

储能测试与评价



基于AED-CEEMD-Transformer的锂离子电池健康状态估计

陈锐¹, 丁凯¹, 祖连兴¹, 许青松¹, 王宗标¹, 罗大思¹, 苏敬江¹, 胡圣¹, 毛冀龙²

(¹长园深瑞能源技术有限公司, 广东 珠海 519000; ²强电磁工程与新技术国家重点实验室 (华中科技大学), 湖北 武汉 430074)

摘要: 锂电池健康状态(state of health, SOH)的精确预测评估对电池设备安全稳定运行极为重要, 通过对SOH的快速准确预测, 可以提高电池设备的安全性并降低出现故障的风险。针对难以精确预测锂离子电池SOH的问题, 本文采用电池容量作为SOH的指标, 提出一种利用平均欧几里得距离(average euclidean distance, AED)和互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)方法建立基于Transformer网络结构的锂离子电池健康状态估计算法。首先, 我们利用AED评估电池数据库中的电池与待预测电池初期循环容量之间的相似度, 并选出具有相似容量退化趋势的电池作为训练集以提高模型的训练速度, 然后利用CEEMD方法将电池容量曲线分解为容量再生部分以及退化趋势部分, 将各个分量分别使用Transformer网络来建立锂电池退化模型, 进而得到锂离子电池的SOH预测结果。本文使用分别来自斯坦福大学与马里兰大学的两个具有不同充放电策略与不同测试环境下的锂离子电池数据集来验证了所提出的电池预测算法的准确性。本文所提模型的均方根误差均能控制在4%以内, 具有较好的精确性, 并通过与基于LSTM、RNN、GRU的常用锂离子电池健康状态估计算法结果的比较, 验证了所提出估计方法的优越性。

关键词: 锂离子电池; Transformer网络; 电池健康状态; 平均欧几里得距离; 联合互补集合经验模态分解

doi: 10.19799/j.cnki.2095-4239.2023.0440

中图分类号: TM 911

文献标志码: A

文章编号: 2095-4239 (2023) 10-3242-12

Prediction of state of health of lithium-ion batteries based on the AED-CEEMD-Transformer network

CHEN Rui¹, DING Kai¹, ZU Lianxing¹, XU Qingsong¹, WANG Zongbiao¹, LUO Dasi¹,
SU Jingjiang¹, HU Sheng¹, MAO Jilong²

(¹CYG SUNRI CO., LTD., Zhuhai 519000, Guangdong, China; ²State Key Laboratory of Advanced Electromagnetic Engineering and Technology (Huazhong University of Science and Technology), Wuhan 430074, Hubei, China)

Abstract: The accurate prediction and assessment of the state of health (SOH) of lithium-ion batteries are extremely important for the safe and stable operation of the battery equipment. Quickly and accurately predicting the SOH can enhance the safety of battery devices and reduce the failure risk. This study proposes an algorithm for estimating the health status of lithium-ion batteries based on the transformer network structure to address the challenge of accurately predicting their SOH. This algorithm utilizes the battery capacity as the SOH indicator, incorporating the average Euclidean distance (AED) and complementary ensemble empirical mode decomposition (CEEMD) methods. First, the AED is used to assess the similarity between

收稿日期: 2023-06-25; 修改稿日期: 2023-07-14。

第一作者及通信联系人: 陈锐 (1977—), 男, 硕士, 高级工程师, 研究方向为电化学储能设备及系统, E-mail: chenrui@cyg.com。

引用本文: 陈锐, 丁凯, 祖连兴, 等. 基于AED-CEEMD-Transformer的锂离子电池健康状态估计[J]. 储能科学与技术, 2023, 12(10): 3242-3253.

Citation: CHEN Rui, DING Kai, ZU Lianxing, et al. Prediction of state of health of lithium-ion batteries based on the AED-CEEMD-Transformer network[J]. Energy Storage Science and Technology, 2023, 12(10): 3242-3253.

the initial cycle capacities of the batteries in the battery database and the battery to be predicted. The batteries in the battery database with similar capacity degradation trends are selected as the training set for improving the model's training speed. The CEEMD method is then employed to decompose the battery capacity curve into the capacity regeneration and degradation trend parts. The degradation models for the lithium-ion batteries are separately established using the transformer network for each component. As a result, the predictions for the SOH of lithium-ion batteries are obtained. This study validates the accuracy of the proposed battery prediction algorithm using two lithium-ion battery datasets from Stanford University and the University of Maryland. These datasets comprise batteries tested under different charge-discharge strategies and testing environments. The root mean square error of the proposed model can be controlled within 4%, demonstrating its high accuracy level. The superiority of the proposed estimation method is validated by comparing it with the commonly used lithium-ion battery health estimation algorithms based on the long short-term memory, recurrent neural network, and gated recurrent unit.

Keywords: lithium-ion battery; transformer network; state of health; average euclidean distance; complementary ensemble empirical mode decomposition

在双碳目标的背景下, 国家大力扶持新能源, 电池储能因其能量密度高、污染低、使用寿命长的特性而得到了迅速发展^[1]。在基于电池的能源系统中, 电池系统的健康状态(state of health, SOH)是一个非常重要的监控值^[2]。电池的 SOH 预测指的是依照电池的历史运行数据预测接下来一段时间内的电池健康状态并给出寿命终点(end of life, EOL)预警^[3]。EOL 指的是电池到达一个濒临不稳定的状态, 一般来说, 当电池达到 EOL 时, 电池容量会迅速退化, 影响设备的工作效率^[4]。因此, 准确预测 SOH 有助于优化设备的使用, 甚至避免事故发生。

然而, 锂电池复杂的内部化学结构和不同的工作环境导致锂电池的降解过程相当复杂。因此, 很难准确预测锂电池的 SOH。目前, SOH 预测研究按照预测模型的不同可以分为以下两类: ①基于物理模型的方法。基于物理模型的方法基于电池的物理化学现象并进行建模^[5]。该方法在熟悉电池内部反应的基础上能够提供电池退化的物理解释。其主要方法主要包括等效电路模型, 电化学模型和经验退化模型^[6], 但是由于电池内部的化学相互作用较多, 很难从单一的反应推断全局, 考虑所有的化学反应又不切实际。同时, 模型的建立依赖于电池的内部参数, 而内部参数在外部很难观测到, 这也进一步影响到了该方法的实用性。②数据驱动的方法。

与基于模型的方法相比, 数据驱动的方法既不考虑电池的内部反应, 也不分析电池失效的原因, 而是将电池系统视作黑盒, 从电池的历史数据中发现并学习电池的退化规律进行预测。因此, 数据驱动方法被广泛应用于锂离子电池 SOH 预测中, 包括神经网络^[7]、支持向量机(SVM)^[8]、高斯过程回归(GPR)^[9]、相关向量机(RVM)^[10]等。其中基于神经网络方法的电池寿命预测是当前的学术热点问题。为了实现更稳健的 SOH 预测, 文献[11]使用深度神经网络来估计电池的充电曲线并由此计算电池的 SOH。文献[12]结合卷积神经网络与双向长短期记忆网络用于电池的 RUL 预测。文献[13]使用长短期记忆网络与自回归嵌套序列模型聚合信道和周期信息来对健康状态预测。文献[14]综合残差神经网络和双向长短期记忆网络的并加入注意力机制来对电池进行预测。通常, 这些方法基于电池在较长时间段内退化的信息来预测 SOH, 但是基于 RNN 结构的神经网络不可避免地会陷入长期依赖性问题, 较长时间段内的退化信息会影响其预测的性能。基于注意力结构的 Transformer 模型^[15]则最近被提出用于序列建模, 并正在逐步探索其他用途, 包括机器翻译、音乐生成等。Transformer 网络模型通过使用自注意机制完全抛弃了传统的水平方向的 RNN 传播, 通过连续叠加自注意层仅在垂直方向传播。这样, 每一层的计算都可以并行执行, 并且可以通过

GPU来加速。

电池容量再生是估计SOH需要考虑的一个因素^[16]。容量再生表现为电池下一次循环可用容量的突然增加，其特点是短暂且迅速。容量再生增加了容量预测的不确定性。因此，在预测电池寿命时，需要考虑到电池容量再生对于预测的精度影响^[17]，针对此种现象，文献[18]利用EMD分解进而建立基于高斯过程回归的锂离子电池SOH预测模型。文献[19]使用EMD分解之后得到的各个子序列建立自回归移动平均(ARMA)模型。而基于EMD改进的互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)在电池健康状态预测中也有应用^[20]，相较于EMD能实现更为准确的预测精度。

本文设计了一种基于AED-CEEMD-Transformer的网络模型。首先，平均欧几里得距离(average euclidean distance, AED)被用于从历史测试数据库中挖掘与目标电池最相似的测试数据，然后补充待预测电池的短期测试数据来作为训练集。最后，通过应用互补集合经验模态分解(CEEMD)技术，将原始SOH数据序列分解成具有不同频率的几个分量和一个残差。前者包含关于容量再生的信息，后者包含关于寿命退化趋势的信息。为了解决长期依赖的问题，采用Transformer模型分别对寿命退化部分和容量恢复部分进行预测。最后，将这两个预测组合起来，以获得最终的容量预测输出。为了验证所提出方法的有效性，我们将所提网络模型所获得的结果与常用的几种神经网络模型得到的结果进行了比较以验证方法的有效性。

1 网络模型

1.1 数据的标准化

为了减少输入数据分布变化对神经网络的影响，必须对数据进行归一化。设 $x=\{x_1, x_2, \dots, x_n\}$ 表示长度为 n 的容量输入序列，使其映射为 $(0,1]$ ：

$$x' = \frac{x}{C_0}, \quad (1)$$

其中 C_0 表示额定容量。

1.2 基于AED的迁移性测量

给定电池平台中具有相同阴极材料系统的电池，它们的容量数据存在一定的相似性。迁移性测量用于测量目标电池和电池平台中的其他电池之间

的容量退化曲线的相似性。选择作为参考电池的电池与目标待预测电池相较于其他电池应该最相似，并且具有最高的可转移性，这意味着目标电池和参考电池的曲线不仅应该彼此接近，而且应该具有相似的趋势。选取更好的参考电池的容量数据可以减少训练集数量并减少训练时间。

通常，迁移性测量是基于相似性测量方法设计的，该方法可以从许多电池中迅速找到最适合目标电池的参考电池，已经有学者提出了各种相似性测量方法，包括马氏距离(Mahalanobis distance)以及欧几里得距离(Euclidean distance)等。本文使用平均欧几里得距离(Average Euclidean distance, AED)测量方法来评估电池平台下多种电池之间的曲线距离和趋势相似性。

欧几里得距离是一种几何距离测量，由欧几里得空间中两点之间的距离导出。作为计算距离的自然度量，它有多种应用。通过欧几里得距离测量的两个电池SOH变化趋势的相似性可以定义如下：

$$ED_{obj, k} = \|C_{obj} - C_k\|_2 = \sqrt{\sum_{k=1}^n (c_{obj, k} - c_{t, k})^2} \quad (2)$$

式中， $ED_{obj, k}$ 是目标电池与电池平台中第 t 个电池之间的欧几里得距离， C_{obj} 是包含目标电池的容量数据 $\{c_{obj, 1}, c_{obj, 2}, \dots, c_{obj, n}\}$ 的容量向量， C_t 是包含第 i 个电池 $\{c_{t, 1}, c_{t, 2}, \dots, c_{t, n}\}$ 的容量向量， n 代表容量曲线包含从1到 n 个循环的数据。

为了消除容量向量的长度(n)变化引起的可转移性测量结果 $ED_{obj, k}$ 的波动，在欧几里得距离中引入平均运算，得到基于AED的迁移性测量方法。在电池数据库中，任意两组电池的 n 维容量向量之间的AED由式(3)给出

$$AED_{object} = \overline{ED_{obj, t}} = \overline{ED_{obj, k}}/n \quad (3)$$

在模型训练之前，使用公式(3)计算目标电池和电池平台的历史数据库中的每个电池之间的所有AED，并按升序排列，以选择距离最小的电池作为参考电池。由于结合了欧几里得距离和平均计算操作过程，通过曲线接近度和趋势一致性可以容易地选择与目标电池具有更好曲线接近度和趋势一致性的参考电池。通过使用所选取的参考电池来训练模型，避免了用整个电池数据库来训练模型，减少了模型的训练量，同时也减少了训练时间，提高运算效率。

1.3 互补集合经验模态分解 CEEMD

互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)是在经验模态分解(empirical mode decomposition, EMD)的基础上改进而来。EMD 是一种经典的具有处理非线性和非平稳数据的方法^[21]。该方法基于瞬时频率和本征函数(intrinsic mode function, IMF)的概念, 假设一个时间序列中同时存在许多不同的模态, 通过筛选过程将模态提取并逐步分解为有限个独立的固有模态函数分量和平滑趋势分量。由于 EMD 的实现依赖于信号自身的时域特征而没有预定义的基函数, 因此它的实现简单且具有自适应性。

然而, EMD 方法的局部特性可能在一个模态中产生尺度非常不同的震荡, 或者在不同模态中产生尺度相似的震荡, 具有“模式混合”的缺点, 为了解决这个问题, 有学者提出了一种名为集合经验模式分解(ensemble empirical mode decomposition, EEMD)的噪声辅助数据分析方法, 其中真实分量是集合试验的平均值, 每个试验都是添加白噪声数据的 EMD 结果。然而, 随着平均次数的增加, EEMD 方法的实现变得耗时, 此外, 添加白噪声的幅值和迭代次数依靠人为的经验设置, 而不是自适应添加, 设置不当时, 平均次数一般在几百次, 非常耗时。文献[22]提出了 CEEMD 方法, 该方法在每个分解阶段的残差中加入正负成对的自适应辅助白噪声, 克服了重构误差大、分解完备性差的问题, 同时减少了平均次数到几十次, 可以以较低的计算成本提供更好的分解结果^[23]。

1.4 TRANSFORMER 网络模型

在 RNN 结构中, 受链式结构影响, 每一个隐状态都依赖于前一步的隐状态, 必须从前向后必须逐个计算, 每次只增加单个步长, 这带来了长期依赖性问题, 为了避免这一问题, 伴随着深度学习方法的发展, 使用基于 Transformer 网络模型来进行序列的预测逐渐受到了学者们的关注, Transformer 网络模型首次被提出是应用于自然语言的处理^[16], 随后拓展到了计算机视觉等相关的领域。与传统的 RNN 网络模型不同, Transformer 模型没有必须从前向后逐个计算这样的约束, 输入序列可以被并行处理, 由此获得了更快的训练速

度。同时, Transformer 模型也具备了更强的长期依赖建模能力, 更适用于处理长序列相关任务, 能解决类 RNN 模型面对长序列时无法完全消除梯度消失和梯度爆炸的问题。在时间序列上下文依赖方面, Transformer 可以同时建模长期依赖和短期依赖。

1.4.1 注意力机制

注意力机制通过学习输入元素的相关性, 使得神经网络架构能够自动权衡任意输入的局部相关性, 并在执行序列处理计算时考虑这种权重。其核心思想是计算输入序列的权重分布, 为更相关的元素分配更大的权值。简而言之, 注意力机制是将一组键(Key)、值(Value)向量对和查询(Query)向量经过计算后得到相应的输出(Output)。

在计算过程中, 首先需要将查询和每个键进行相似度计算得到对应的权重, 如公式(4)所示, 用来计算相似度的函数选择包括点积、拼接、感知机等。其中 Q 表示查询, K 表示键。

$$f(Q, K_i) = \begin{cases} Q^T K_i \\ Q^T W_o K_i \\ W_o[Q; K_i] \\ v^T \tanh(W_o Q + U_o K_i) \end{cases} \quad (4)$$

接着使用 softmax 函数对上述权重做归一化处理:

$$a_i = \text{softmax}[f(Q, K_i)] = \frac{\exp[f(Q, K_i)]}{\sum_j \exp[f(Q, K_j)]} \quad (5)$$

最后, 将归一化后的权重和相应的值进行加权求和得到最后的注意力计算结果:

$$\text{Attention}(Q, K, V) = \sum_i a_i V_i \quad (6)$$

通过注意力机制的加入, 模型能更好地提取对当前任务更关键的信息并忽略不重要的信息以更好地匹配当前的计算任务。

1.4.2 自注意力机制

相较上文提到的注意力机制, Transformer 模型使用中的自注意力(self-attention)机制更好地解决了长距离依赖的问题。在 Transformer 中, 对于给定的查询 $Q \in \mathbb{R}^{N \times D_k}$ 、键 $K \in \mathbb{R}^{M \times D_k}$ 、值 $V \in \mathbb{R}^{M \times D_v}$, 有缩放点积注意力定义:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (7)$$

其中 N 和 M 表示查询和键(或值)的长度, D_k 、

D_v 表示键(或查询)和值的维度。缩放因子 $1/\sqrt{d_k}$ 用于归一化,使得训练过程中梯度保持稳定,从而避免梯度消失问题的出现。

不同于其他模型只使用单个注意力模块,Transformer使用多头注意力模块并行运算,其中 D_m 维的原始查询、键和值矩阵分别用学习到的 H 个不同的向量投影到 D_q 、 D_k 和 D_v 维空间。根据公式(8)对每个投影查询、键和值计算,分别输出注意力权重。然后,模型将所有输出连接起来并将它们投影回 D_m 维表示。

$$\begin{aligned} \text{head}_i &= \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \\ \text{Multi}(Q, K, V) &= \text{Concat}(\text{head}_1, \text{head}_H)W^O \end{aligned} \quad (8)$$

1.4.3 位置编码

Transformer模型依靠其精巧的自注意力并行结构,可以进行并行计算并解决了长期依赖性问题,获得了远超同规模LSTM模型的训练速度,但是由于并行计算结构,也带来了上下文关系注入问题。对于Transformer模型而言,序列的顺序关系无法进行直接获取,自注意力模块在计算注意力分布时只能给出输出向量和输入向量之间的权重关系,而不能给出位置信息,因此,需要引入位置编码矩阵 P 。

如公式(9)所示, PE 为二维矩阵,维度跟输入矩阵的维度一样, $2i$ 表示偶数位置, $2i+1$ 表示奇数位置, pos 表示数据点在整个序列中的位置,其特征维度为 d_m 。

$$\begin{aligned} PE_{(\text{pos}, 2i)} &= \sin(\text{pos}/10000^{2i/d_m}) \\ PE_{(\text{pos}, 2i+1)} &= \cos(\text{pos}/10000^{2i/d_m}) \end{aligned} \quad (9)$$

1.4.4 损失函数

在神经网络中的训练阶段,数据集的某个批次

输入模型之后得到输出,即当前模型的预测值,为了提高模型的预测精度,需要利用损失函数的反向传播来更新调整模型的参数,其中,损失函数用来计算得到预测值与真实值之间的损失值。经过模型的更新迭代,损失值会越来越小,小于给定的值或者训练的代数达到终点之后,停止训练。本文采用的损失函数如公式(10)所示。

$$\text{loss}(x, y) = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad (10)$$

1.5 评判标准

为了具现模型进行SOH估计的科学性和精确性,使用均方根误差和平均绝对百分比误差指标组合进行比较。

均方根误差(root mean squared error, RMSE)作为模型对电池SOH估计的评价指标,如公式(11)所示。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (11)$$

平均绝对百分比误差(mean absolute percent error, MAPE):在标准操作条件下,锂离子电池实际容量的预测值与实际容量的真实值之间的误差的绝对值,作为真实值的百分比。

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (12)$$

1.6 预测流程

本文所提出的SOH预测的流程如图1所示,其主要步骤如下:

(1) 准备阶段:根据待预测电池前 n 个循环的容量数据,对比电池数据库中其他电池前 n 个循环的历史容量数据,使用AED方法遍历数据库寻得AED得分最高的电池组,他们具有和待预测电

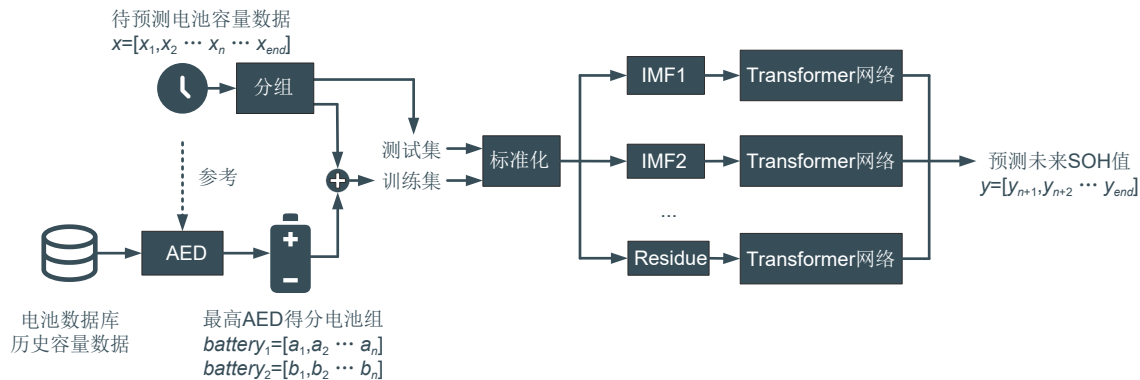


图1 整体预测方法框架

Fig. 1 The overall forecasting methodology framework

池相近的容量变化趋势。将电池组的容量数据和待预测电池的容量数据依图 2 划分为训练集以及测试集。

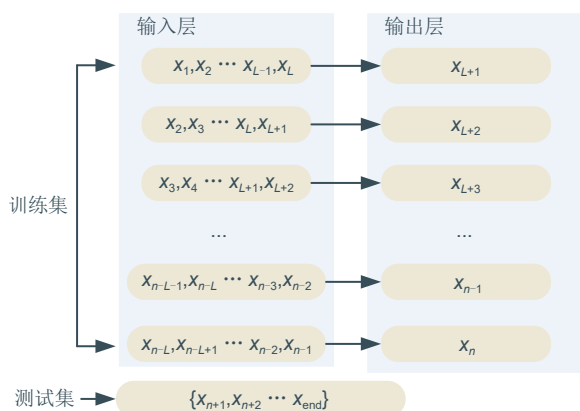


图 2 数据划分流程

Fig. 2 Data Segmentation Process

(2) 训练阶段: 将训练集标准化之后, 进行 CEEMD 分解, 成 N 个 IMF 分量以及一个残值, 然后将每条分量分别进行 Transformer 网络建模, 得到每个分量所对应的神经网络模型。

(3) 预测阶段: 将测试集标准化之后输入模型, 得到所预测的第 n 个循环的 SOH 值, 并更新输入量, 继续预测第 $n+1$ 个循环的 SOH 值, 依次循环直到达到电池的寿命终点。

(4) 评价阶段: 将预测的 SOH 值和真实的 SOH 值之间进行评价指标的计算, 作为所提出模型的性能的评价指标。

本文的数据划分流程如图 2 所示, 其中, 待预测电池的数据按照图示划分为训练集以及测试集, 电池组的数据全部划分为训练集。输入层单次输入数据量由滑动窗口 L 控制, L 取为 64。

2 仿真验证

结合上文所提模型结构, 本文提出基于 AED-CEEMD-Transformer 的网络模型: 首先将待预测电池的容量数据按照一定的比例分为训练集和测试集, 根据测试集的容量数据, 利用 AED 方法找出电池平台中具有相似容量退化趋势的电池数据与待预测电池的循环测试数据一起组成完整的训练集, 然后利用 CEEMD 方法将初始容量数据分解成容量再生部分以及退化趋势部分, 对这两部分分别打包成训练集并分别使用 Transformer 模型进行训练,

最后为了验证模型的有效性, 将测试集用于误差验证。

2.1 实验结果分析

本文选取的电池数据库来自于斯坦福大学^[24], 共选取由 124 个在快速充电条件下循环失效的商用锂离子电池。这些锂离子电池磷酸盐(LFP)/石墨电池由 A123 Systems(APR18650M1A)制造, 在设置为 48 °C 的恒温室中循环。电池的标称容量为 1.1 Ah, 标称电压为 3.3 V。

电池集使用不同的充电策略: 一步或两步快速充电策略进行充电。之后电池以 1C 的速度进行恒流(CC)-恒压(CV)充电, 上限和下限截止电压分别为 3.6 V 和 2.0 V。充电阶段结束之后所有电池以相同的 4C 的速率进行放电。

电池共有三个批次, 本文分为 A、B、C 三组, 三组电池循环实验的时间不同。图 3(a)展示的是随





图 3 电池容量退化曲线

Fig. 3 Battery capacity degradation curve

着循环次数的增加,电池的容量随之下降的曲线图,可以看出,在电池的循环寿命方面,有部分电池的容量迅速下降,有些下降则没有那么明显,不同电池之间的容量退化趋势有很大的差异性,但是也可以看出,循环寿命相似的曲线之间往往趋势也是相似的,这说明如果在预测目标电池的SOH时,找到一个退化趋势与之相近的电池能起到很好的参考作用;在单一容量曲线方面,虽然容量总体呈下降趋势,但是在小范围内有容量的恢复波动,这也是上文所说的容量再生现象。

图3(b)给出的是三组电池的循环寿命的箱线图,图中,橙色的线是中位数,其余分别指上下四分位数,极值,圆圈表示的是异常值。三组电池之间表现了很明显的寿命差异,尤其是B组电池的寿命明显小于其他两组,寿命分布于[300,600]区间,不及其余组别电池的一半,但是其电池之间有最强

的相似性,分布区间很小。其余两组电池寿命的分布差异则很大。

为了剥离出电池容量曲线中的容量再生部分以及退化趋势,使用CEEMD方法对电池容量曲线进行分解得到多段本征函数以及残值。为证明其有效性,图4展示的是某一电池经过CEEMD分解之后所得到的各个分量图。经过分解之后,有4个IMFs和一个残值。IMF1、2、3都具有高频率的波动,其相应地反映了高频容量再生,IMF4的频率波动相对较低。通常来说,多个IMF值一起显示电池的容量再生现象,我们可以用IMFs来描述容量再生现象。残值则与原始SOH值一起绘制在图的最下方。为了定量分析原始的SOH值与残值之间的相关性,本文使用皮尔逊相关性分析两条曲线,其相关系数为0.9949,这意味着残值足以准确描述电池的退化趋势^[25]。




图4 CEEMD分解图

Fig. 4 CEEMD decomposition diagram

抽取电池数据库中A、B、C三组,每组别的前2个电池共6个电池进行验证,并分别使用每个电池的前30%、50%、70%数据作为训练集,为了验证本文所提模型的预测能力,分配相同的训练集,使用LSTM、RNN、GRU等网络模型进行相同的寿命预测并对比分析,为了对比的严

谨性,所有模型统一以MAE作为损失函数进行编译,并采用Adam优化器,学习率设置为0.001,epoch设置为500。输入模型的容量向量均为64个循环长度。对比结果如图5所示。图中,每行为不同电池的预测结果,数据的比例按列区分,红色的竖直虚线是预测的开始点。从图中可以看

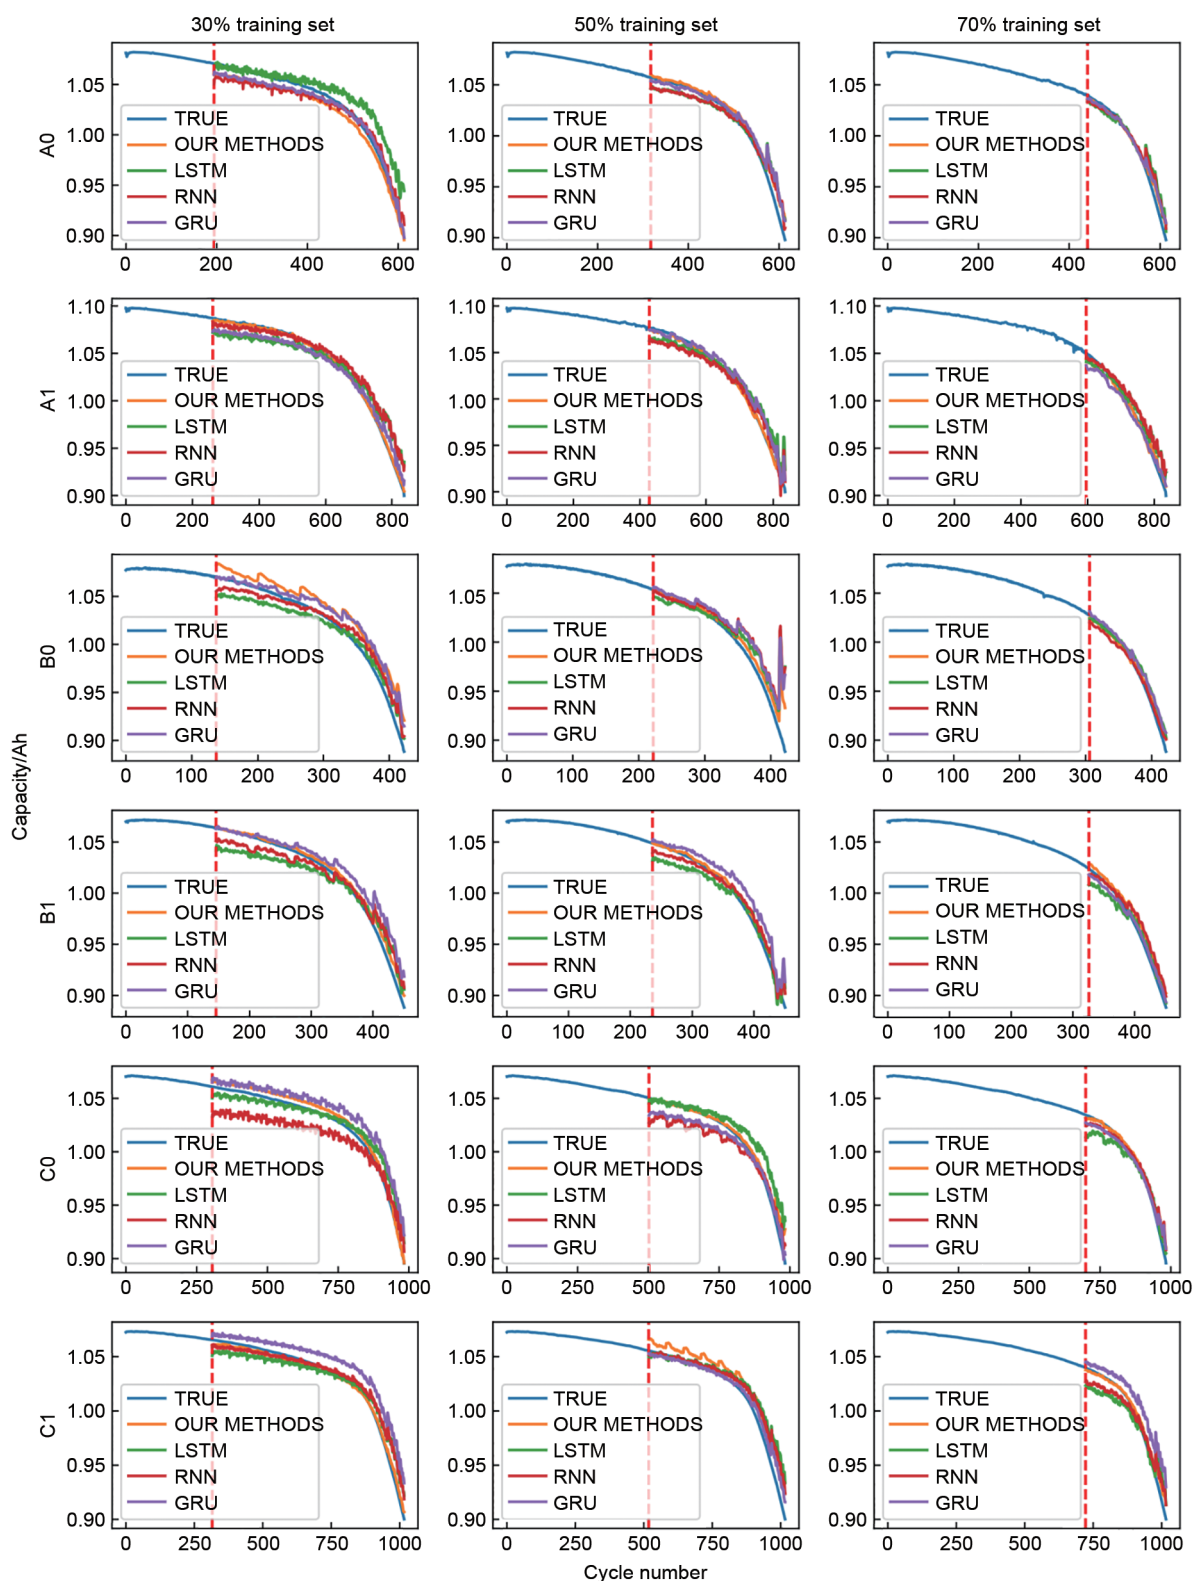


图5 电池估计结果

Fig. 5 Battery estimation results

出, 本文所设计模型所预测的容量曲线与真实的容量曲线较为接近, 并且所预测电池的循环寿

命次数范围分布从 400 到 1000 不等, 证明在较大的寿命区间内, 我们所提方法均有效, 有较

强的适应性。而其他方法与真实值相比有较大的波动。

为了具体展示多种方法之间的预测性能差异,我们还使用两个预定义的指标来评估所提出的方法的预测性能,评估公式如式(10)、(11)所示,具体误差值如表1所示。以电池A0为例,在30%训练集时, RMSE、MAPE 的误差分别为4.59%和3.33%, 小于 LSTM、RNN、GRU 三种方法的 RMSE 误差: 4.98%, 5.13% 以及 5.33%。表中已

经把最小的值加粗显示,可以看出,在不同的训练集比例以及不同的电池下,我们所提方式均有较小的误差数值,这证明,我们所提方法有较强的预测性能,并且不受训练集比例以及电池种类的影响,在不同情况下均能实现寿命预测。也可以看出 LSTM 作为常用的预测模型的优势: 比剩余的两种方法的精度更高,但是 LSTM 是在基于 RNN 模型的基础上进一步发展而导致其也具有长期依赖性的缺点,实际预测效果也表明了长期依赖性的负面影响。

表1 多种方法估计误差指标对比
Table 1 Comparison of multiple methods for estimating error metrics

电池	误差	前 30% 训练集				前 50% 训练集				前 70% 训练集			
		OURS	LSTM	RNN	GRU	OURS	LSTM	RNN	GRU	OURS	LSTM	RNN	GRU
A0	RMSE	0.04599	0.04981	0.05130	0.05337	0.04753	0.05160	0.05322	0.05334	0.04857	0.05027	0.05059	0.05109
	MAPE	0.03332	0.03533	0.03715	0.03857	0.03457	0.03798	0.03993	0.04000	0.03842	0.04049	0.04076	0.04106
A1	RMSE	0.05217	0.05672	0.06219	0.06051	0.05467	0.05906	0.06120	0.06363	0.04996	0.05406	0.05551	0.05541
	MAPE	0.03859	0.04137	0.04570	0.04429	0.04155	0.04562	0.04742	0.04928	0.04073	0.04444	0.04561	0.04542
B0	RMSE	0.04896	0.05504	0.05836	0.05666	0.04810	0.05150	0.05475	0.05305	0.04934	0.05091	0.05258	0.05206
	MAPE	0.03738	0.04130	0.04390	0.04240	0.03744	0.04056	0.04292	0.04162	0.04006	0.04188	0.04319	0.04277
B1	RMSE	0.04890	0.05444	0.05632	0.05516	0.05159	0.05661	0.05782	0.05914	0.04536	0.04943	0.05149	0.05171
	MAPE	0.03676	0.03983	0.04254	0.04176	0.04010	0.04385	0.04506	0.04612	0.03828	0.04139	0.04273	0.04293
C1	RMSE	0.03968	0.04459	0.04657	0.04710	0.04254	0.04748	0.04901	0.04779	0.04229	0.04742	0.04841	0.04808
	MAPE	0.02872	0.03214	0.03331	0.03356	0.03111	0.03482	0.03605	0.03495	0.03308	0.03749	0.03813	0.03783
C2	RMSE	0.04011	0.04501	0.04707	0.04869	0.04270	0.04785	0.05026	0.04898	0.04509	0.04823	0.04889	0.04996
	MAPE	0.02793	0.03223	0.03306	0.03414	0.03043	0.03385	0.03680	0.03554	0.03572	0.03804	0.03870	0.03963

2.2 在其他电池数据库的实验结果

2.1 节的电池数据库中电池之间的差异来自于充电策略的不同,为了验证本文所提方法应用在其他循环策略的电池数据库上的有效性,使用马里兰大学先进生命周期工程中心(center for advanced life cycle engineering, CALCE) 电池数据集中 CS2_33、CS2_34、CS2_35、CS2_36、CS2_37、CS2_38(分别用 CS1、CS2、CS3、CS4、CS5、CS6 表示)共6个电池的充放电实验数据^[14]作为模型的输入数据。电池在放电策略上存在差异,并使用0.5 C 恒定电流充电。

同上文一样分别选取电池前30%、50%、70%数据作为训练集进行预测,预测结果如图6所示,由图6可知,本文所提 AED-CEEMD-Transformer 网络模型对来自 CALCE 电池数据库的6种型号电池的 SOH 估计均有很好的预测效果。表2所示为本文模型在 CALCE 数据集测试的评价指标。可以

看出,除了CS1 电池的 RMSE 较大,大于0.03 之外,其余5种电池的 RMSE 和 MAPE 均较低,通过本文所提模型在 CALCE 电池数据集上的预测结果分析可知,在不同放电策略的数据集下,本文所提网络模型有良好的预测精度,能实现多种放电策略之下的电池 SOH 估计预测。

3 结 论

在本工作中,我们提出了一种基于 AED-CEEMD-Transformer 网络模型的锂离子电池 SOH 预测方法。该方法由三部分组成,其中 AED 用于从电池平台中寻找与目标电池最为相似的参考电池,该步骤可以减少训练集来加快预测效率;CEEMD 用于将电池的容量曲线分解成容量再生曲线以及退化趋势部分,增加预测精度;相较于常见的 RNN、LSTM 等神经网络模型,Transformer

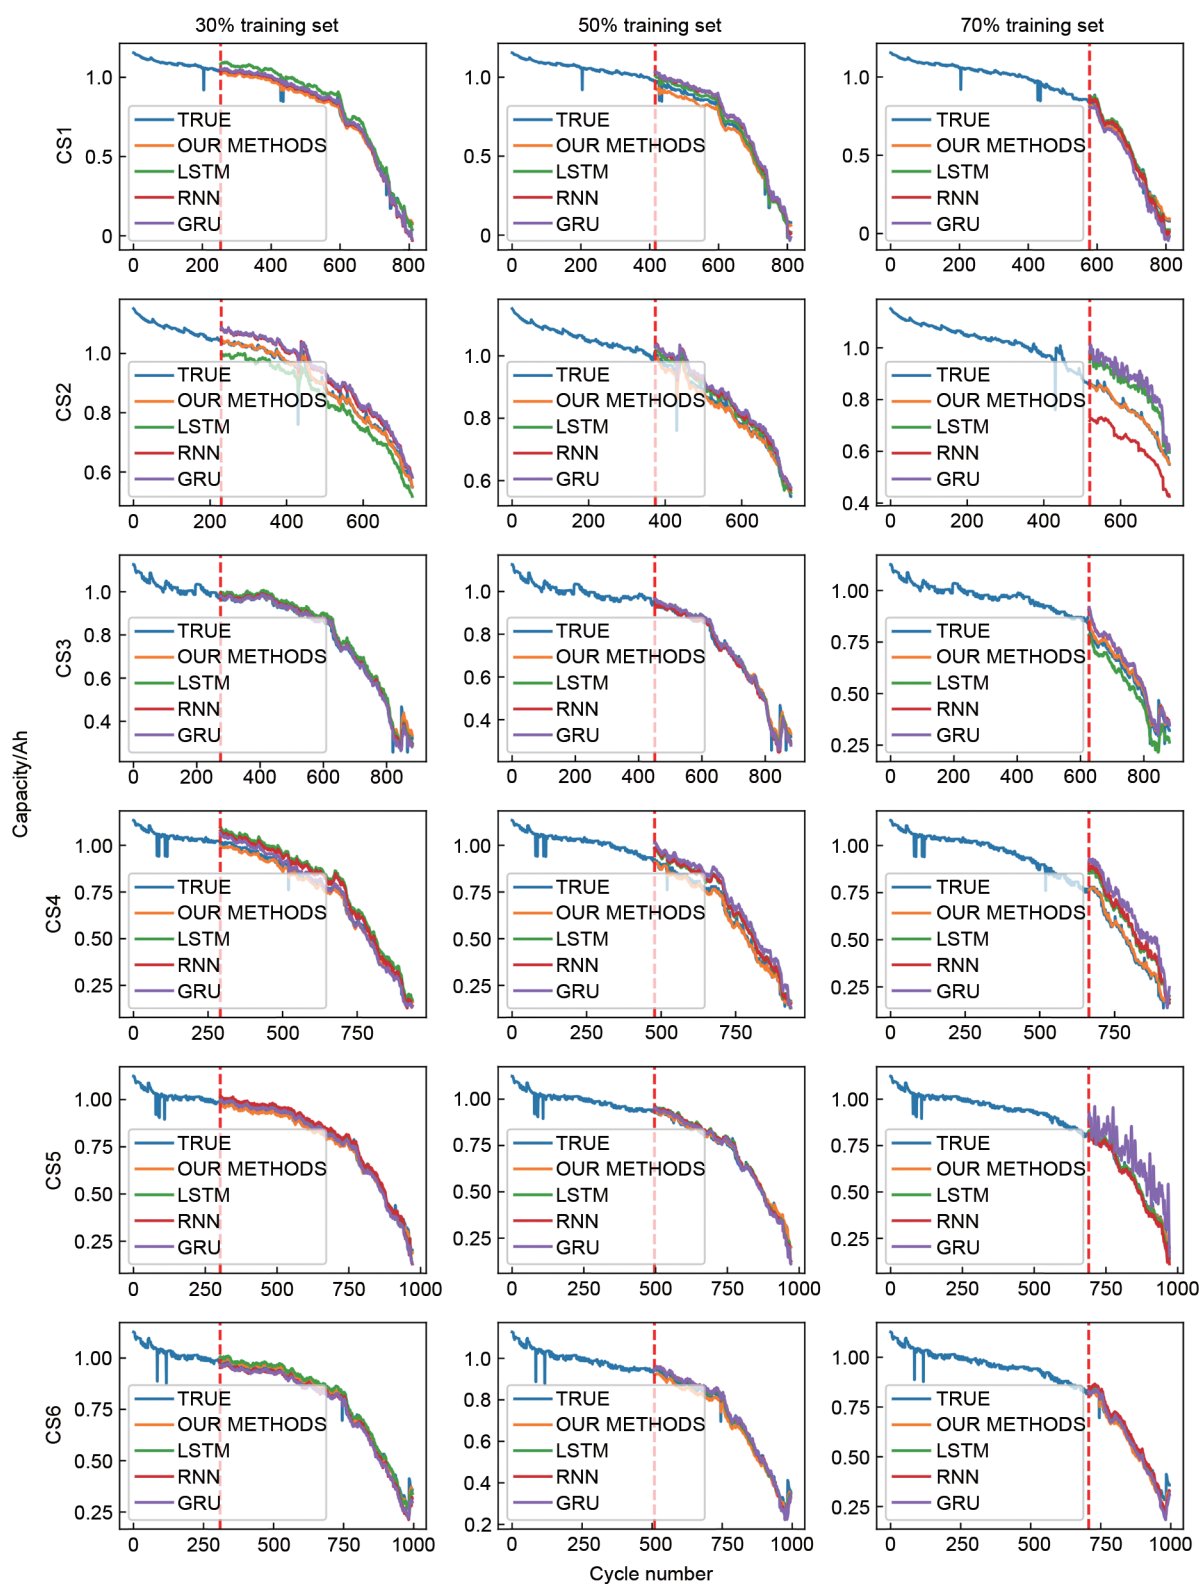


图6 CALCE 电池估计结果

Fig. 6 Estimated results for CALCE cells

网络模型摆脱了链式结构，避免了长期依赖性等弊端，并且可以进行并行计算加快模型训练进度。为

了验证所提出方法的有效性，我们使用了来自斯坦福大学的大型锂离子电池数据集，其电池以不同的

表2 CALCE电池估计误差
Table 2 CALCE cell estimation error

电池	误差	前 30% 训练集				前 50% 训练集				前 70% 训练集			
		OURS	LSTM	RNN	GRU	OURS	LSTM	RNN	GRU	OURS	LSTM	RNN	GRU
CS1	RMSE	0.03637	0.03937	0.03988	0.03986	0.03687	0.03802	0.03882	0.03882	0.03280	0.03324	0.03313	0.03335
	MAPE	0.08005	0.08188	0.08320	0.08314	0.08857	0.09069	0.09296	0.09296	0.09761	0.09977	0.09950	0.10023
CS2	RMSE	0.01584	0.01811	0.01829	0.01863	0.01451	0.01635	0.01653	0.01657	0.01060	0.01127	0.01154	0.01175
	MAPE	0.01573	0.01740	0.01763	0.01789	0.01495	0.01672	0.01691	0.01695	0.01184	0.01260	0.01288	0.01307
CS3	RMSE	0.02656	0.02884	0.02905	0.02925	0.02614	0.02770	0.02819	0.02824	0.02146	0.02175	0.02189	0.02190
	MAPE	0.03453	0.03639	0.03655	0.03673	0.03829	0.03861	0.03915	0.03923	0.03468	0.03540	0.03558	0.03562
CS4	RMSE	0.03259	0.03470	0.03536	0.03528	0.03030	0.03184	0.03234	0.03231	0.02546	0.02592	0.02613	0.02598
	MAPE	0.05495	0.05670	0.05776	0.05766	0.05607	0.05884	0.05978	0.05966	0.05538	0.05671	0.05760	0.05709
CS5	RMSE	0.02647	0.02843	0.02885	0.02835	0.02637	0.02775	0.02794	0.02787	0.02377	0.02405	0.02422	0.02423
	MAPE	0.03604	0.03743	0.03779	0.03736	0.04016	0.04059	0.04079	0.04066	0.04107	0.04120	0.04143	0.04144
CS 6	RMSE	0.02543	0.02787	0.02837	0.02833	0.02609	0.02752	0.02768	0.02772	0.02339	0.02353	0.02369	0.02366
	MAPE	0.03324	0.03491	0.03530	0.03525	0.03779	0.03802	0.03815	0.03819	0.03744	0.03762	0.03784	0.03777

充电速率降解，以及斯里兰卡大学的数据集，其电池以不同的放电速率降解。结果表明，与其他机器学习方法相比，该方法显著提高了预测性能。

参 考 文 献

[1] LU J H, XIONG R, TIAN J P, et al. Battery degradation prediction against uncertain future conditions with recurrent neural network enabled deep learning[J]. *Energy Storage Materials*, 2022, 50: 139-151.

[2] 胡振恺, 雷博, 李勇琦, 等. 储能用锂离子电池安全性测试与评估方法比较[J]. *储能科学与技术*, 2022, 11(5): 1650-1656.

HU Z K, LEI B, LI Y Q, et al. Comparative study on safety test and evaluation methods of lithium-ion batteries for energy storage[J]. *Energy Storage Science and Technology*, 2022, 11(5): 1650-1656.

[3] 戴俊彦, 夏明超, 陈奇芳. 基于双重注意力机制的电池 SOH 估计和 RUL 预测编解码模型[J]. *电力系统自动化*, 2023, 47(6): 168-177.

DAI J Y, XIA M C, CHEN Q F. Encoding and decoding model of state of health estimation and remaining useful life prediction for batteries based on dual-stage attention mechanism[J]. *Automation of Electric Power Systems*, 2023, 47(6): 168-177.

[4] SHEN S Q, LIU B C, ZHANG K, et al. Toward fast and accurate SOH prediction for lithium-ion batteries[J]. *IEEE Transactions on Energy Conversion*, 2021, 36(3): 2036-2046.

[5] 徐乐, 邓忠伟, 谢翌, 等. 锂离子电池高精度机理建模、参数辨识与寿命预测研究进展[J]. *机械工程学报*, 2022, 58(22): 19-36.

XU L, DENG Z W, XIE Y, et al. Review on research progress in high-fidelity modeling, parameter identification and lifetime prognostics of lithium-ion battery[J]. *Journal of Mechanical Engineering*, 2022, 58(22): 19-36.

[6] 王瑞洁, 惠周利, 杨明. 基于间接健康指标的高斯过程回归对锂电池 SOH 预测[J]. *储能科学与技术*, 2023, 12(2): 560-569.

WANG R J, HUI Z L, YANG M. Gaussian process regression based on indirect health indicators for SOH estimation of lithium

battery[J]. *Energy Storage Science and Technology*, 2023, 12(2): 560-569.

[7] MA G J, XU S P, YANG T, et al. A transfer learning-based method for personalized state of health estimation of lithium-ion batteries[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, PP(99): 1-11.

[8] 舒星, 刘永刚, 申江卫, 等. 基于改进最小二乘支持向量机与 Box-Cox 变换的锂离子电池容量预测[J]. *机械工程学报*, 2021, 57(14): 118-128.

SHU X, LIU Y G, SHEN J W, et al. Capacity prediction for lithium-ion batteries based on improved least squares support vector machine and box-cox transformation[J]. *Journal of Mechanical Engineering*, 2021, 57(14): 118-128.

[9] 何冰琛, 杨薛明, 王劲松, 等. 基于 PCA-GPR 的锂离子电池剩余使用寿命预测[J]. *太阳能学报*, 2022, 43(5): 484-491.

HE B C, YANG X M, WANG J S, et al. Prediction of remaining useful life of lithium-ion batteries based on pca-gpr[J]. *Acta Energiae Solaris Sinica*, 2022, 43(5): 484-491.

[10] 郑伟彦, 吴靖, 许杰, 等. 基于 RVM-PF 融合算法的锂离子电池剩余使用寿命预测[J]. *浙江电力*, 2021, 40(4): 54-64.

ZHENG W Y, WU J, XU J, et al. Prediction of remaining useful life of lithium-ion battery based on RVM-PF algorithm[J]. *Zhejiang Electric Power*, 2021, 40(4): 54-64.

[11] TIAN J P, XIONG R, SHEN W X, et al. Deep neural network battery charging curve prediction using 30 points collected in 10 Min[J]. *Joule*, 2021, 5(6): 1521-1534.

[12] 梁海峰, 袁芃, 高亚静. 基于 CNN-Bi-LSTM 网络的锂离子电池剩余使用寿命预测[J]. *电力自动化设备*, 2021, 41(10): 213-219.

LIANG H F, YUAN P, GAO Y J. Remaining useful life prediction of lithium-ion battery based on CNN-Bi-LSTM network[J]. *Electric Power Automation Equipment*, 2021, 41(10): 213-219.

[13] PHAM T, LE T, DANG D, et al. ARNS: A data-driven approach for SoH estimation of lithium-ion battery using nested sequence models with considering relaxation effect[J]. *IEEE Access*, 2022,

- 10: 117067-117083.
- [14] 王朋凯, 张新燕, 张光昊. 基于 ResNet-Bi-LSTM-Attention 的锂离子电池剩余使用寿命预测[J]. 储能科学与技术, 2023, 12(4): 1215-1222.
- WANG P K, ZHANG X Y, ZHANG G H. Remaining useful life prediction of lithium-ion batteries based on ResNet-Bi-LSTM-Attention model[J]. Energy Storage Science and Technology, 2023, 12(4): 1215-1222.
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention Is All You Need[M]. arXiv, 2017.
- [16] 刘芊彤, 邢远秀. 基于 VMD-PSO-GRU 模型的锂离子电池剩余寿命预测[J]. 储能科学与技术, 2023, 12(1): 236-246.
- LIU Q T, XING Y X. Remaining life prediction of lithium-ion battery based on VMD-PSO-GRU model[J]. Energy Storage Science and Technology, 2023, 12(1): 236-246.
- [17] 肖浩逸, 何晓霞, 梁佳佳, 等. 一种基于模态分解和机器学习的锂电池寿命预测方法[J]. 储能科学与技术, 2022, 11(12): 3999-4009.
- XIAO H Y, HE X X, LIANG J J, et al. A lithium battery life-prediction method based on mode decomposition and machine learning[J]. Energy Storage Science and Technology, 2022, 11(12): 3999-4009.
- [18] 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.
- ZHENG X Y, DENG X G, CAO Y P. State of health prediction of lithium-ion batteries based on energy-weighted Gaussian process regression[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(6): 63-69.
- [19] 陈彦余, 夏向阳, 周文钊, 等. 基于 EMD-ARMA 的锂离子电池剩余寿命预测[J]. 电力学报, 2021, 36(1): 43-50, 59.
- CHEN Y Y, XIA X Y, ZHOU W Z, et al. Prediction of the lithium-ion battery remaining useful life based on EMD-ARMA[J]. Journal of Electric Power, 2021, 36(1): 43-50, 59.
- [20] 欧阳名三, 屈琪. 基于 SAE-EEMD-GRU 的锂离子电池剩余使用寿命预测[J]. 佳木斯大学学报(自然科学版), 2022, 40(2): 43-49.
- MINGSAN O Y, QI Q. Remaining useful life prediction of lithium-ion batteries based on SAE-EEMD-GRU[J]. Journal of Jiamusi University (Natural Science Edition), 2022, 40(2): 43-49.
- [21] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [22] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]//2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). May 22-27, 2011, Prague, Czech Republic. IEEE, 2011: 4144-4147.
- [23] CONG X W, ZHANG C P, JIANG J C, et al. A hybrid method for the prediction of the remaining useful life of lithium-ion batteries with accelerated capacity degradation[J]. IEEE Transactions on Vehicular Technology, 2020, 69(11): 12775-12785.
- [24] SEVERSON K A, ATTIA P M, JIN N, et al. Data-driven prediction of battery cycle life before capacity degradation[J]. Nature Energy, 2019, 4(5): 383-391.
- [25] 黄凯, 丁恒, 郭永芳, 等. 基于数据预处理和长短期记忆神经网络的锂离子电池寿命预测[J]. 电工技术学报, 2022, 37(15): 3753-3766.
- HUANG K, DING H, GUO Y F, et al. Prediction of remaining useful life of lithium-ion battery based on adaptive data preprocessing and long short-term memory network[J]. Transactions of China Electrotechnical Society, 2022, 37(15): 3753-3766.