

DOI: 10.13382/j.jemi.B2508541

基于增量能量和不一致性特征的锂离子 电池组 SOH 估计方法*

张朝龙 王安祥 张艳 程开新 周渝杰

(金陵科技学院智能科学与控制工程学院 南京 211169)

摘要:针对现有锂离子电池组健康状态(state of health, SOH)精确估计难题,设计了一种融合电池组整体与单体不一致性多尺度特征的高精度 SOH 估计方法。在该方法中,提出了一种结合卷积神经网络(convolutional neural network, CNN)、柯尔莫可洛夫-阿诺德网络(Kolmogorov-Arnold network, KAN)与 Bahdanau 注意力(Bahdanau attention, BA)机制的深度学习模型 CNN-KAN-BA。在提出的 SOH 估计过程中,首先通过对 6 节串联 18650 电池组开展系统老化实验,获取全生命周期数据。进而,采用增量能量分析(incremental energy analysis, IEA)方法提取表征电池组整体衰退的增量能量曲线长度特征,同时计算组内单体电压中位数绝对偏差量与温度峰度作为反映不一致性演化的关键个体特征,从而构建了全面描述电池组“整体-单体”协同衰退的多尺度特征集。利用训练数据的特征训练了 CNN-KAN-BA 估计模型,并对测试数据进行了验证,结果表明该方法可实现高精度 SOH 估计,其平均绝对误差为 0.587 4%,均方根误差为 0.699 0%,平均决定系数高于 98%,均优于其他常见的 SOH 估计方法。所提出的方法可有效解决锂离子电池组 SOH 精确估计问题。

关键词:锂离子电池组;健康状态;增量能量分析;柯尔莫哥洛夫-阿诺德网络;不一致性

中图分类号: TM910.1; TN86 **文献标识码:** A **国家标准学科分类代码:** 120.30

Lithium-ion battery pack SOH estimation method based on incremental energy and inconsistency features

Zhang Chaolong Wang Anxiang Zhang Yan Cheng Kaixin Zhou Yujie

(College of Intelligent Science and Control Engineering, Jinling Institute of Technology, Nanjing 211169, China)

Abstract: To address the current challenge in accurately estimating the state of health (SOH) of lithium-ion battery packs, a high-precision SOH estimation method integrating multi-scale features of the overall degradation and individual cell inconsistencies of the battery pack is designed. In this method, a deep learning model convolutional neural network Kolmogorov-Arnold network-Bahdanau attention (CNN-KAN-BA) combining a convolutional neural network (CNN), a Kolmogorov-Arnold network (KAN), and a Bahdanau attention (BA) mechanism is proposed. In the proposed SOH estimation process, systematic aging experiments are first conducted on a six-cell series-connected 18650 battery pack to obtain full life-cycle data. Then, the incremental energy analysis (IEA) method is adopted to extract the incremental energy curve length feature that characterizes the overall degradation of the battery pack. Simultaneously, the median absolute deviation of individual cell voltages within the pack and the temperature kurtosis are calculated as key individual features reflecting the evolution of inconsistency. Thereby, a multi-scale feature set that comprehensively describes the coordinated “overall-individual” degradation of the battery pack is constructed. The CNN-KAN-BA estimation model is trained using the features from the training data and is validated with the test data. The results show that this method can achieve high-precision SOH estimation, with a mean absolute error of 0.587 4%, a root mean square error of 0.699 0%, and an average coefficient of determination higher than 98%, all of which are superior to other common SOH estimation methods. The proposed method can effectively solve the problem of precise SOH estimation for lithium-ion battery packs.

Keywords: lithium-ion battery pack; state of health (SOH); incremental energy analysis (IEA); Kolmogorov-Arnold network (KAN); inconsistency

收稿日期: 2025-07-06 Received Date: 2025-07-06

* 基金项目:江苏省高等学校基础科学(自然科学)研究重大项目(23KJA480002)、江苏高校“青蓝工程”中青年学术带头人、金陵科技学院高层次人才项目(jit-rcyj-202202)资助

0 引言

动力锂离子电池已经广泛应用于新能源汽车中。精准、高效、可靠地估计锂离子电池的健康状态 (state of health, SOH), 对延长电动汽车的使用寿命^[1]、优化电池管理系统^[2] (battery management system, BMS) 至关重要, 是推动新能源汽车产业可持续发展的关键技术之一。

传统的 SOH 估计方法主要包括直接测量法、基于模型驱动方法和数据驱动方法。直接测量法通常包括库伦计数法^[3]、开路电压法^[4]以及电化学阻抗谱法^[5-6]。其中库伦计数法是通过测量充放电电流的累积量计算 SOH, 但易受误差积累和电池自放电影响, 导致长期估算偏差; 开路电压法是基于其与荷电状态关系估算 SOH, 但测量前需长时间静置, 且受温度和荷电状态变化影响较大; 电化学阻抗法是通过测量电池在不同频率下的阻抗变化评估 SOH, 但测试设备昂贵, 难以实现在线测量。

基于模型的方法大致可以分为基于等效电路模型^[7] (equivalent circuit model, ECM)、电化学模型^[8] (electrochemical model, EM) 和数据-物理融合模型^[9] (hybrid model, HM) 的方法。其中等效电路模型是使用电池的等效电路参数 (如电池内阻、电容、极化阻抗等) 模拟电池的动态特性, 并结合状态观测方法 (如卡尔曼滤波) 来估计 SOH, 这种方法计算相对简单, 但模型参数受温度、充放电倍率等因素影响, 需频繁校正; 电化学模型基于电池内部的电化学动力学方程 (如 P2D 模型), 通过数值计算模拟锂离子的传输、固相扩散、SEI 生成等过程, 从而评估电池健康状态, 此方法具有较强的物理解释性, 但计算相对复杂, 数值求解成本高。数据-物理融合模型是通过结合物理模型 (ECM、P2D) 和数据驱动方法 (机器学习、深度学习), 通过历史数据修正模型参数来提高 SOH 估计精度和适应性, 该方法兼顾物理可解释性和数据适应能力, 但本身仍需部分物理参数标定, 计算复杂度较高。

数据驱动方法是基于电池的历史运行数据, 提取特征并利用机器学习方法构建 SOH 估计模型, 避免了复杂的物理建模过程。其中, 常见的特征包括电池充放电过程中电压、电流等关键特征, 其变化趋势反应了 SOH 变化趋势。另外, 也有学者提出了增量容量分析法的特征提取方法^[10], 该方法基于电压-容量关系, 通过绘制出增量容量 (incremental capacity, IC) 曲线, 识别出 SOH 退化过程中的关键变化点, 间接表征了内部化学反应的平衡过程并具有良好的物理可解释性。然而, 该特征不能反应电池能量与老化的关系。此外, 锂离子电池通常是成组使用, 而针对电池组 SOH 估计研究中, 多将电池模组视为一个大容量单体电池^[11], 基于电池模组的总电压、

总电流提取系统级特征, 沿用单体电池的建模框架进行 SOH 估计。这种等效化方法忽略了电池模组内单体间的差异信息, 在电池模组一致性较好时能有效评估系统整体健康状态。

数据驱动中常利用机器学习方法构建模型, 如支持向量机 (support vector machine, SVM)^[12]、极限学习机 (extreme learning machine, ELM)^[13]、随机森林 (random forest, RF)^[14] 等, 这些传统的机器学习对人工特征工程要求较高, 同时难以自动提取深层特征, 模型的泛化能力也相对较差。此外, 深度学习方法, 如卷积神经网络 (convolutional neural network, CNN)^[15]、循环神经网络 (recurrent neural network, RNN)^[16] 及其变种长短时记忆 (long short term memory, LSTM)^[17]、门控循环单元 (gated recurrent unit, GRU)^[18-19] 等, 具有自动提取特征、强化非线性建模和时间序列处理能力, 在 SOH 估计中表现优异, 但依赖大模型数据且计算成本较高; 相比之下, 混合模型方法能够结合不同网络的优势, 如 CNN-LSTM^[20] 能同时提取局部特征和建模时间依赖, 在 SOH 估计方面能够达到更好的效果。

在此提出了一种新颖的锂离子电池组的 SOH 估计方法。首先, 提出了提取电池组整体特征和组内不一致特征的多尺度特征。针对整体特征, 提出了增量能量分析 (incremental energy analysis, IEA) 法, 基于电压-能量 (V-E) 关系, 构建增量能量 (incremental energy, IE) 曲线, 利用曲线长度特征直接反映 SOH 退化趋势。针对电池组内各单体电池之间的差异性, 提出提取电压中位数绝对偏差量和温度峰度作为组内不一致性特征。随后, 提出了 CNN-柯尔莫哥洛夫-阿诺德网络-Bahdanau 注意力 (Kolmogorov-Arnold Network-Bahdanau attention, CNN-KAN-BA) 机制的模型, 该模型融合了 CNN、KAN 和 Bahdanau 注意力机制。其中 KAN 基于 Kolmogorov-Arnold 逼近定理的深度学习方法, 通过 B-Spline 基函数进行特征变换, 能够有效逼近复杂的非线性关系。BA 机制会为每个时间步计算重要性权重, 动态调整模型对各时间步特征的关注程度, 改善了模型对异常行为的敏感性, 与 KAN 非线性映射形成协同优化, 有助于 SOH 的精准估计。最后在锂离子电池组老化实验数据集上对所提出的方法开展了实验验证, 并与其他典型特征、典型模型进行了对比实验, 最终实验结果表明, 提出的方法在 SOH 估计方面效果更优。

1 锂电池组健康状态

对于电池的 SOH 有多种定义, 在此采用容量比来定义锂离子电池的 SOH。该种定义兼具直观性和可靠性, 如式(1)所示。

$$SOH = \frac{Q_{\max \text{ capacity}}}{Q_{\text{rated capacity}}} \times 100\% \quad (1)$$

式中: $Q_{\max \text{ capacity}}$ 代表锂电池当前最大放电容量; $Q_{\text{rated capacity}}$ 代表锂电池额定容量。电池组的 SOH 值随着循环次数的变化趋势如图 1 所示。

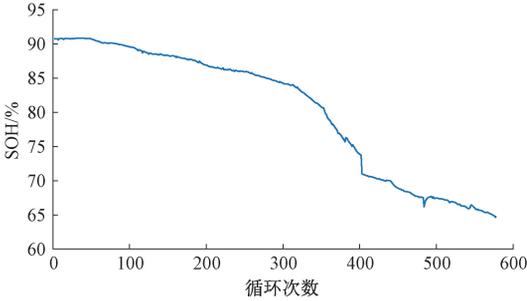


图 1 SOH 的变化趋势

Fig. 1 Trend chart of SOH

2 特征提取及相关性分析

提取电池组整体特征和组内不一致特征的多尺度特征用于电池组 SOH 估计。锂离子电池组在充电过程中电压和电流随时间变化的曲线如图 2 所示。选取了充电阶段的数据,对 IE 曲线展开全面且详细的分析,结合充电阶段的温度数据,提取综合健康指标,并运用皮尔逊相关系数法分析从 IE 曲线中提取的特征之间的相关性。

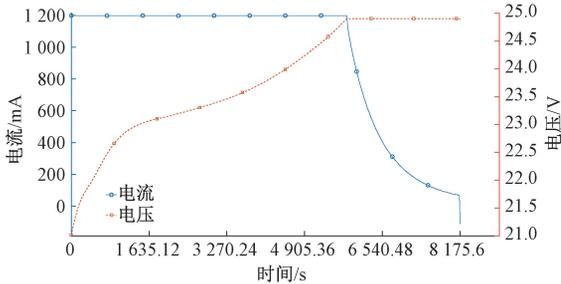


图 2 电流和电压随时间变化的曲线

Fig. 2 Graphs of current and voltage varying with time

2.1 IE 曲线

IE 曲线是电池放电过程中能量变化率的曲线,其形态会随着电池的老化而变化。相比于直接使用电池的电压或容量,IE 曲线能更直观地反映出电池内部的衰减模式,比传统单一物理量(如电压或电流)更具有代表性。IE 曲线相关的计算公式如式(2)所示。

$$IE = \frac{dE}{dV} = \frac{\Delta E}{\Delta V} \quad (2)$$

式中: ΔE 表示电池在某一电压段内变化的能量。

电池组不同循环次数下的 IE 曲线如图 3 所示,该曲线为某次循环中,增量能量在不同电压阶段的分布特征,

重点关注了单次循环里电池响应行为和结构演变。

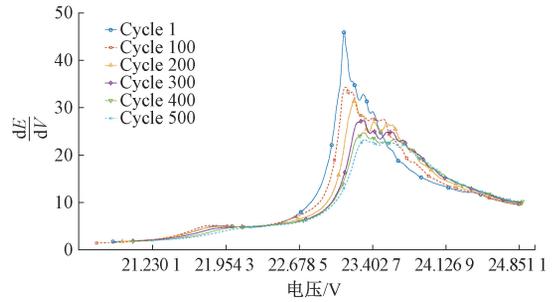


图 3 电池组 IE 曲线

Fig. 3 Battery pack IE curve graph

2.2 IE 曲线特征

IE 曲线是表征动力电池老化过程的重要指标之一,能够直观反映不同老化阶段电池内部特性的演变过程。为了更好地量化这种演变过程中的特征变化,通常提取 IE 曲线中的典型几何参数(如曲线长度、峰值和面积),作为衡量老化状态及性能衰减规律的参考依据。

1) 曲线长度

增量能量曲线的长度表征了曲线在整个电压区间内的起伏和复杂程度,反映了老化过程中微观行为和相变过程的细微偏移,体现了 IE 曲线随老化产生的相态转变及结构特征的微小变化。通常,长度值越大,表明老化过程中的响应更为复杂,结构和相变特征更为明显。曲线长度的计算公式如式(3)所示。

$$L = \sum_{i=1}^{N-1} \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (3)$$

式中: x_i 为第 i 个采样点在横坐标上的数值; y_i 为第 i 个采样点在纵坐标上的数值; N 为采样点总数。

2) 曲线面积

面积是对曲线分布及累积效果的综合表征,能够反映信号在规定区间内的总体响应和能量水平。它通过对采样点之间区域的数值积分,量化研究对象在不同状态下的综合表现及响应强度。面积值的增大或减小,揭示了研究对象在特定电压窗口下宏观能量水平的改变,计算公式如式(4)所示。

$$A = \sum_{i=1}^{N-1} \frac{y_i + y_{i+1}}{2} (x_{i+1} - x_i) \quad (4)$$

式中: x_i 为第 i 个采样点在横坐标上的数值; y_i 为第 i 个采样点在纵坐标上的数值; N 为采样点总数。

在对 IE 曲线的分析中,曲线长度基于相邻数据点间的欧氏距离累加计算,对局部波动和峰形变化敏感,可反映曲线的形态复杂度;曲线面积则通过梯形法进行数值积分,表征对应电压区间内的总电荷量,反映的整体强度。因此,曲线长度与曲线面积分别从几何形态和物理总量两个互补的维度量化电池老化行为。

3) 曲线峰值

IE 曲线中的峰值反映了电池在特定电压下响应最为突出的区域,代表老化过程中相变或结构演变的极值特征。它能够直观显示不同老化阶段极值区域的位置偏移及强度衰减,从而成为评估性能退化的敏感指标,其计算公式如式(5)所示。

$$P = \max y_i \quad (5)$$

式中: y_i 为第 i 个采样点在纵坐标上的数值。

2.3 不一致性特征

基于由 6 节串联 18650 锂离子电池构成的电池组开展老化实验,在实验过程中同步采集每一节单体电池的电压与温度数据。在此基础上,以同一循环阶段下组内 6 个单体电池的电压与温度分布为研究对象,计算其统计不一致性特征。所采用的特征包括峰度、中位数绝对偏差(median absolute deviation, MAD)以及方差,用于从分布形态、离散程度和异常敏感性等不同角度刻画组内单体电池之间的差异性。

1) 峰度

峰度是衡量数据分布相对于正态分布尖峭或平坦程度的指标,可反映参数是否存在极端偏离或异常分布。在动力电池老化后期,部分单体性能急剧衰退,其测量值分布常出现尖峰或厚尾特征,导致峰度值显著升高,其计算公式如式(6)所示。

$$K = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma} \right)^4 \quad (6)$$

式中: x_i 为第 i 个样本值; \bar{x} 为样本值的均值; σ 为样本值的标准差; N 为样本数。

2) 中位数绝对偏差量

MAD 是衡量数据相对于其中位数偏离程度的稳健统计量,能有效反映动力电池组不同单体状态参数分布的集中性与一致性。相较于标准差易受极端值主导的特性,MAD 对极值具有更强抗干扰性,使其在含极端老化单体的动力电池系统中能提供更稳健的离散性评估。当动力电池组老化不一致性加剧时,部分单体性能显著偏离主体性能范围,致使 MAD 值增大,从而更灵敏稳定地反映状态参数分布的离散程度,其计算公式如式(7)所示。

$$MAD = \text{median} | x_i - \text{median}_j(x_j) | \quad (7)$$

式中: x_i 为第 i 个样本值; $\text{median}_j(x_j)$ 为所有样本值的中位数。

3) 方差

方差是衡量一组数据相对于均值的离散程度的统计量,其计算公式如式(8)所示。

$$\text{Var} = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (8)$$

式中: x_i 为第 i 个样本值; \bar{x} 为样本值的均值; N 为样本数。

2.4 皮尔逊相关系数

皮尔逊相关系数是衡量两个变量之间线性相关程度的统计指标,通常用符号 r 表示。皮尔逊相关系数的计算公式如式(9)所示。

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2} \cdot \sqrt{\sum (Y_i - \bar{Y})^2}} \quad (9)$$

式中: X_i, Y_i 表示数据集中的两个变量(如特征与 SOH); \bar{X}, \bar{Y} 分别表示 X 和 Y 的均值。

3 CNN-KAN-BA 模型的搭建

3.1 CNN

CNN 通过卷积操作和聚合运算自动提取数据的局部特征,保存特征的主要信息,并使用池化层减少计算复杂度,广泛用于影像处理、时间序列数据分析及其他工作。卷积神经网络由输入层、一维卷积层、激活函数层、池化层和输出层构成。

1) 一维卷积层

卷积操作如式(10)所示。

$$y_t^{(K)} = \sum_{i=0}^{M-1} x_{t+i} W_i^{(K)} + b^{(K)} \quad (10)$$

式中: $y_t^{(K)}$ 是卷积核 K 在时间步 t 处的输出值; x_{t+i} 是输入时间序列的值; $W_i^{(K)}$ 是卷积核的权重(大小为 M); $b^{(K)}$ 是偏置项; M 是卷积窗口大小(即卷积核的长度)。

2) 激活函数层(ReLU)

ReLU 定义如式(11)所示。

$$h_t^{(k)} = \max(0, y_t^{(k)}) \quad (11)$$

式中: $y_t^{(k)}$ 是卷积层输出; $h_t^{(k)}$ 是 ReLU 激活后的值。

3) 池化层

最大池化操作如式(12)所示。

$$\text{pool}(t) = \max(h_t, h_{t+1}, \dots, h_{t+M-1}) \quad (12)$$

式中: M 是池化窗口大小; h_t 是 ReLU 处理后的特征。

3.2 KAN-BA

KAN 是受 Kolmogorov-Arnold 表示定理启发而提出的新兴的神经网络。该定理表明,若 f 是有界域上的多元连续函数,对于光滑函数 $f: [0, 1]^n \rightarrow \mathbb{R}$, 可以写成:

$$f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_{p=1}^n \lambda_{qp} x_p \right) \quad (13)$$

式中: $\lambda_{pq}: [0, 1]^n \rightarrow \mathbb{R}$, 且 $\Phi_q: \mathbb{R} \rightarrow \mathbb{R}$ 。这为 KAN 的设计提供了理论基础。

KAN 主要由特征变换层、B-Spline 计算层、线性组合

层、最终输出层组成。KAN 结构如图 4 所示。

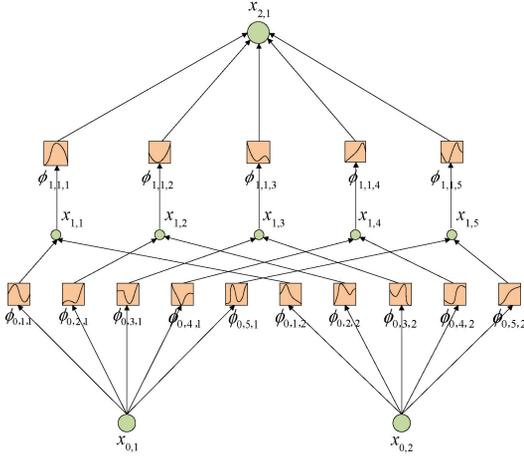


图 4 KAN 结构

Fig. 4 KAN structure diagram

1) 特征变换层

每个输入特征 x_p 先经过一组单变量变换 (B-Spline 表示), 映射到多维特征空间, 如式 (14) 所示。

$$\tilde{x}_{p,q} = \Phi_{p,q}(x_p) \quad (14)$$

式中: x_p 表示输入特征; $\Phi_{p,q}(x_p)$ 为非线性变换函数;

$\tilde{x}_{p,q}$ 表示变换后的新特征。

2) B-Spline 计算层

每个单变量变换 $\Phi(x)$, 由 B-Spline 计算得到, 其数学表达式如式 (15) 所示。

$$\Phi_{p,q}(x) = \sum_{i=0}^n c_i B_{i,k}(x) \quad (15)$$

式中: $B_{i,k}(x)$ 为 B-Spline 基函数, 计算公式如式 (16)、(17) 所示。

$$B_{i,0}(x) = \begin{cases} 1, & t_i \leq x < t_{i+1} \\ 0, & \text{其他} \end{cases} \quad (16)$$

$$B_{i,k}(x) = \frac{x - t_i}{t_{i+k} - t_i} B_{i,k-1}(x) + \frac{t_{i+k+1} - x}{t_{i+k+1} - t_{i+1}} B_{i+1,k-1}(x) \quad (17)$$

3) 线性组合层

经过 B-Spline 变换的特征进一步进行线性加权, 如式 (18) 所示。

$$x_{1,k} = \sum \lambda_{l,k,j} \tilde{x}_j \quad (18)$$

式中: $\lambda_{l,k,j}$ 是可训练的权重参数; $x_{1,k}$ 是经过变换后的新特征。

4) 最终输出如式 (19) 所示。

$$y = \sum_q w_q \Phi_q(x) \quad (19)$$

式中: w_q 是可训练的特征权重; $\Phi_q(x)$ 是 B-Spline 变换

后的特征。

KAN 通过非线性映射能有效逼近输入输出的复杂关系, 但其对所有时间步等权处理, 无法突出关键退化阶段。为弥补此不足, 在 KAN 后引入 Bahdanau 注意力机制, 实现关键时间步的自适应聚集, 提升特征选择能力, 增强模型对序列退化模式的捕获效果。

假设输入序列经过 CNN-KAN 后的输出为:

$$X = [x_1, x_2, \dots, x_T], x_i \in R^H \quad (20)$$

式中: T 是时间步; H 是特征维度。

对每个时间步特征, 首先计算评分如下:

$$u_t = \tanh(W_1 x_t + b_1) \quad (21)$$

$$e_t = W_2 u_t + b_2 \quad (22)$$

式中: $W_1 \in R^{A \times H}$, A 是注意力隐层大小; $W_2 \in R^{1 \times A}$; e_t 是时间步 t 的重要性分数。

随后, 归一化权重如下:

$$\alpha_t = \frac{\exp(e_t)}{\sum_{t'=1}^T \exp(e_{t'})} \quad (23)$$

式中: α_t 是时间步 t 的注意力权重。

最后, 加权组合并做最终估计输出为:

$$c = \sum_{t=1}^T \alpha_t x_t \quad (24)$$

$$\hat{y} = f(c) \quad (25)$$

式中: c 是所有 KAN 输出的加权和; f 是输出层。

$$\hat{y} = W_o c + b_o \quad (26)$$

Bahdanau 注意力的结构如图 5 所示。

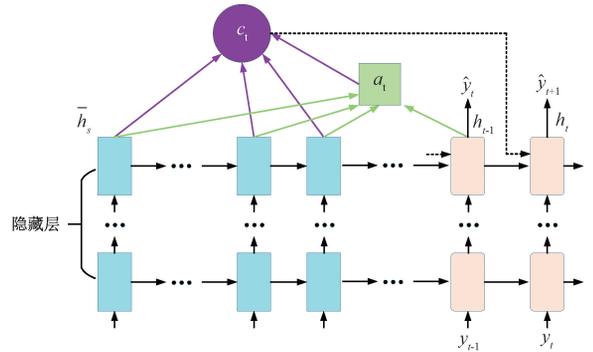


图 5 Bahdanau 注意力结构

Fig. 5 Bahdanau Attention structure diagram

4 实验流程、结果和分析

4.1 实验数据

实验采用 6 节力神 18650 电池串联开展充放电测试, 每节单体电池的标称容量为 2.4 Ah。利用新威 BTS 充放电设备, 如图 6 所示, 对锂电池组在室温条件下进行老化试验, 测得锂电池组的老化数据。锂电池组的老化

试验中,先以 1.2 A 恒流充电,至电池组端电压达到截止电压 24.9 V。然后对锂电池组以 24.9 V 进行恒压充电,直至电流降至 48 mA 停止充电。最后以 2 A 进行恒流放电,直至电池组端电压降至 19.3 V。当电池组的最大放电容量达到失效阈值(额定容量的 70%左右)时,终止实验。

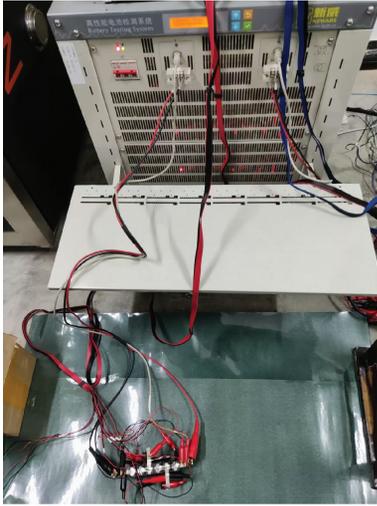


图 6 新威 BTS 充放电设备

Fig. 6 Neware BTS charging and discharging equipment

4.2 实验步骤

本文主要进行了锂电池组健康状态估计,具体实验步骤如图 7 所示。

1) 通过实验设备测量出电池组在恒流-恒压充电阶段的电流、电压、能量、温度等原始数据。

2) 根据所记录的能量、电压等数据绘制出电池组的能量增量曲线,并根据增量能量曲线提取各个循环的 IEA 曲线特征,再结合电压和温度的不一致性特征,形成特征体系。再通过皮尔逊相关系数法遴选合适的 IE 曲线特征、电压和温度的一不一致性特征。

3) 将处理好的数据集均分为训练集和测试集,把提取的相关特征作为特征输入,输入到搭建的 CNN-KAN-BA 混合深度学习模型中进行调试训练、优化参数配置。

4) 最后利用测试数据验证特征体系和 CNN-KAN-BA 模型的估计效果。计算出评估指标。

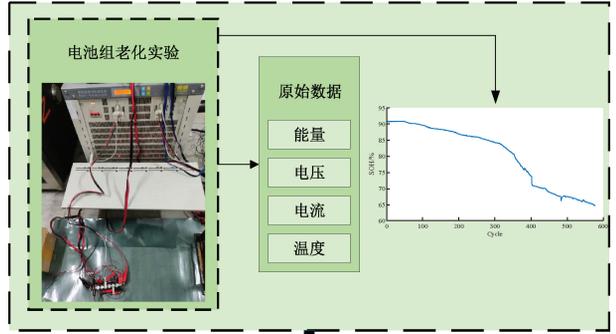
4.3 实验结果和分析

为了严格评估 SOH 估计的准确性,本文实验采用平均绝对误差(MAE)、均方根误差(RMSE)、 R^2 指标来评估回归模型的性能。

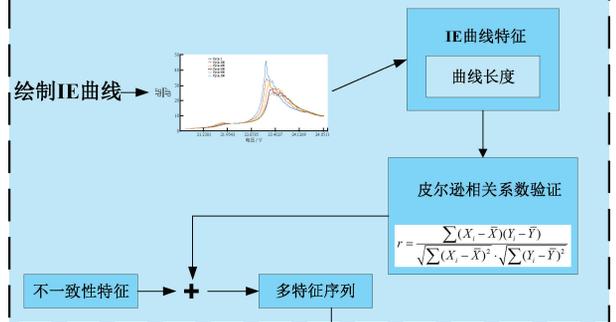
$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (27)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (28)$$

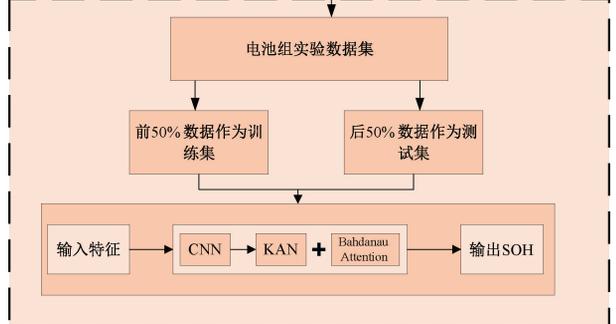
步骤1) 数据测量



步骤2) 特征提取



步骤3) 模型训练



步骤4) 估计结果

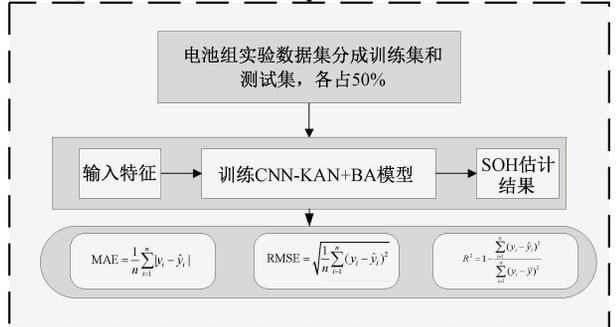


图 7 实验步骤

Fig. 7 Experimental steps

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (29)$$

式中: n 表示充放电循环次数; y_i 表示真实 SOH 值; \bar{y} 表

示平均真实的 SOH 值; \hat{y}_i 表示估计的 SOH 值。另外求得的 MAE 和 RMSE 的值越小表示模型估计的精准度越高,对于 R^2 的值,其越接近 1 表示模型的拟合效果越好。

计算出电池组 IE 曲线典型特征和不一致性相关特征与电池组 SOH 之间的皮尔逊相关性系数。其计算结果如表 1 所示。

表 1 各类特征对 SOH 的皮尔逊相关性对比

Table 1 Comparison of Pearson correlation coefficients of various features with SOH

特征类型	特征	相关系数
组整体特征	IE 曲线长度	0.908
	IE 曲线面积	0.676
	IE 曲线峰值	0.899
组内电压不一致性特征	电压峰度	0.619
	电压中位数绝对偏差量	0.931
组内温度不一致性特征	电压方差	0.495
	温度峰度	0.929
	温度中位数绝对偏差量	-0.868
	温度方差	-0.633

从表 1 可以看到,IE 曲线长度、电压中位数绝对偏差量和温度峰度量分别对 SOH 表现出较高的皮尔逊相关性(0.908、0.931、0.929)。IE 曲线长度反映电化学反应的路径复杂度,与电池电极材料局部老化及动力学分散程度直接相关;电压中位数绝对偏差量量化了电池组内单体的电压离散程度,表征因不一致性引起的容量损失;温度峰度刻画温度分布的集中性与异常热点,指向热行为与老化状态的关联。因此,选取 IE 曲线长度作为电池组整体老化特征,选择电压中位数绝对偏差量和温度峰度作为不一致性特征,构建用于电池组 SOH 估计的多尺度特征体系。

针对曲线长度与面积因离散采样可能产生的数值误差,实验采用固定的采样频率(30 s/点)以保持原始波形信息,并选用梯形积分法与欧氏距离公式进行计算,以降低离散化误差;在统计分析层面,针对电池组样本量有限(6 节)可能引入的统计偏差,采用 MAD 等稳健统计量评估组内离散程度,并辅以多周期滑动窗口平滑处理,以抑制异常波动并增强老化趋势的稳定性。

提出的 CNN-KAN-BA 模型中,CNN 用于捕捉时间序列的局部动力学特征,KAN 用于构建 SOH 衰退过程中的非线性交互关系,Bahdanau 注意力层则对不同时间片段的特征进行了加权,从而突出了对最终 SOH 估计的关键捕捉学习阶段。将训练数据和测试数据均匀分配,利用训练数据对 CNN-KAN-BA 模型进行训练,最终的参数设置如表 2 所示。随后,将建立的 CNN-KAN-BA 模型对测试数据进行估计,其效果如图 8 所示。

表 2 模型参数设置

Table 2 Model parameter settings

模块	参数配置	功能概述
CNN	Filters = 16, KernelSize = 5, PoolingSize = 2, Dropout = 0.1	提取随时间衰减过程中的局部特征
KAN	节点数 = 128, 激活类型 = B-样条函数	建模 SOH 衰退过程中的非线性交互关系
Bahdanau Attention	Dense(hidden_dim) + Dense(1) + softmax	强调不同时间阶段对 SOH 的相对重要性
Output	Dense(1), L2 正则化 = 1×10^{-4}	完成 SOH 值的最终回归

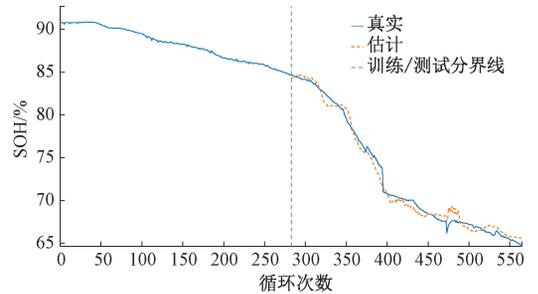


图 8 CNN-KAN-BA 模型 SOH 估计效果

Fig. 8 The effect diagram of SOH estimation by CNN-KAN-BA model

实验最终评估参数如表 3 所示。

表 3 测试数据的估计结果各指标

Table 3 Estimated results of the test data for each indicator (%)

MAE	RMSE	R^2
0.587 4	0.699 0	98.89

为了进一步验证所提的锂电池组健康状态估计方法的可行性和有效性,在此开展了特征对比的实验。分别提取电池组老化实验数据在恒流充电阶段的平均电压、恒压充电阶段的平均电流和增量容量曲线的曲线长度 3 个典型特征,利用提出的 CNN-KAN-BA 模型进行训练,并得出各特征最终估计电池组 SOH 的效果。实验对比结果如图 9 所示。

本文实验所选用的特征以及对比的 3 个典型特征的最终评估指标如表 4 所示。

表 4 各类特征评估指标

Table 4 Various characteristic evaluation indexes (%)

各类特征	MAE	RMSE	R^2
所用特征	0.587 4	0.699 0	98.89
平均电压	2.267 6	2.962 9	79.68
平均电流	1.494 7	1.999 9	90.74
IC 曲线长度	2.108 4	2.648 9	83.75

在各类特征的 SOH 估计性能对比中,所提出的多尺度特征表现最优,MAE 为 0.587%,RMSE 为 0.699%, R^2 达到 98.89%,显示出极高的估计精度和拟合度。恒压充

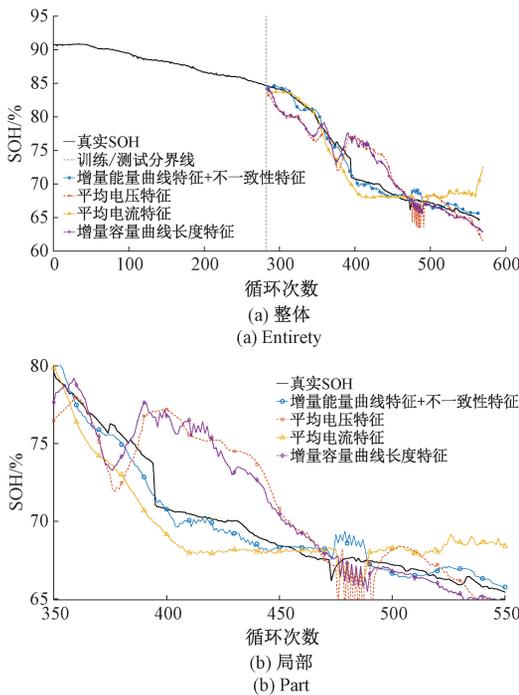


图 9 各类特征 SOH 估计效果对比

Fig. 9 Comparison of various characteristic SOH estimation effects

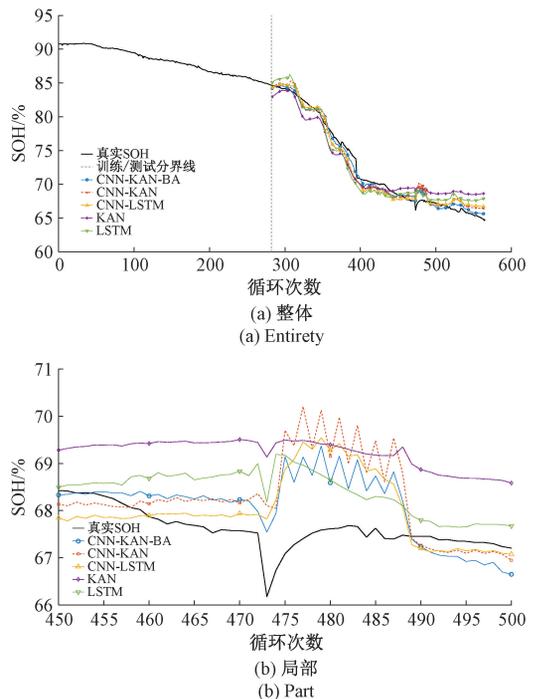


图 10 各模型 SOH 估计效果对比

Fig. 10 Comparison of SOH estimation effects of each model

电阶段的平均电流特征次之。ICA 曲线长度特征的表现中等。而恒流充电阶段的平均电压特征表现相对较差, R^2 仅为 79.68%。实验结果表明, 结合增量能量分析曲线长度特征和温度不一致性特征的多尺度特征在电池组 SOH 估计中具有显著优势, 能够更准确地反映电池的健康状态, 而单一电压或电流特征的估计精度相对有限。

将提出的 CNN-KAN-BA 方法与其他深度学习方法开展了对比。分别使用 CNN-KAN、CNN-LSTM、KAN、LSTM 方法基于训练数据建立模型, 并对测试数据开展了验证。模型对比的实验结果如图 10 所示。各个对比指标如表 5 所示。

表 5 各模型评估指标

Table 5 Evaluation indexes of each model (%)

模型	MAE	RMSE	R^2
CNN-KAN-BA	0.587 4	0.699 0	98.89
CNN-KAN	0.897 6	1.099 7	97.26
CNN-LSTM	0.917 2	1.099 4	97.26
KAN	1.647 0	1.896 5	91.86
LSTM	1.369 1	1.597 6	94.22

通过上面各模型对电池组 SOH 估计的效果, 各个方法均展示了良好的估计结果, 这说明所提出的特征具有普适性。CNN-KAN 模型由于结合 CNN 提取局部特征与 KAN 进行非线性映射, 在短期 SOH 估计上表现优于 CNN-LSTM 模型, 但因缺乏时间序列建模, 长期估计误差

较大。CNN-LSTM 模型具备时间依赖建模能力, 适用于长期估计, 但在 SOH 变化剧烈阶段, 受梯度消失影响, 估计精度下降。LSTM 模型易忽略多尺度特征和关键信息, 难以充分挖掘复杂非线性关系, 导致 SOH 的估计效果一般。另外, KAN 模型仅依赖非线性映射, 缺乏特征提取和时间建模能力, 整体估计效果最差。而提出的 CNN-KAN-BA 模型, 通过 CNN 提取局部特征、KAN 实现非线性特征映射, 并借助 BA 聚焦关键时间步信息, 较为全面地学习了电池组 SOH 的退化规律, 在锂离子电池组 SOH 估计任务中表现较好。RMSE 和 MAE 均显著低于其他对比模型, R^2 也显著高于其他模型训练的结果, 达到了 98.89%, 说明其在 SOH 估计中的拟合精度更高, 误差更小; 尽管 CNN-KAN 模型能够提取局部特征并实现非线性映射, 但其缺乏对时间序列依赖关系的建模能力, 导致在 SOH 退化趋势拟合方面仍存在一定不足; 而 CNN-LSTM 模型具备时序建模能力, 但未融合 KAN 的非线性特征优化, 因而在复杂工况下的估计精度仍逊于所提出的 CNN-KAN-BA 模型。与此同时, 单独使用 KAN 模型进行建模时, 缺乏 CNN 对增量能量曲线等局部特征的提取能力, 使得其整体估计效果较弱。

为系统分析不同结构模块对电池 SOH 估计性能的影响, 本文围绕卷积特征提取、非线性函数建模以及时序注意力机制 3 个核心因素, 设计并开展了多组消融实验。在保持数据集划分、特征输入及训练策略一致的前提下,

分别构建了如下对比模型:仅采用卷积神经网络的 CNN 模型;在 CNN 基础上引入 Bahdanau 注意力机制的 CNN-Attention 模型;仅采用 KAN 的非线性建模模型;以及在 KAN 结构中引入 Bahdanau 注意力机制的 KAN-Attention 模型。通过对上述不同结构组合的预测性能进行对比分析,可以定量评估各模块在特征提取、时序信息聚合及非线性退化建模中的作用,从而进一步验证所提出模型结构设计的合理性与有效性。各组消融实验的结果如图 11 所示。各组消融实验的评估指标如表 6 所示。

强化全局非线性建模,BA 进一步提升关键信息利用效率,三者协同作用显著提升了电池 SOH 估计性能。

5 结 论

针对当前锂离子电池组 SOH 估计方法的不足,本文提出了一种基于增量能量和不一致性特征的锂离子电池组 SOH 估计方法。通过提取增量能量曲线长度作为整体特征,结合组内电压中位数绝对偏差和温度峰度的不一致性特征,形成高效的多尺度特征。通过搭建 CNN-KAN-BA 混合深度学习模型进行训练,以实现高精度 SOH 估计。实验结果表明,该方法能够准确估计出电池组 SOH 值,并通过对比实验,进一步确定了该方法的可行性和优越性,均方根误差和平均绝对误差均低于 1%, R^2 超过了 98%,达到了很好的估计效果,解决了锂离子电池组的 SOH 精确估计问题。尽管该方法在所构建的实验数据集和工况条件下表现出良好的估计精度,其模型性能仍在一定程度上依赖于数据分布及工况一致性,对于不同电池类型、倍率条件或更复杂运行环境下的泛化能力仍有待在后续研究中进一步验证。

下一步的研究计划是将提出的 SOH 估计方法应用于新能源汽车、储能系统的电池模组(包),在实际测试中进一步验证和优化提出的方法。

参考文献

- [1] WANG G, SUN L, WANG A, et al. Lithium battery remaining useful life prediction using VMD fusion with attention mechanism and TCN [J]. Journal of Energy Storage, 2024, 93: 112330.
- [2] NYAMATHULLA S, DHANAMJAYULU C. A review of battery energy storage systems and advanced battery management system for different applications: Challenges and recommendations [J]. Journal of Energy Storage, 2024, 86: 111179.
- [3] ZHANG S, GUO X, DOU X, et al. A rapid online calculation method for state of health of lithium-ion battery based on coulomb counting method and differential voltage analysis [J]. Journal of Power Sources, 2020, 479: 228740.
- [4] BIAN X, WEI Z, LI W, et al. State-of-health estimation of lithium-ion batteries by fusing an open circuit voltage model and incremental capacity analysis [J]. IEEE Transactions on Power Electronics, 2021, 37(2): 2226-2236.
- [5] OBREGON J, HAN Y R, HO C W, et al. Convolutional autoencoder-based SOH estimation of lithium-ion batteries using electrochemical impedance spectroscopy [J]. Journal of Energy Storage, 2023, 60: 106680.

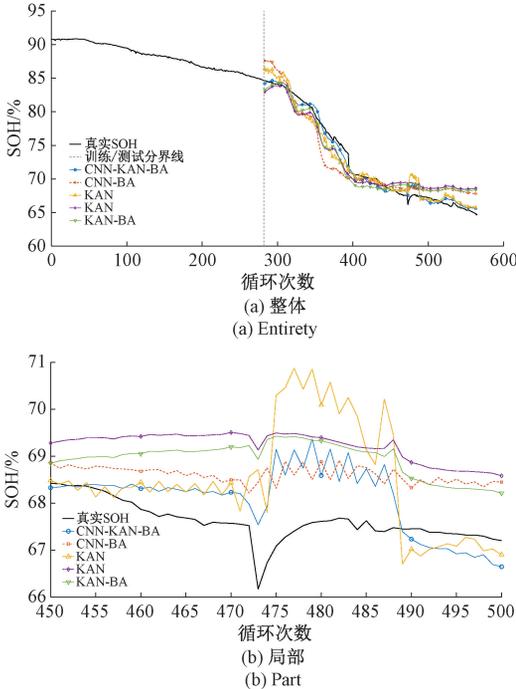


图 11 各模型 SOH 估计效果对比

Fig. 11 Comparison of SOH estimation effects of each model

表 6 各模型评估指标

Table 6 Evaluation indexes of each model (%)

模型	MAE	RMSE	R^2
CNN-KAN-BA	0.587 4	0.699 0	98.89
CNN	1.867 3	2.300 3	88.02
CNN-BA	1.101 1	1.398 7	95.57
KAN	1.647 0	1.896 5	91.86
KAN-BA	1.511 2	1.755 8	93.02

消融实验结果表明,完整的 CNN-KAN-BA 模型在各项指标上均取得最优性能。其中,CNN 模块主要用于提取退化特征中的局部时序变化与短期模式,但单独使用时对全局非线性退化关系的表征能力有限,导致预测精度较低。KAN 模块通过可解释的非线性映射增强了对全局退化趋势的建模能力,但缺乏对局部细节特征的充分刻画。引入 BA 机制后,模型能够自适应地强调对 SOH 变化贡献更大的关键特征与时间片段,从而有效抑制冗余信息。综合来看,CNN 提供局部特征感知,KAN

- [6] 吴绪,杨丽君,肖滢琳,等. 电池动态电化学阻抗谱的无源检测方法研究[J]. 仪器仪表学报,2024,45(12): 107-117.
WU X, YANG L J, XIAO Y L, et al. Research on passive detection method for battery dynamic electrochemical impedance spectroscopy [J]. Chinese Journal of Scientific Instrument, 2024, 45(12): 107-117.
- [7] 黄海宏,汪宇航,王海欣. 基于锂电池等效电路模型的阻抗曲线拟合算法[J]. 仪器仪表学报,2021,41(8): 70-77.
HUANG H H, WANG Y H, WANG H X. Impedance curve fitting algorithm based on equivalent circuit model of lithium-ion battery [J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 70-77.
- [8] GAO Y, LIU K, ZHU C, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model [J]. IEEE Transactions on Industrial Electronics, 2021, 69(3): 2684-2696.
- [9] ZHOU D, LIANG J, LI F, et al. SOH prediction of lithium-ion batteries using a hybrid model approach integrating single particle model and neural networks[J]. Journal of Energy Storage, 2024, 104: 114579.
- [10] AGUDELO B O, ZAMBONI W, MONMASSON E. Application domain extension of incremental capacity-based battery SoH indicators [J]. Energy, 2021, 234: 121224.
- [11] CHE Y, DENG Z, LI P, et al. State of health prognostics for series battery packs: A universal deep learning method[J]. Energy, 2022, 238: 121857.
- [12] FENG X, WENG C, HE X, et al. Online state-of-health estimation for Li-ion battery using partial charging segment based on support vector machine [J]. IEEE Transactions on Vehicular Technology, 2019, 68(9): 8583-8592.
- [13] 丁阳征,贾建芳. 改进 PSO 优化 ELM 预测锂离子电池剩余寿命[J]. 电子测量与仪器学报,2019,33(2): 72-79.
DING Y ZH, JIA J F. Remaining useful life prediction of lithium-ion batteries using improved PSO optimized ELM[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 72-79.
- [14] YANG N, SONG Z, HOFMANN H, et al. Robust state of health estimation of lithium-ion batteries using convolutional neural network and random forest [J]. Journal of Energy Storage, 2022, 48: 103857.
- [15] CHAE S G, BAE S J, OH K Y. State-of-health estimation and remaining useful life prediction of lithium-ion batteries using DnCNN-CNN [J]. Journal of Energy Storage, 2025, 106: 114826.
- [16] ANSARI S, AYOB A, LIPU M S H, et al. Jellyfish optimized recurrent neural network for state of health estimation of lithium-ion batteries [J]. Expert Systems with Applications, 2024, 238: 121904.
- [17] 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 CH L, ZHAO SH SH, HE Y G. State-of-health estimate for lithium-ion battery using information entropy and PSO-LSTM [J]. Journal of Mechanical Engineering, 2022, 58(10): 180-190.
- [18] HONG J, LI K, LIANG F, et al. A novel state of health prediction method for battery system in real-world vehicles based on gated recurrent unit neural networks [J]. Energy, 2024, 289: 129918.
- [19] 张朝龙,罗来劲,刘惠汉,等. 基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计[J]. 电子测量与仪器学报,2023,37(1):167-176.
ZHANG CH L, LUO L J, LIU H H, et al. State-of-health estimation for lithium-ion batteries based on incremental energy method and BiGRU-Dropout [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 167-176.
- [20] XU H, WU L, XIONG S, et al. An improved CNN-LSTM model-based state-of-health estimation approach for lithium-ion batteries [J]. Energy, 2023, 276: 127585.

作者简介



张朝龙,2018 年于合肥工业大学获得博士学位,现为金陵科技学院教授,主要研究方向为锂电池智能管控、故障诊断和预测。

E-mail: zhangchaolong@126.com

Zhang Chaolong received the Ph. D. degree from Hefei University of Technology in 2018. Now he is a professor at Jinling Institute of Technology. His main research interests include intelligent control of lithium battery, fault diagnostics and prognostics.



王安祥(通信作者),2023 年于芜湖学院获得学士学位,现为金陵科技学院硕士研究生,主要研究方向为锂电池健康状态估计及寿命预测。

E-mail: 15005507945@163.com

Wang Anxiang (Corresponding author) received his B. Sc. degree from the School of Wuhu University in 2023. Now he is a M. Sc. candidate at Jinling Institute of Technology. His main research interests include state-of-health estimation and lifespan prediction of lithium-ion batteries.