Gramian angle field; convolutional neural network; temporal convolution network

锂离子电池因其循环寿命长、能量密度高和可靠性好等优点在电动汽车、微电网和储能系统等领域发挥着重要作用^[1-3]。作为复杂的电化学系统,锂离子电池在连续工作过程中电化学性能会发生衰退^[4-6]。电池性能的持续衰退导致可用容量减少,影响其使用寿命,甚至会造成安全隐患^[7-9]。为了提高锂离子电池的性能,需要采用电池管理系统(BMS)对其进行全面监控和保护。健康状态(SOH)估计是BMS的重要组成部分,对保证电池的安全稳定运行具有重要意义^[10-12]。

SOH估计方法可以分为基于模型的方法和基于数据驱动的方法^[4,11]。基于模型的方法是将电池模型与卡尔曼滤波器、粒子滤波器等技术相结合,估算模型中某些会随着电池老化而变化的参数来表征电池的SOH。描述电池特性的模型包括电化学模型和等效电路模型。Xiong等提出了一种在线估计电池剩余容量的方法,采用电化学阻抗谱对电池的老化程度进行测定,引入基于分数阶阻抗模型的在线参数识别方法进行电池老化分析,最后提取固体电解质界面电阻来预测电池剩余容量^[13]。Zhu等基于二阶RC等效电路模型,提出了一种融合无迹卡尔曼滤波器和改进的无迹粒子滤波算法的SOH估计模型,该方法具有较高的精度和较快的运算速度^[14]。由于等效电路模型精度有限且适应性差,无法描述电池内部反应机理,SOH估计需要建立电池老化模型以更好地描述电池的老化现象。基于模型的方法依赖于电池老化模型的准确性,然而锂离子电池的老化机制十分复杂,建立准确的估计模型始终具有挑战性。

相比之下,数据驱动的方法不依赖精确的电池模型,其通过特定的学习算法来提取历史数据点中的老化信息。长短期记忆(LSTM)神经网络作为典型的深度学习算法,由于其在时间序列预测中的出色表现,在SOH估计中得到了越来越多的关注^[15]。Choi等提出了一种用于SOH估计的LSTM模型,采用电压、电流和温度作为电池健康状态指标^[16]。然而,单独的LSTM忽略了后向信息的影响,随着时间序列长度的增加,其预测精度往往会降低。Cheng等利用电流和电压作为健康特征,将经验模态分解与反向长短期记忆神经网络相结合用于SOH估计,此方法有效地解决了单一LSTM模型预测精度下降的问题^[17]。时序卷积网络模型(TCN)作为卷积神经网络(CNN)模型的变体,被广泛用于处理自然语音和音频合成等许多时序问题。四川大学刘少卿等将TCN网络与门控循环单元相结合,实现了SOH的准确估计,研究结果表明该方法的绝对平均误差为0.017^[18]。吴晓丹等将变分模态分解与TCN相结合并引入注意力机制,提高了模型的准确性^[19]。

综上所述,现有的方法大多从一维时序中提取与电池老化相关的特征来实现SOH估计,所提取的特征无法完全反映电池的老化特性。由于锂离子电池的退化是一个复杂过程,需要从不同角度提取和分析各种特征,大多数SOH估计方法仅针对某一特定的特征,不能全面表征锂离子电池的健康状态。为了解决以上问题,本文提出了一种新的混合模型来提高SOH预测的准确性和稳定性。主要创新点如下:①为了能利用多维度特征信息反映电池

的健康状态,通过格拉姆角场(GAF)算法,将容量增量(IC)序列转换为图片,可以更好地捕捉 IC 序列数据的局部和全局特征,从而反映出电池更多老化细节;②提出一种特征融合网络,利用二维卷积神经网络(2DCNN)从图片中提取特征,利用一维卷积神经网络(1DCNN)从 IC 序列中提取特征,将两种不同维度的健康特征进行融合;③采用 TCN 网络挖掘和学习融合特征,以提高 SOH 预测的准确性。

1 实验方法与数据处理

1.1 实验方法

本文选用美国国家航空航天局(NASA)编号为 B0005、B0006 的锂离子电池循环寿命数据集^[20]与牛津大学编号为 Cell 1、Cell 3、Cell 7 和 Cell 8 的锂离子电池循环寿命数据集^[21]对所提混合模型进行验证。NASA 两块 18650 电池的工作温度为 24℃,充电截止电压为 4.2 V,额定容量为 2 A·h,采用恒流恒压充电模式和恒流放电模式对电池进行老化实验。牛津大学 4 块 Kokam 锂离子电池的额定容量为 740 mA·h,环境温度为 40℃,采用恒流恒压充电模式和 ARTEMIS 城市行驶循环放电模式,每 100 次循环后进行表征测试,表征测量为以 1C 恒流充放电,其中 C 表示电池的充放电倍率,数据采样频率为 1 Hz。NASA 数据集是锂离子电池健康状态估计领域使用最广泛的数据集之一,许多研究者使用该数据集验证他们的模型和算法,能够使不同方法之间的比较更加客观公平;牛津大学的数据集相对较新,其老化试验的放电工况更接近于实车动态运行工况,能更好地验证模型在动态工况下的性能。通过验证本文建立的模型在两种数据集上的性能,能够评估模型对不同电池和不同循环工况的适用性和稳定性。

每循环电池的实际 SOH(用符号 β_{SOH} 表示)计算方法如下

$$\beta_{\text{SOH}}(i) = \frac{C(i)}{C_r} \quad (1)$$

其中: $\beta_{\text{SOH}}(i)$ 和 $C(i)$ 分别表示第 i 次循环电池的 SOH 和容量; C_r 表示电池的初始容量。

通过计算得到 NASA 两块电池的 SOH 曲线如图 1(a)所示。可以看到,随着循环次数的增加,SOH 并没有呈现出单调下降的趋势,而是出现了容量再生现象,这对电池的 SOH 预测带来了挑战。图 1(b)所示为牛津大学 4 块电池的 SOH 曲线,可以看出,4 块电池的 SOH 曲线也存在小幅波动。




图 1 实验电池的真实健康状态

Fig. 1 Actual SOH of the experimental battery

1.2 数据处理方法

1.2.1 容量增量分析法

传统的电池估计方法利用历史容量数据对模型进行训练,难以克服容量再生对预测精度的影响。为了解决以上问题,本文从 IC 曲线中提取老化特征进而对预测模型进行训练,以实现准确的 SOH 估计。容量增量表示充电过程中容量随电压的变化率,其计算方法如下

$$\frac{dQ}{dV} = \frac{Idt}{dV} \quad (2)$$

$$\frac{\Delta Q}{\Delta V} = \frac{Q_{V_j|V_{j+1}}}{V_{j+1} - V_j} = \frac{I(t_{j+1} - t_j)}{V_{j+1} - V_j} \quad (3)$$

式中: Q 为电池的容量; V 、 I 分别表示电压与电流; t 、 j 表示时间与时刻。式(3)是计算 IC 的离散表达式。

通过分析不同循环的 IC 曲线,可以揭示电池的老化机理,提取与电池性能衰退有关的特征。电池的老化模式可以分为活性材料损失、电导率损失和锂库存损失^[22]。锂离子电池内部的活性材料会随着老化而逐渐减少,表现为在近似恒定电压下 IC 曲线峰高或峰面积的降低;电导率损失、集流体腐蚀、黏合剂分解等现象,表现为 IC 曲线向更高的电压区间移动;锂库存损失、固态电解质界面膜的生长和分

解、电解质分解等现象,在 IC 曲线上表现为 IC 峰高的降低。

1.2.2 滤波算法

Cell 1 电池的 IC 曲线如图 2(a)所示,原始 IC 曲线中包含大量噪声,无法从中提取有效特征,需要利用滤波器平滑 IC 曲线。综合考虑各种滤波器的特点以及适用范围,本文选择 Savitzky-Golay (SG) 滤波器对原始 IC 曲线进行处理,该滤波器广泛用于数据平滑和去噪^[23],其核心思想是对窗口内的数据进行加权滤波,通过给定的高阶多项式,结合最小二乘拟合计算得到其权重。SG 滤波器的基本原理如下

$$N = 2n + 1 \quad (4)$$

$$\mathbf{X} = [x_{-n}, x_{-n+1}, \dots, x_{n-1}, x_n] \quad (5)$$


$$y_i = b_0 + b_1 x_i + b_2 x_i^2 + \dots + b_{w-1} x_i^{w-1} \quad (6)$$

式中: N 为窗口的长度; n 为窗口内拟合点 y_i 左右两侧的数据点数; $\mathbf{X}$ 表示数据点矩阵, x_i 为窗口内的数据点; w 为多项式阶数。多个窗口中的多项式可以用矩阵形式表示如下

$$\mathbf{Y}_{(2n+1) \times 1} = \mathbf{X}_{(2n+1) \times w} \mathbf{A}_{w \times 1} + \mathbf{E}_{(2n+1) \times 1} \quad (7)$$

式中: $\mathbf{Y}$ 表示拟合点矩阵; $\mathbf{A}$ 表示待定系数矩阵; $\mathbf{E}$ 表示拟合点与数据点之间的误差。

将 SG 滤波器窗口长度设置为 39,多项式拟合阶数设置为 4,经过 SG 滤波器处理后的 IC 曲线如图 2(b)所示。与原始的 IC 曲线相比,经过滤波处理后的 IC 曲线更光滑、噪声更少。分析不同循环对应的 IC 曲线,可以发现随着循环次数的增加,IC 曲线逐渐向高电压区间移动,并且 IC 峰值逐渐降低。虽然 IC 曲线能较好地反映电池老化规律,但是如果从全部 IC 曲线中提取健康特征,可能会提取到一些干扰信息,从而增加预测模型计算的复杂度。因此,本文选择从部分 IC 曲线中提取特征,将 IC 峰值作为中点,提取不同长度的 IC 曲线作为模型的输入。



(b)滤波后的 IC 曲线

图 2 Cell 1 电池的 IC 曲线

Fig. 2 IC curves of Cell 1 battery

2 锂离子电池健康状态估计方法

目前的 SOH 估计方法基本都是从电池的直接测量参数,例如电压、电流等提取健康特征,难以全面反映电池的老化规律。与已有的 SOH 估计方法相比,本文所提出的方法具有以下优势:① GAF 图像包含了一维时间序列数据中所缺少的空间关系特征、全局特征等,这些特征能够反映更加细微的电池老化过程;② 特征融合网络可以将 GAF 图片特征和时序特征进行融合,从多维度角度表征电池的健康状况;③ 将 CNN 网络和 TCN 网络结合,可以解决 TCN 网络无法直接从图片中提取特征信息的问题,更好地挖掘和学习电池的老化特征。

2.1 算法框架


本文提出的基于 GAF-CNN-TCN 的锂离子电池 SOH 预测方法的总体框架如图 3 所示,主要由 IC 曲线提取、基于 GAF 算法的 IC 序列转换、特征融合网络构建 3 部分组成,具体实现过程如下。

2.1.1 IC 曲线提取

首先,利用恒流充电实验获得的电压、时间与电流曲线计算得到 IC 曲线;其次,利用 SG 滤波器对原始 IC 曲线进行平滑处理;最后,以 IC 峰值作为部分 IC 曲线的中点,提取不同长度的 IC 曲线作为 GAF 算法的输入。

2.1.2 基于 GAF 算法的 IC 序列转换

通过 GAF 算法将 2.1.1 节中提取到的不同长度的 IC 序列转化为二维图像,其转化过程包含原始数据的归一化处理、极坐标转换与格拉姆矩阵生成 3 部分。



(a)原始 IC 曲线




图 3 基于 GAF-CNN-TCN 的锂离子电池 SOH 预测方法的总体框架

Fig. 3 Overall framework of the SOH prediction method for lithium-ion batteries based on GAF-CNN-TCN

2.1.3 特征融合网络构建

首先,建立 2D CNN 网络提取图片中的特征,同时搭建 1D CNN 网络用以提取一维 IC 序列的特征;其次,利用特征融合网络将与电池老化有关的图片特征与一维时序特征进行融合;最后,将融合后的特征输入 TCN 网络中进行训练,实现锂离子电池的 SOH 预测。

2.2 基于 GAF 的 IC 曲线转换

GAF 是一种有效的二维表示算法,将其与深度学习算法结合,可以更好地处理与时间序列相关的问题^[24]。本文利用 GAF 算法将一维 IC 曲线转化为二维图片数据。GAF 算法的核心思想是将时间序列中的每个值转换成极坐标中的角度,进而通过计算角度之间的余弦值来生成图像。该算法的实现过程如下

$$\hat{z}_k = \frac{(z_k - \max Z) + (x_k - \min Z)}{\max Z - \min Z} \quad (8)$$

$$\begin{cases} \varphi_k = \arccos \hat{z}_k, -1 \leq \hat{z}_k \leq 1 \\ r_k = \frac{t_k}{M}, t_k \in M \end{cases} \quad (9)$$

$$\mathbf{G} =$$

$$\begin{bmatrix} \cos(\varphi_1 + \varphi_1) & \cos(\varphi_1 + \varphi_2) & \cdots & \cos(\varphi_1 + \varphi_k) \\ \cos(\varphi_2 + \varphi_1) & \cos(\varphi_2 + \varphi_2) & \cdots & \cos(\varphi_2 + \varphi_k) \\ \vdots & \vdots & & \vdots \\ \cos(\varphi_k + \varphi_1) & \cos(\varphi_k + \varphi_2) & \cdots & \cos(\varphi_k + \varphi_k) \end{bmatrix} \quad (10)$$

式中: φ_1 、 φ_k 为所选取 IC 向量的第 1、 k 个元素的反余弦函数值; $Z = \{z_1, z_2, \dots, z_k\}$ 表示时间序列; $\hat{z}_k$ 为归一化的时间序列; t_k 是时间戳; r_k 是极坐标半径; $\mathbf{G}$ 表示格拉姆差场矩阵。利用式(9)将归一化的时间序列从笛卡尔坐标系转化为极坐标系,最后利用式(10),生成一个保留时间依赖性的类格拉姆矩阵,进而将其转化为图片。图 4 为 B0005 电池在第

1 次循环对应长度为 100 的 IC 曲线的转化结果。可以看出,IC 曲线对应的 GAF 图像具有对称性,并且 IC 曲线的变化趋势能够通过色块的变化来反映。




图 4 IC 曲线转化结果

Fig. 4 Transformation results of IC curves

2.3 时序卷积网络

利用 TCN 网络可以有效捕获电池老化过程中的动态变化和特征,从而提高 SOH 的预测精度。

TCN 模型的基本结构如图 5 所示,其由膨胀因果卷积、Dropout 层、ReLU 函数等构成。TCN 引入残差块来代替卷积层,以解决在网络结构加深时发生梯度爆炸、过拟合等问题。膨胀因果卷积是 TCN 高效处理时间序列数据的最重要组成部分,其由因果卷积和膨胀卷积组成,基本结构如图 6 所示。因果卷积由一维卷积组成,其输出是通过融合上一层中此时的输入和更早时刻的输入得到的,是一种严格的时间约束模型,适用于挖掘时序数据的潜在特征。由于膨胀卷积可以在更大的感受野内获取信息,克服了传统卷积层只关注局部邻域的问题,因此能更好地捕捉序列中的长期依赖关系。膨胀卷积的实现过程如下

$$F(e) = \sum_{l=1}^L (f(e + dl)q(l)) \tag{11}$$

式中： e 是序列中的第 e 个元素； $f(e)$ 为输入的时间序列； $F(e)$ 为对应的输出序列； l 是过滤器的尺寸； L 为过滤器尺寸的最大值； d 是扩张因子； $q(l)$ 是长度为 l 的过滤器。




图 5 TCN 模型的基本结构
Fig. 5 Basic structure of TCN model




图 6 膨胀因果卷积的结构
Fig. 6 Structure of dilated causal convolutions

2.4 特征融合网络

由于 TCN 只能用来处理一维时序数据,无法从 GAF 图片中提取特征。因此,本文提出了一种新型的特征融合网络结构,通过二维卷积神经网络提取图片特征,利用一维卷积神经网络提取原始 IC 序列特征,之后将两种特征进行融合,输入到 TCN 网络。

具体实现过程如图 7 所示。特征提取分为两个部分,一部分为 2D CNN 网络分支,其通过 2D 卷积核提取图像特征;另一部分为 1D CNN 网络分支,其使用 1D 卷积核提取,各模型的详细参数设置见表 1。




图 7 特征融合网络
Fig. 7 Feature fusion network

表 1 各模型的详细参数设置
Table 1 Parameters of each model

模型	参数设置
LSTM	1 个 LSTM 层,神经元个数为 32,随机丢弃率为 0.1,学习率为 0.001,训练 200 次。
CNN-LSTM	1 个卷积层,卷积核尺寸为 3,个数为 64,步长为 2;1 个最大池化层,池化层尺寸为 2,步长为 2;1 个 LSTM 层,神经元个数为 32;模型随机丢弃率为 0.1,学习率为 0.001,训练 200 次。
TCN	1 个 TCN 层,TCN 内含 1 个残差块,内置一维 CNN,卷积核个数为 64,尺寸为 3;模型随机丢弃率为 0.1,扩张因子 d 为 1、2、4、8,学习率为 0.001,训练 200 次。
GAF-CNN-TCN	两种卷积,一维 CNN 有 2 个卷积层,结构为卷积-池化-卷积-池化,卷积核尺寸为 3,个数分别为 32 和 64,步长为 2;池化层为 2,步长为 2;二维 CNN 有两个卷积层,结构为卷积-池化-卷积-池化,卷积核尺寸为 3×3 ,个数分别为 32 和 64,步长为 2×2 ;池化层尺寸为 2×2 ,步长为 2×2 ;TCN 内含 1 个残差块,内置一维 CNN,卷积核个数为 64,尺寸为 3;模型随机丢弃率为 0.1,扩张因子 d 为 1、2、4、8,学习率为 0.001,训练 200 次。

3 结果分析

3.1 误差评价指标

为了评估本文 GAF-CNN-TCN 模型对锂离子电池 SOH 预测的精度,采用均方根误差(RMSE,设为 R_{MSE})、平均绝对误差(MAE,设为 R_{MAE})和平均绝对百分比误差(MAPE,设为 R_{MAPE}),来评价本文建立的 SOH 预测模型的预测效果。计算方法如下

$$R_{MSE} = \sqrt{\frac{1}{u} \sum_{i=1}^u (p_i - s_i)^2}$$
 (12)

$$R_{MAE} = \frac{1}{u} \sum_{i=1}^u |p_i - s_i|$$
 (13)

$$R_{MAPE} = \frac{100\%}{u} \sum_{i=1}^u \frac{|p_i - s_i|}{s_i}$$
 (14)

式中: u 为预测 SOH 序列和实际 SOH 序列的长度; p_i 为第 i 次循环预测的 SOH; s_i 为第 i 次循环实际的 SOH。 R_{MSE} 衡量了模型预测值与真实值之间的平均偏差, R_{MSE} 越小表示模型的预测精度越高。 R_{MAE} 是预测值与真实值之间绝对误差的平均值,用于评估模型的预测准确度,该值越小表示模型的预测准确度越高。 R_{MAPE} 是预测值与真实值之间相对误差的平均百分比,该值越小,表明预测模型越准确。

3.2 不同长度 IC 曲线的预测结果分析

选取 Cell 3 和 B0006 电池来验证 GAF-CNN-TCN 模型在输入不同长度 IC 曲线时的预测性能。对于 Cell 3 电池,分别选择长度为 256、324、400 和 484 的 IC 曲线作为 GAF-CNN-TCN 模型的输入;对于 B0006 电池,分别选取长度为 64、81、100 和 144 的 IC 曲线作为 GAF-CNN-TCN 模型的输入。训练集与测试集的比例均为 1 : 1。

Cell 3 电池的 SOH 预测结果如图 8(a)所示,可以看出,输入长度为 400 的 IC 曲线时,SOH 预测曲线波动较小且更接近真实值,其预测效果优于长度为 256 和 324 的 IC 曲线,表明增加 IC 曲线长度可以降低预测误差。然而,长度为 484 的 IC 曲线预测效果却更差,这是因为虽然增加 IC 曲线长度可以提取更多与电池老化相关的特征,但也会引入一些相关性较低的混淆特征参数,从而影响 SOH 的预测精度。B0006 电池的 SOH 预测结果如图 8(b)所示,可以看出,输入长度为 100 的 IC 曲线时,模型的预测效果优于长度为 64、81 和 144 的 IC 曲线。在后续的研究中,对于牛津大学和 NASA 电池分别使用长度为 400 和 100 的 IC 曲线作为 GAF-CNN-TCN 模型的输入。




图 8 两种电池的 SOH 预测结果
Fig. 8 SOH prediction results for two types of batteries

Cell 3 和 B0006 电池的 SOH 预测误差见表 2。对于 Cell 3 电池,当输入长度为 400 的 IC 曲线时,利用 GAF-CNN-TCN 模型进行 SOH 预测的 R_{MAE} 、 R_{MAPE} 、和 R_{MSE} 均在 0.003 以内。对于 B0006 电池,当输入长度为 100 的 IC 曲线时,利用 GAF-CNN-TCN 模型进行 SOH 预测的 R_{MAE} 、 R_{MAPE} 、和 R_{MSE} 均在 0.004 以内,表明该预测模型具有较好的拟合效果和预测精度。

表 2 不同长度 IC 曲线的 SOH 预测误差
Table 2 SOH prediction errors for IC curves with different lengths

电池	IC 曲线长度	R_{MAE}	R_{MAPE}	R_{MSE}
Cell 3	256	0.008 7	0.010 9	0.009 2
	324	0.005 8	0.007 3	0.006 8
	400	0.002 4	0.002 9	0.002 6
	484	0.010 9	0.013 5	0.012 1
B0006	64	0.006 2	0.009 3	0.009 2
	81	0.008 4	0.012 5	0.009 8
	100	0.002 4	0.003 7	0.003 4
	144	0.008 8	0.013 6	0.011 1

注:表中加粗部分为预测误差最小的 IC 曲线长度。

3.3 不同预测起点的预测结果分析

为了比较 GAF-CNN-TCN 模型在不同预测起点下的 SOH 预测效果,选取 Cell 7 和 Cell 8 电池数据对模型进行训练,分别设置 4 000 和 6 000 次循环作为模型的预测起点。GAF-CNN-TCN 模型对 Cell 7 电池的预测结果如图 9 所示,可以看出,当选择预测起点为 6 000 次循环时,预测曲线波动更小且更接近真实的 SOH 曲线。GAF-CNN-TCN 模型对 Cell 8 电池的 SOH 预测结果如图 10 所示,可以看出,预测起点为 6 000 次循环的结果也优于 4 000 次循环的,这表明增加训练集数据的比例可以有效提高预测精度。




图 9 Cell 7 电池不同预测起点的 SOH 预测结果
Fig. 9 SOH prediction results of Cell 7 battery at different prediction starting points




图 10 Cell 8 电池不同预测起点的 SOH 预测结果
Fig. 10 SOH prediction results of Cell 8 battery at different prediction starting points

对比图 9 和图 10 可以发现,GAF-CNN-TCN 模型对 Cell 7 电池的 SOH 预测效果优于 Cell 8 电池。这是因为对于 Cell 7 电池来说,通过实验平台采集的数据更加平稳,所包含的无效特征信息更少。Cell 8 电池数据中则含有较多的无效特征,这会给 GAF-CNN-TCN 模型的训练带来一定的干扰。

表 3 所示为 GAF-CNN-TCN 模型对 Cell 7 和 Cell 8 电池进行 SOH 预测的误差指标,可以发现:设置预测起点为 6 000 次循环时,预测模型的 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 均低于预测起点为 4 000 次循环的;当预测起点为 6 000 次循环时,Cell 7 和 Cell 8 两块电池的平均 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别为 0. 001 4、0. 001 75、0. 001 65,误差均在 0. 002 以内;当预测起点为 4 000 次循环时,两块电池的平均 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别为 0. 002 5、0. 003 15、0. 003 05,误差均不超过 0. 003 2。表明预测起点为 6 000 次循环时,GAF-CNN-TCN 模型具有更高的预测精度。综上所述,本文所建立的 GAF-CNN-TCN 模型在 Cell 7 和 Cell 8 电池上均能保持较小的误差,并且在不同预测起点下均能表现出较高的精度。

表 3 不同预测起点的 SOH 预测误差

Table 3 SOH prediction errors at different prediction starting points

电池	预测起点 循环数	R_{MAE}	R_{MAPE}	R_{MSE}
Cell 7	4 000	0. 001 8	0. 002 3	0. 002 2
	6 000	0. 001 4	0. 001 7	0. 001 6
Cell 8	4 000	0. 003 2	0. 004 0	0. 003 9
	6 000	0. 001 4	0. 001 8	0. 001 7

3.4 不同模型的预测结果对比

为了验证本文方法的有效性,将 GAF-CNN-TCN 模型的预测效果与 TCN 模型、LSTM 模型、CNN-LSTM 模型进行对比分析。为了更客观地对比各模型的性能,模型的输入均为部分 IC 曲线,训练集与测试集的比例均为 1 : 1。图 11(a)为不同模型对 Cell 1 电池的预测结果,可以看出:GAF-CNN-TCN 模型的 SOH 预测曲线波动最小,更接近于真实值;TCN、LSTM、CNN-LSTM 模型的 SOH 预测效果较差,且随着循环次数的增加,偏离 SOH 真实值的程度越来越大;图 11(b)所示为不同模型的预测值与真实 SOH 的差值(用符号 γ_{error} 表示),可以看出,GAF-CNN-TCN 模型的误差波动最小,而 LSTM 模型和 CNN-LSTM 模型的预测误差均大于 TCN 模型和 GAF-CNN-TCN 模型,并且随着循环次数的增加而不断增大。这是因为 GAF-CNN-TCN 模型通过将 IC 序列数据转化为图像,结合 CNN 的特征提取能力和 TCN 的特征学习能力,能够更全面地捕捉和利用数据中的特征信息,从而实现更准确的 SOH 预测。




图 11 不同模型对 Cell 1 电池的 SOH 预测结果

Fig. 11 SOH prediction results of different models for Cell 1 battery

4 种模型对 B0005 电池的预测结果如图 12(a) 所示,可以看出,B0005 电池有明显的容量再生现象,LSTM 模型和 CNN-LSTM 模型的 SOH 预测曲线波动较大且无法准确预测 SOH 曲线的容量再生点;TCN 模型的预测效果优于 LSTM 和 CNN-LSTM 模型;GAF-CNN-TCN 模型的预测效果最好且能够很好地预测电池的容量再生点。图 12(b)为不同模型的 SOH 预测误差,可以看出,GAF-CNN-TCN 模型的误差波动很小,而其他 3 种模型的误差整体大于 GAF-CNN-TCN 模型,并且在容量再生点下出现很大的偏差。

为了量化分析 3 种模型的预测结果,分别计算了 3 种模型进行 SOH 预测的 R_{MAE} 、 R_{MAPE} 和 R_{MSE} ,不同模型的 SOH 预测误差见表 4。可以看出,对于 Cell 1 电池,GAF-CNN-TCN 模型预测的 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别为 0.003 1、0.003 8、0.003 6,均小于 TCN 模型、LSTM 模型和 CNN-LSTM 模型。同时,GAF-CNN-TCN 模型对 B0005 电池同样表现出较低的预测误差,其 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别为 0.002 8、0.004 0、0.003 6。




图 12 不同模型对 B0005 电池的 SOH 预测结果

Fig. 12 SOH prediction results of different models for B0005 battery

表 4 不同模型的 SOH 预测误差

Table 4 SOH prediction errors of different models				
电池	预测模型	R_{MAE}	R_{MAPE}	R_{MSE}
Cell 1	LSTM	0.025 3	0.032 3	0.027 1
	CNN-LSTM	0.023 8	0.030 4	0.025 6
	TCN	0.018 5	0.023 8	0.020 8
	GAF-CNN-TCN	0.003 1	0.003 8	0.003 6
B0005	LSTM	0.016 4	0.023 8	0.017 9
	CNN-LSTM	0.012 0	0.017 6	0.014 9
	TCN	0.007 4	0.010 4	0.009 1
	GAF-CNN-TCN	0.002 8	0.004 0	0.003 6

综合对比 4 种模型对 Cell 1 和 B0005 电池的预测误差可以发现,与 LSTM 模型相比,本文建立的 GAF-CNN-TCN 混合模型的 SOH 预测误差 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别降低了 85.65%、86.12%、84.0%;与 CNN-LSTM 模型相比,本文 GAF-CNN-TCN 混合模型的 SOH 预测误差 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别降低了 83.24%、83.75%、82.27%;与 TCN 模型相比,本文 GAF-CNN-TCN 混合模型的 SOH 预测误差 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别降低了

76.92%、77.19%、76.01%。对比分析两种单一模型,可以发现 TCN 模型的预测误差比 LSTM 模型更小,同时,TCN 模型的预测误差也小于 CNN-LSTM 模型。这是因为 TCN 模型具有独特的一维全卷积网络和因果卷积网络,可以有效提取 IC 曲线中所包含的特征信息,从而提高了 SOH 预测精度。与单 TCN 模型相比,GAF-CNN-TCN 混合模型的预测精度更高,这是因为通过 GAF 算法转换后的图像不仅保留了时间序列数据中的时间顺序信息,并且能够反映各个序列间的相关性,这可以帮助识别电池老化过程中的细微变化。在本文建立的混合模型中,利用 CNN 模型可以从图像中提取这些与电池健康状况相关的特征;利用特征融合网络能够将不同维度的特征进行融合,更加全面地反映电池老化的规律。综上所述,本文建立的 GAF-CNN-TCN 混合模型在不同电池上均表现出更小的预测误差和更好的预测效果。

为了进一步验证本文建立的混合模型的性能,对比了 RFR-MLR-SVR-GPR、EEMD-GWO-SVR、PSO-LSTM 和 Ecoder-TCN 等不同先进模型对 B0005 电池的 SOH 预测结果,不同方法的 SOH 预测结果见表 5。与文献中其他方法相比,本文的方法在 NASA 和牛津电池数据集上都表现出较好的预测性能,精度高于大多数其他方法。

表 5 不同方法的 SOH 预测结果

Table 5 SOH prediction results of different methods

电池编号	模型	训练集比例	R_{MSE}
Cell 1	RFR-MLR-SVR-GPR ^[25]		0.007 0
	Bi-LSTM ^[26]	70%	0.004 7
	IFDA-LSTM ^[27]		0.003 9
	GAF-CNN-TCN	50%	0.003 6
B0005	EEMD-GWO-SVR ^[28]	50%	0.009 6
	TCN ^[29]	50%	0.009 5
	GRU-Attention ^[30]	50%	0.008 8
	PSO-LSTM ^[31]	50%	0.007 8
	ISSA-GPR ^[32]	50%	0.006 7
	IQPSO-LSTM	50%	0.006 5
	IPSO-GPR	50%	0.006 3
	Ecoder-TCN ^[29]	50%	0.006 0
	IGPR ^[34]	50%	0.004 8
	GAF-CNN-TCN	50%	0.003 6

注:表中加粗部分为本文提出的 GAF-CNN-TCN 模型的预测结果。

4 结 论

为了提高锂离子电池 SOH 预测精度,本文利用 SG 滤波、GAF 算法与深度学习网络,构建了 SOH 预测模型,采用 NASA 和牛津大学的电池数据集对建立的模型进行验证,得到主要结论如下。

(1)建立了一种新的 GAF-CNN-TCN 混合模型,利用 GAF 算法将一维 IC 序列转化为图片数据,并且搭建一种特征融合网络将不同维度的电池老化特征进行融合,将融合特征输入混合模型实现了 SOH 的精确估计。

(2)对比分析了选择不同长度的 IC 曲线作为模型输入、设置不同循环次数作为预测起点对 SOH 估计误差的影响。结果表明:对于牛津大学的电池数据集,输入长度为 400 的 IC 曲线误差最小,其 R_{MSE} 为 0.002 6;对于 NASA 的电池数据集,输入长度为 100 的 IC 曲线误差最小,其 R_{MSE} 为 0.003 4。预测起点为 6 000 次循环时,Cell 7 和 Cell 8 两块电池的平均 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别为 0.001 4、0.001 75、0.001 65,预测起点为 4 000 次循环时,平均 R_{MAE} 、 R_{MAPE} 和 R_{MSE} 分别为 0.002 5、0.003 15、0.003 05。

(3)与 LSTM 模型、CNN-LSTM 模型和 TCN 模型相比,本文 GAF-CNN-TCN 混合模型具有更好的鲁棒性和更高的预测精度,其预测误差 R_{MSE} 分别降低了 84.0%、82.27%、76.01%。

尽管本文提出的 GAF-CNN-TCN 混合模型的准确性和稳定性能够在 NASA 与牛津大学的锂离子电池数据集上验证,但是这两种数据集均为实验室测试数据。在今后的研究中,将探索采用实车老化数据集验证本文 GAF-CNN-TCN 混合模型的性能。

参考文献:

[1] 赵轩,李美莹,余强,等. 电动汽车动力锂电池状态估计综述[J]. 中国公路学报, 2023, 36(6): 254-283.
ZHAO Xuan, LI Meiyong, YU Qiang, et al. State estimation of power lithium batteries for electric vehicles: a review [J]. China Journal of Highway and Transport, 2023, 36(6): 254-283.

[2] ZHANG Lei, HU Xiaosong, WANG Zhenpo, et al. A review of supercapacitor modeling, estimation, and applications: a control/management perspective [J]. Renewable and Sustainable Energy Reviews, 2018, 81 (Part 2): 1868-1878.

- [3] 赵云飞, 徐俊, 王霄, 等. 双自适应衰减卡尔曼滤波锂电池荷电状态估计 [J]. 西安交通大学学报, 2018, 52(12): 99-105.
ZHAO Yunfei, XU Jun, WANG Xiao, et al. An estimation method for state of charge of lithium-ion batteries using dual adaptive fading extended Kalman filter [J]. Journal of Xi'an Jiaotong University, 2018, 52(12): 99-105.
- [4] CHE Yunhong, HU Xiaosong, LIN Xianke, et al. Health prognostics for lithium-ion batteries: mechanisms, methods, and prospects [J]. Energy & Environmental Science, 2023, 16(2): 338-371.
- [5] LIN Chuanping, XU Jun, MEI Xuesong. Improving state-of-health estimation for lithium-ion batteries via unlabeled charging data [J]. Energy Storage Materials, 2023, 54: 85-97.
- [6] XU Jun, MEI Xuesong, WANG Xiao, et al. A relative state of health estimation method based on wavelet analysis for lithium-ion battery cells [J]. IEEE Transactions on Industrial Electronics, 2021, 68 (8): 6973-6981.
- [7] DENG Zhongwei, HU Xiaosong, LI Penghua, et al. Data-driven battery state of health estimation based on random partial charging data [J]. IEEE Transactions on Power Electronics, 2022, 37(5): 5021-5031.
- [8] HU Xiaosong, CHE Yunhong, LIN Xianke, et al. Battery health prediction using fusion-based feature selection and machine learning [J]. IEEE Transactions on Transportation Electrification, 2021, 7(2): 382-398.
- [9] HU Xiaosong, XU Le, LIN Xianke, et al. Battery lifetime prognostics [J]. Joule, 2020, 4(2): 310-346.
- [10] SHI Mingjie, XU Jun, LIN Chuanping, et al. A fast state-of-health estimation method using single linear feature for lithium-ion batteries [J]. Energy, 2022, 256: 124652.
- [11] 赵云飞, 徐俊, 王海涛, 等. 采用 Morlet 小波的锂电池相对健康状态估计 [J]. 西安交通大学学报, 2019, 53(12): 97-103.
ZHAO Yunfei, XU Jun, WANG Haitao, et al. An estimation method of relative state-of-health for lithium-ion batteries using Morlet wavelet [J]. Journal of Xi'an Jiaotong University, 2019, 53(12): 97-103.
- [12] LIN Chuanping, XU Jun, SHI Mingjie, et al. Constant current charging time based fast state-of-health estimation for lithium-ion batteries [J]. Energy, 2022, 247: 123556.
- [13] XIONG Rui, TIAN Jinpeng, MU Hao, et al. A systematic model-based degradation behavior recognition and health monitoring method for lithium-ion batteries [J]. Applied Energy, 2017, 207: 372-383.
- [14] ZHU Feng, FU Jingqi. A novel state-of-health estimation for lithium-ion battery via unscented Kalman filter and improved unscented particle filter [J]. IEEE Sensors Journal, 2021, 21(22): 25449-25456.
- [15] ZHOU Yanting, WANG Yanan, WANG Kai, et al. Hybrid genetic algorithm method for efficient and robust evaluation of remaining useful life of supercapacitors [J]. Applied Energy, 2020, 260: 114169.
- [16] CHOI Y, RYU S, PARK K, et al. Machine learning-based lithium-ion battery capacity estimation exploiting multi-channel charging profiles [J]. IEEE Access, 2019, 7: 75143-75152.
- [17] CHENG Gong, WANG Xinzh, HE Yurong. Remaining useful life and state of health prediction for lithium batteries based on empirical mode decomposition and a long and short memory neural network [J]. Energy, 2021, 232: 121022.
- [18] 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.
LIU Shaoqing, LI Shuai, MIAO Jianguo, et al. Lithium-ion battery state of health estimation based on TCN-BiGRU [J]. Electronic Measurement Technology, 2023, 46(23): 68-76.
- [19] 吴晓丹, 范波, 王建祥, 等. 基于 VMD-TCN-Attention 的锂电池寿命预测 [J]. 电源技术, 2023, 47(10): 1319-1325.
WU Xiaodan, FAN Bo, WANG Jianxiang, et al. Life prediction of lithium battery based on VMD-TCN-Attention [J]. Chinese Journal of Power Sources, 2023, 47(10): 1319-1325.
- [20] GOEBEL K, SAHA B, SAXENA A, et al. Prognostics in battery health management [J]. IEEE Instrumentation & Measurement Magazine, 2008, 11(4): 33-40.
- [21] BIRKL C. Diagnosis and prognosis of degradation in lithium-ion batteries [D]. Oxford, USA: University of Oxford, 2017.
- [22] PASTOR-FERNÁNDEZ C, UDDIN K, CHOUCHELMANANE G H, et al. A comparison between electrochemical impedance spectroscopy and incremental capacity-differential voltage as li-ion diagnostic techniques to identify and quantify the effects of degradation modes within battery management systems [J]. Journal of Power Sources, 2017, 360: 301-318.

- [23] XU Huanwei, WU Lingfeng, XIONG Shizhe, et al. An improved CNN-LSTM model-based state-of-health estimation approach for lithium-ion batteries [J]. *Energy*, 2023, 276: 127585.
- [24] WANG Zhiguang, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks [C]//2015, Association for the Advancement of Artificial Intelligence. Washington, DC, USA: AAAI, 2015: 40-46.
- [25] LIN Mingqiang, WU Denggao, MENG Jinhao, et al. A multi-feature-based multi-model fusion method for state of health estimation of lithium-ion batteries [J]. *Journal of Power Sources*, 2022, 518: 230774.
- [26] XU Peng, HUANG Yuan, RAN Wenwen, et al. State of health estimation of Lib based on discharge section with multi-model combined [J]. *Heliyon*, 2024, 10(4): e25808.
- [27] TIAN Aina, CHEN Zhe, PAN Zhuangzhuang, et al. Li-ion battery state of health estimation based on short random charging segment and improved long short-term memory [J]. *IET Signal Processing*, 2023, 2023(1): 8839034.
- [28] YANG Zhanshe, WANG Yunhao, KONG Chenzai. Remaining useful life prediction of lithium-ion batteries based on a mixture of ensemble empirical mode decomposition and GWO-SVR model [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-11.
- [29] 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.
- ZHANG Xiaoyuan, ZHANG Jinhao, JIANG Yajun. Power battery health evaluation based on improved TCN model [J]. *Energy Storage Science and Technology*, 2022, 11(5): 1617-1626.
- [30] 毛百海, 覃昊, 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.
- MAO Baihai, QIN Wu, XIAO Xianbin, et al. SOH estimation of lithium-ion batteries based on LSTM & GRU-Attention multijoint model [J]. *Energy Storage Science and Technology*, 2023, 12(11): 3519-3527.
- [31] 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 [EB/OL]. (2023-11-24) [2024-02-05]. <https://link.cnki.net/urlid/12.1420.TM.20231123.1426.002>.
- Ning Xuefeng, SHI Zhenglu, XU Jiazhu. State of health estimation of lithium-ion batteries based on health factors and PSO-LSTM [EB/OL]. (2023-11-24) [2024-02-05]. <https://link.cnki.net/urlid/12.1420.TM.20231123.1426.002>.
- [32] 张梦迪, 刘洋, 陈健, 等. 基于 ISSA-GPR 的锂离子电池健康状态估计 [EB/OL]. (2023-12-19) [2024-03-10] <https://link.cnki.net/urlid/12.1420.TM.20231219.1345.010>.
- ZHANG Mengdi, LIU Yang, CHEN Jian, et al. Estimation of health state of lithium-ion battery based on ISSA-GPR [EB/OL]. (2023-12-19) [2024-03-10]. <https://link.cnki.net/urlid/12.1420.TM.20231219.1345.010>.
- [33] PENG Simin, SUN Yunxiang, LIU Dandan, et al. State of health estimation of lithium-ion batteries based on multi-health features extraction and improved long short-term memory neural network [J]. *Energy*, 2023, 282: 128956.
- [34] 邓鸿彬, 吴松荣, 刘齐, 等. 基于改进高斯过程回归的锂离子电池健康状态估计 [EB/OL]. (2024-04-26) [2024-04-28]. <https://link.cnki.net/urlid/12.1420.TM.20240426.0915.008>.
- DENG Hongli, WU Songrong, LIU Qi, et al. State-of-health estimation of lithium-ion batteries based on improved Gaussian process regression [EB/OL]. (2024-04-26) [2024-04-28]. <https://link.cnki.net/urlid/12.1420.TM.20240426.0915.008>.

(编辑 武红江)