

DOI: 10.19783/j.cnki.pspc.231507

基于自适应噪声完全集合经验模态分解与 BiLSTM-Transformer 的锂离子电池剩余使用寿命预测

刘斌¹, 吉春霖², 曹丽君¹, 武欣雅¹, 段云凤³

(1. 太原科技大学应用科学学院, 山西 太原 030024; 2. 太原科技大学计算机科学与技术学院, 山西 太原 030024; 3. 太原科技大学经济与管理学院, 山西 太原 030024)

摘要: 锂离子电池剩余使用寿命(remaining useful life, RUL)是使用者十分关心的问题, 其涉及电池的更换时间和安全。针对锂离子电池的电容量非线性变化趋势, 提出了一种基于自适应噪声完全集合经验模态分解与双向长短期记忆网络-Transformer 的锂离子电池剩余使用寿命预测方法。首先, 利用自适应噪声完全集合经验模态分解方法对锂离子电池电容量数据进行分解。其次, 使用串联的双向长短期记忆神经网络和 Transformer 网络对分解后得到的残差序列和本征模态分量序列进行建模预测。最后, 将预测的若干本征模态分量序列和残差序列进行求和, 并对求和之后的最终预测数据与原始数据进行 RUL 预测。采用 NASA 公开的电池数据集对所提方法进行验证, 结果表明, 所提方法的平均绝对误差、均方根误差、平均绝对百分比误差和绝对误差控制分别控制在 0.0173、0.0231、1.2084%和 3 个循环周期以内, 能够有效地提高锂离子电池 RUL 的预测精度。

关键词: 锂离子电池; 剩余使用寿命预测; Transformer 网络; 双向长短期记忆网络; 完全集合经验模态分解

Prediction of remaining service life of lithium-ion batteries based on complete ensemble empirical mode decomposition with adaptive noise and BiLSTM-Transformer

LIU Bin¹, JI Chunlin², CAO Lijun¹, WU Xinya¹, DUAN Yunfeng³

(1. School of Applied Science, Taiyuan University of Science and Technology, Taiyuan 030024, China; 2. School of Computer Science and Technology, Taiyuan University of Science and Technology, Taiyuan 030024, China; 3. School of Economics and Management, Taiyuan University of Science and Technology, Taiyuan 030024, China)

Abstract: The remaining useful life (RUL) of lithium-ion batteries is a concern for users, as it relates to the timing of battery replacement and safety. Addressing the non-linear variation trend in the capacity of lithium-ion batteries, a method for predicting the RUL is proposed based on complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) and a bidirectional long short-term memory (BiLSTM)-Transformer. First, the lithium-ion battery capacity data is decomposed using CEEMDAN method. Subsequently, a concatenated model consisting of BiLSTM neural networks and a Transformer network is employed to model and predict the residual sequences obtained from the decomposition and the intrinsic mode component sequences. Finally, the predicted intrinsic mode component sequences and residual sequences are summed, and the RUL is forecast by comparing the final data after summation with the original data. The proposed method is validated using NASA's publicly available battery dataset. Experimental results demonstrate that the mean absolute, root mean square, mean absolute percentage errors and absolute errors are controlled within 0.0173, 0.0231, 1.2084% and 3 cycles, respectively. The proposed approach effectively enhances the accuracy of RUL prediction for lithium-ion batteries.

This work is supported by the National Natural Science Foundation of China (No. 72071183).

Key words: lithium-ion battery; remaining useful life; Transformer network; bidirectional long short term memory network; complete ensemble empirical mode decomposition

基金项目: 国家自然科学基金项目资助(72071183); 山西省基础研究计划项目资助(202103021224274, 202303021221144); 山西省回国留学人员科研项目资助(2022-163)

0 引言

近年来,新能源汽车正逐渐替代传统燃油汽车,其能量主要来源于锂离子电池,然而随着锂离子电池持续的充放电循环使用,出现容量衰退和电极材料损耗等问题,带来一定安全隐患^[1]。因此,对锂离子电池剩余使用寿命(remaining useful life, RUL)精确预测显得尤为重要且有实际意义。

目前,国内外对锂离子 RUL 的研究主要有基于模型的预测方法和基于数据驱动的预测方法。基于模型的预测方法需要了解电池内部构造以及相关的物理化学理论,建立相应的物理失效模型或电化学反应模型,以模拟锂离子电池性能的退化过程。文献[2]提出了一种基于电化学机理的移动平均估计模型,该模型考虑了精度、计算强度、水平长度和容错性。文献[3]采用双向耦合方法建立了商用电池的电化学-热老化模型,研究了模型中输入参数的不确定性对输出参数电压、温度和老化的影响。文献[4]设计了锂电池实验,利用二阶 RC 等效电路模型,取得了相对较好的锂离子电池 RUL 预测结果。文献[5]结合了耦合电化学模型、等效电路模型、传热模型和流体动力学模型,对电池和电池组的容量和可靠性进行了评估和预测。

电池在实际使用过程中变化复杂。基于模型的预测方法难以根据实时情况对模型进行调整。而基于数据驱动的预测方法通过分析训练数据的退化模式,实时更新网络参数,从而建立训练数据与测试数据之间的退化映射关系,更加灵活方便。常见的基于数据驱动的预测方法包括自回归集成移动平均^[6]、支持向量机^[7]、神经网络^[8]、卷积神经网络^[9]以及双向长短期记忆网络和注意力机制^[10]。文献[11]将状态检测和循环神经网络(recurrent neural network, RNN)引入电池容量预测,将状态检测提供的容量数据用于 RNN 模型的训练。虽然 RNN 可以根据历史信息预测未来趋势,但存在长期依赖问题。为了缓解这一问题,文献[12]采用了双向门控循环单元神经网络模型。双向门控循环单元神经网络预测精度高且训练参数较少,但在处理复杂序列时仍表现不佳,因此文献[13]引入长短期记忆(long short-term memory, LSTM)网络。LSTM 网络可以更好地利用之前的历史数据,解决了循环神经网络和双向门控循环单元神经网络的长期依赖问题,并结合混沌映射、反向学习策略和柯西变化干扰策略的麻雀优化算法,在给定范围内快速搜寻到最好的 LSTM 网络参数,取得了较好的预测结果。

原始数据中存在噪声,如果不对数据进行去噪处

理,会影响预测的精度。文献[14]利用深度残差网络提取原始数据的隐含特征信息,再使用双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络进行预测,并结合注意力机制对预测结果进行权重分配,提高了 RUL 预测精度。文献[15]利用自编码器对数据进行去噪,并提出基于神经网络和先前估计值的预测方法,将模型分为增量模型和多步模型,从而提高了数据驱动方法的预测效果。文献[16]提出一种基于 Transformer 的锂离子 RUL 预测方法,加入去噪自编码器对原始数据进行去噪,降低了噪声对预测结果的影响,并设计了时间编码层进一步提高了预测精度。

尽管上述方法在一定程度上具有去噪作用,但仍难以完全捕捉电池容量的再生现象,降低了 RUL 预测的准确性^[17]。模态分解方法可以解决难以捕捉的电容再生现象。文献[18]采用经验模态分解(ensemble empirical mode, EMD)方法对电池容量数据进行分解,选取可以体现锂电池退化的模态分量,基于模态分量构建高斯过程回归模型。对锂离子电池 RUL 进行点预测和区间预测。虽然 EMD 可以分离出数据中存在的噪声成分,但存在模态混叠问题。集合经验模态分解(ensemble empirical mode decomposition, EEMD)是一种时频域信号处理方法。在数据中加入白噪声进行多次经验模态分解,将每次分解得到的本征模函数(intrinsic mode function, IMF)进行平均,并对白噪声进行补偿,得到最终 IMF。文献[19]引入 EEMD,并结合集成机器学习和 LSTM 进行预测,提高了预测精度。虽然 EEMD 方法缓解了经验模态分解的模态混叠问题^[20-21],但加入的随机噪声和多次分解会引入一些重构误差,影响分解的精度。文献[22]引入互补集合经验模态分解方法对数据进行分解,借助排列熵算法把各个 IMF 分量重构为低频分量和高频分量,低频分量用作电池预测。文献[23]利用互补集合经验模态分解方法将电池容量曲线分解为再生部分和退化趋势部分,结合深度学习得到了锂离子电池的健康状态预测结果。尽管互补集合经验模态分解可以自适应地确定噪声水平,解决了噪声选取随机性的问题,但计算复杂度高。文献[24]提出了自适应噪声完全集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)方法,有效地降低了互补集合经验模态分解方法的计算复杂度。文献[25]使用 CEEMDAN 方法分解数据,结合随机森林算法对每个 IMF 分量分配权重。通过加权重构不同 IMF 分量的预测结果,实现了对锂离子电池 RUL 的预测。该方法采用的随机森林算法需要训练多个

决策树模型, 导致内存需求大, 增大了运算成本, 并且在处理少量数据时效果不佳。

针对上述方法存在的问题, 本文提出了一种 CEEMDAN-BiLSTM-Transformer 的锂离子电池 RUL 预测方法。将锂离子电池容量作为预测 RUL 的唯一特征。鉴于原始数据中存在噪声, 因此, 本文采用 CEEMDAN 方法对数据进行分解, 将容量数据拆分为多个 IMF 分量和一个残差序列, 以此达到去噪的目的。分解后的数据利用 BiLSTM 网络对长序列的处理优势, 以及对过去和未来信息同时保留的能力进行初步特征提取。在此基础上, 为了更有效地捕获序列的全局特征, 采用了具有多头注意力机制的 Transformer 模型。该模型可以在不同位置上有效提取整体特征, 并且具备并行计算多个子空间注意力的能力, 从而捕捉序列的不同特征。最后, 将各个 IMF 分量和一个残差序列的预测结果进行累加, 完成锂离子电池 RUL 预测。

1 非线性数据分解与深度学习模型

1.1 自适应噪声完全集合经验模态分解方法

EMD 方法是一种用于信号处理和数据分析的技术, 适用于分析非线性和非平稳信号。通过逐步分解非线性数据, 生成一系列不同特征尺度的数据序列, 每个数据序列被称为 IMF。如果要成为一个 IMF, 必须同时满足以下两个条件:

- 1) 在整个分解过程中, 极值点的总个数与零点的总个数差值不超过 1;
- 2) 在任何时刻的某一区域, 由极大值点和极小值点分别构成上、下包络曲线, 均值等于 0。

利用 EMD 方法可以将电容量的再生现象从非线性数据中分离出来, 得到若干个 IMF 分量和一个残差序列。对于给定的一段原始非线性数据 $P(n)$, 有:

- (1) 获取这段非线性数据的所有极大值点和极小值点, 通过使用 3 次样条曲线将所有局部极大值点和局部极小值点分别连接, 构成上、下包络曲线。

- (2) 根据得到的上、下包络曲线求解均值包络函数曲线 $m_1(n)$ 。

$$m_1(n) = \frac{e_{\max}(n) + e_{\min}(n)}{2} \quad (1)$$

式中, $e_{\max}(n)$ 、 $e_{\min}(n)$ 分别表示上、下包络曲线值。

- (3) 用原始非线性数据减去得到的均值包络函数曲线, 得到一个中间信号 $IMF_1(n)$ 。

$$IMF_1(n) = P(n) - m_1(n) \quad (2)$$

判断中间信号 $IMF_1(n)$ 是否满足 IMF 的两个必要条件: 如满足, 则称 $IMF_1(n)$ 为一个 IMF 分量;

如不满足, 则以此 IMF 分量为基础, 重复步骤 (1)–(3)。

- (4) 用原始非线性数据减去第一个模态分量, 得到第一次分解的残差 $R_1(n)$ 。

$$R_1(n) = P(n) - IMF_1(n) \quad (3)$$

式中, IMF_1 表示第一个模态分量。

- (5) 对 $R_1(n)$ 重复步骤 (1)–(4), 得到 $IMF_2(n)$, 再用 $R_1(n)$ 减去 $IMF_2(n)$ 得到第二次分解的残差。依此类推, 当完成第 c 次分解, $R_c(n)$ 为单调函数时, 经验模态分解结束。

$$\begin{cases} R_2(n) = R_1(n) - IMF_2(n) \\ \vdots \\ R_c(n) = R_{c-1}(n) - IMF_c(n) \end{cases} \quad (4)$$

式中: $R_c(n)$ 表示第 c 个残差; $IMF_c(n)$ 表示第 c 个 IMF 分量。

$P(n)$ 可以由分解得到的所有 IMF 分量和最后的残差求和表示。

虽然 EMD 方法可以将非线性数据分解为若干个 IMF 分量和一个残差, 但不同频率成分的信号可能会混合在一起, 导致分解得到的 IMF 分量包含混杂的频率成分。因此, EEMD 加入白噪声缓解了模态混叠现象, 但 EEMD 依赖于添加的白噪声, 导致添加不同的噪声会产生不同的分解结果, 所以结果的稳定性和一致性会受到影响。为了充分捕捉电容量再生现象, 更好地预测电池的 RUL, 本文引入 CEEMDAN 方法。将锂离子电池的容量数据进行分解, 分解得到的若干 IMF 和最后的残差作为输入序列。通过以下步骤, 即可获得 IMF 和残差。

- 1) 在原始非线性数据 $P(n)$ 中添加可自适应分解的高斯白噪声 $\varepsilon_0 w^t(n)$, 得到新的信号 $P^t(n)$ 。

$$P^t(n) = P(n) + \varepsilon_0 w^t(n) \quad (5)$$

式中: ε_0 为白噪声幅度; $w^t(n)$ 为第 t 次添加的白噪声序列。

- 2) 对 $P^t(n)$ 进行经验模态分解获得第一模态, 再对第一模态求平均得到 CEEMDAN 方法的一个模态分量 $IMF_1(n)$ 。

$$IMF_1(n) = \frac{1}{N} \sum_{t=1}^N E_1 p^t(n) \quad (6)$$

式中, E_1 表示为 EMD 分解数据信号时产生的第一阶模态的算子。

用原始非线性数据 $P(n)$ 减去第一个模态分量 $IMF_1(n)$, 得到第一残差 $R_1(n)$ 。

$$R_1(n) = P(n) - IMF_1(n) \quad (7)$$

3) 在 $R_1(n)$ 中加入新的高斯白噪声 $\varepsilon_1 E_1 w^l(n)$ ，并进行 EMD，得到第二个模态分量 $IMF_2(n)$ 。

$$IMF_2(n) = \frac{1}{N} \sum_{i=1}^N E_1(R_1(n) + \varepsilon_1 E_1 w^l(n)) \quad (8)$$

4) 用第二个模态分量和第一残差计算第二残差 $R_2(n)$ 。

$$R_2(n) = R_1(n) - IMF_2(n) \quad (9)$$

5) 重复步骤 3) 和步骤 4)，直到第 i 残差 $R_i(n)$ 为单调函数时，分解结束。

$$IMF_i(n) = \frac{1}{N} \sum_{i=1}^N E_i(R_{i-1}(n) + \varepsilon_{i-1} E_{i-1} w^l(n)) \quad (10)$$

$$R_i(n) = R_{i-1}(n) - IMF_i(n) \quad (11)$$

式中： E_{i-1} 为分解信号时产生的第 $i-1$ 阶模态的算子； ε_{i-1} 为第 i 次分解前添加的白噪声幅度。

原始信号可表示如式(12)所示。

$$P(n) = \sum_{i=1}^l IMF_i + R_l(n) \quad (12)$$

1.2 BiLSTM 网络

在时序预测任务中，输入序列过长所包含的信息较多，RNN 不能很好地利用数据的特征，这对最终的预测结果会产生较大影响。LSTM 网络作为循环神经网络模型的一种变体，可以更好地处理长时间序列。LSTM 由遗忘门、输入门和输出门组成，如图 1 所示。

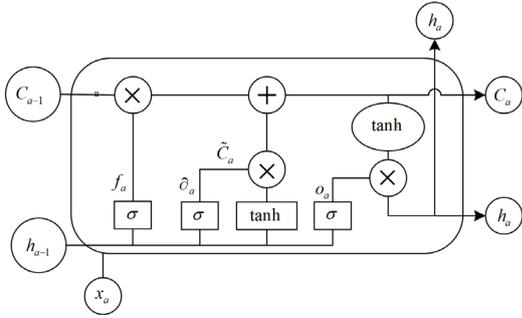


图 1 LSTM 结构图

Fig. 1 LSTM structure diagram

遗忘门将上一单元的输出序列和当前单元的输入序列作为输入，通过 sigmoid 激活函数得到 0-1 数值，该数值表示上一层单元输出被遗忘的概率，其中，0 意味着所有的信息都被遗忘，而 1 意味着所有的信息都被保存。相关计算如式(13)所示。

$$f_a = \sigma(W_f \cdot [h_{a-1}, x_a] + b_f) \quad (13)$$

式中： f_a 表示遗忘门； σ 表示 sigmoid 激活函数； W_f 表示遗忘门的权重矩阵； h_{a-1} 表示前一时间步的隐状态； x_a 表示当前输入； $[\cdot, \cdot]$ 为拼接操作； b_f 表

示遗忘门的偏置项。

输入门选择性地新信息存放到细胞状态中，相关计算为

$$\partial_a = \sigma(W_\partial \cdot [h_{a-1}, x_a] + b_\partial) \quad (14)$$

$$\tilde{C}_a = \tanh(W_c \cdot [h_{a-1}, x_a] + b_c) \quad (15)$$

式中： ∂_a 表示输入门的输出； \tilde{C}_a 表示候选记忆单元； W_∂ 和 W_c 分别为输入门和候选记忆单元的权重矩阵； b_∂ 和 b_c 分别为输入门和候选记忆单元的偏置项。

输出门决定了哪些信息需要输出到下一个时间步，相关计算为

$$o_a = \sigma(W_o \cdot [h_{a-1}, x_a] + b_o) \quad (16)$$

式中： o_a 表示输出门的输出； W_o 为输出门的权重矩阵； b_o 为输出门的偏置项。

最后，通过结合遗忘门、输入门和输出门的结果来更新记忆单元状态和隐状态。

$$C_a = f_a \times C_{a-1} + \partial_a \times \tilde{C}_a \quad (17)$$

$$h_a = o_a \times \tanh(C_a) \quad (18)$$

式中： C_a 表示当前记忆单元； h_a 表示当前时间步的隐状态。

在非线性数据中，数据的变化趋势并不稳定。简单的 LSTM 网络不能充分提取数据特征。而 BiLSTM 网络可以同时从正向和反向两个方向提取数据特征，并将当前位置的输入与过去的信息和未来的信息相连，从而更好地提取数据的特征关系，如图 2 所示。因此，本文采用 BiLSTM 网络模型，对经过 CEEMDAN 后得到的多个 IMF 分量和一个残差序列进行特征提取，建立了数据之间的时间关系。

BiLSTM 网络在每个时间步长内计算前向 LSTM 隐状态 \vec{h}_a 和后向 LSTM 隐状态 \overleftarrow{h}_a ，最后将两个隐状态拼接得到最终输出 H_a 。

$$\vec{h}_a = \vec{o}_a \times \tanh(\vec{C}_a) \quad (19)$$

$$\overleftarrow{h}_a = \overleftarrow{o}_a \times \tanh(\overleftarrow{C}_a) \quad (20)$$

$$H_a = \begin{bmatrix} \vec{h}_a \\ \overleftarrow{h}_a \end{bmatrix} \quad (21)$$

式中： \vec{C}_a 和 \overleftarrow{C}_a 分别表示前向和后向当前记忆单元； \vec{o}_a 和 \overleftarrow{o}_a 分别表示前向和后向输出门的输出。

1.3 Transformer

标准 Transformer 是一个序列到序列的体系结构，该结构包括一个编码器和一个解码器。编码器负责将输入序列映射成更高维度的向量，再把该向量输入到解码器中，生成一系列输出。本文方法使用编码器把输入序列映射到高维表示，用全连接层

代替解码器。Transformer 编码器如图 3 所示。在完整的子层——多头自注意力层和前馈网络层。Transformer 的编码器堆栈中, 每个编码器分为两个

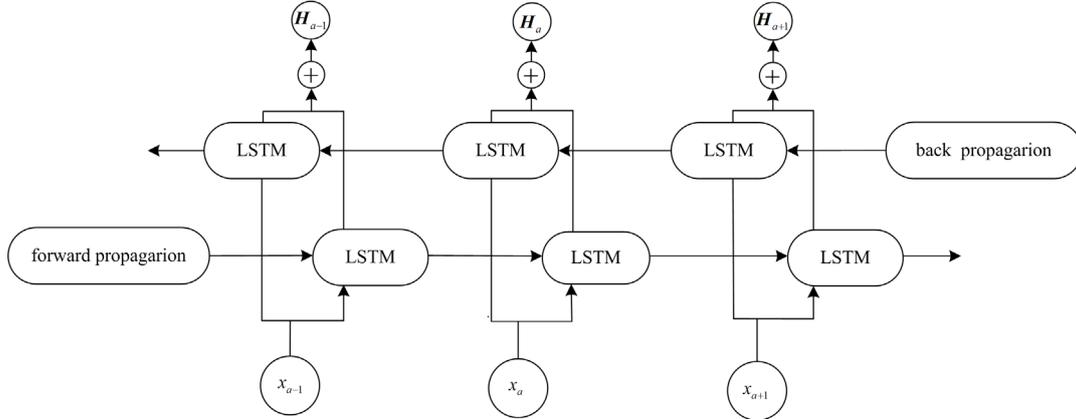


图 2 双向长短期记忆网络结构示意图

Fig. 2 Schematic diagram of bidirectional long short-term memory network structure

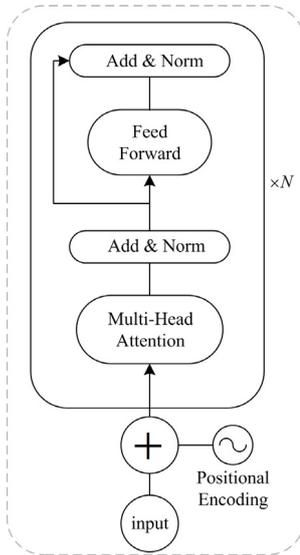


图 3 Transformer 编码器结构图

Fig. 3 Transformer encoder structure diagram

在序列输入到多头自注意力层之前, 需要加入位置编码(positional encoding, PE)表示序列中数据之间的位置关系。本文使用不同频率下的正弦函数表示数据之间的相对位置。

$$PE(k, 2u) = \sin(k / 10000^{2u/m}) \quad (22)$$

$$PE(k, 2u + 1) = \cos(k / 10000^{2u/m}) \quad (23)$$

式中: k 为时间步长; u 为特征的维数; m 为输入序列的长度。

多头自注意力层用作捕捉不同位置之间的依赖关系, 其运算为

$$\text{MultiHead}(Q, K, V) = \text{Concat}[head_1, head_2, \dots, head_p]W^G \quad (24)$$

$$head_p = \text{Attention}(Q_p, K_p, V_p) \quad (25)$$

$$\text{Attention}(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (26)$$

式中: MultiHead 表示多头自注意力机制; Q, K, V 分别代表查询、键和值矩阵; W^G 表示可训练的权重矩阵; p 表示头的个数; Attention 表示注意力机制; d_k 表示 K 矩阵的列数, 即向量的维度。

前馈网络(feed-forward network, FFN)的作用是在注意力机制的基础上进一步提取特征, 从而增强模型的表达能力。FFN 表示为

$$\text{FFN}(\delta) = \text{ReLU}(\delta W_1 + b_1)W_2 + b_2 \quad (27)$$

式中: FFN 表示前馈网络; δ 表示输入数据; W_1, W_2 表示权重矩阵; b_1, b_2 表示偏置项。

Transformer 使用多头自注意力机制对 BiLSTM 网络提取到的特征进行进全局建模, 再经过 FFN 完成特征提取。

1.4 CEEMDAN-BiLSTM-Transformer 网络架构

在时序预测任务中, 原始数据是不单调和不平稳的。这些非线性数据经过 CEEMDAN, 得到的 IMF 可以充分提取退化过程中的电池容量再生势。BiLSTM 网络可以利用其递归特性, 提取数据的时间特征。Transformer 网络通过多头自注意力机制和前馈网络换对数据进行建模, 充分挖掘数据的全局特征。因此, 本文提出一种结合 CEEMDAN、BiLSTM 和 Transformer 模型的 RUL 预测方法 (CEEMDAN-BiLSTM-Transformer)。该方法包括数据预处理模块、BiLSTM 模块、Transformer 模块和全连接(fully connected, FC)模块, 如图 4 所示。

1) 数据预处理模块使用 CEEMDAN 对容量退化过程进行分解, 得到若干个 IMF 分量和一个残差序列。

2) 将这些序列分别输入到 BiLSTM 模块。BiLSTM 模块由 3 个单层 BiLSTM 网络构成, 每个单层 BiLSTM 在经过激活函数处理后, 将其输出传递到下一层, 使得每层都可以学习到不同时间尺度上的信息。这种 3 层结构有助于更好地捕捉长序列中数据之

间的长期依赖关系, 从而提高模型的信息提取能力。

3) 将 BiLSTM 模块提取的特征输入到 Transformer 模块中, 利用多头注意力机制提取不同位置的数据特征并进行拼接, 再通过前馈网络进行非线性变换, 并在 Transformer 网络的多头自注意力层前后和前馈网络层前后加入残差连接以解决梯度消失的问题。

4) 将 Transformer 的输出输入到 FC 层, 进行 RUL 预测。

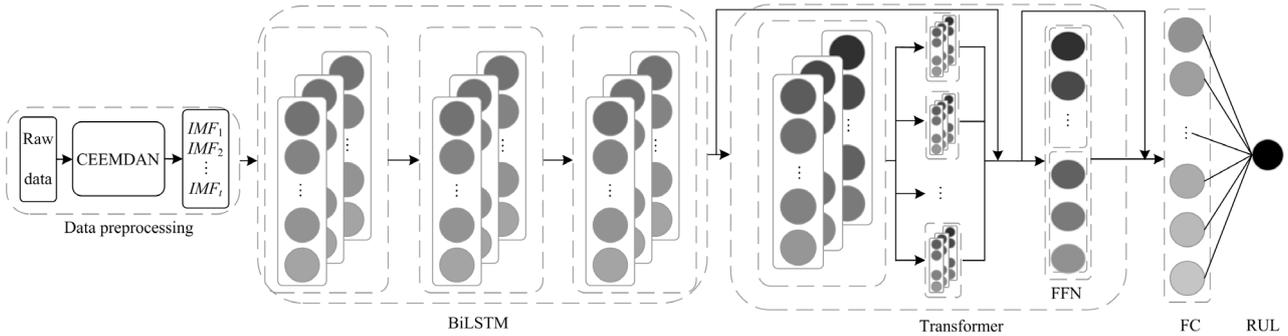


图 4 CEEMDAN-BiLSTM-Transformer 结构图

Fig. 4 CEEMDAN-BiLSTM-Transformer structure diagram

在更新深度学习网络模型的网络参数时, 需要借助损失函数来评估真实值与预测值之间的误差。本文研究的是时序预测任务, 目的是尽可能地减小真实值和预测值之间的误差。因此, 本文选用最小化损失函数、均方误差函数作为模型训练的损失函数, 其表达式为

$$M_{SE} = \frac{1}{r} \sum_{g=1}^r d_g^2 \quad (28)$$

式中: r 为训练样本的样本量; d_g 表示预测值和真实值之间的误差。

2 实验相关内容介绍

2.1 数据集

本文使用 NASA 艾姆斯研究中心公开的锂离子电池退化数据集^[26]进行验证。该数据集中的容量数据具有再生现象, 存在的噪声影响了预测精度, 因此适用于验证所提方法的有效性。

NASA 锂离子电池数据集包含 4 种不同的退化数据, 分别在充电、放电和阻抗测试 3 种不同的条件下进行收集。电池的充电和放电测试在恒温 24 °C 下进行。电池在持续充电状态时, 电池先在 1.5 A 的恒流状态下持续充电, 当电压达到 4.2 V 时, 切换到恒压模式。电池在持续放电状态时, 放电电流大小不变, 直到电压降到预设值。B0007 电池正常的工作范围为 2~1.5 Ah, 其他电池正常的工作范围为

2~1.4 Ah。尽管不同电池之间存在一些差异, 但均取额定容量为 2 Ah。当容量降到额定容量的 70% 时电池失效。B0005、B0006、B0007 子集的数据长度均是 168, B0018 子集的数据长度是 132。NASA 电池随循环次数增加的电池容量变化曲线如图 5 所示。

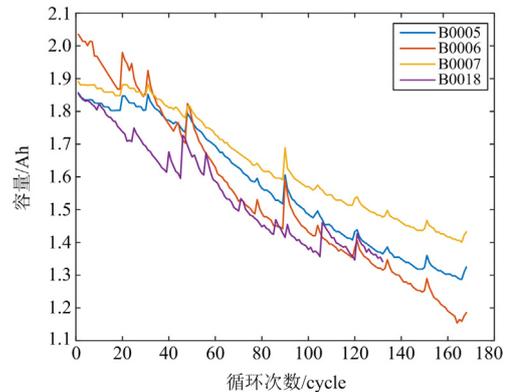


图 5 NASA 电池容量变化曲线

Fig. 5 NASA battery capacity change curve

2.2 基于 CEEMDAN-BiLSTM-Transformer 模型的电池 RUL 预测

由于设备、环境和使用状况等条件的影响, 导致锂离子电池容量出现再生现象。锂离子电池容量再生现象使得数据中存在一些离群点, 从而神经网络难以捕捉到容量再生现象, 导致直接使用原始数据进行 RUL 预测出现一定偏差。因此, 本文使用

CEEMDAN 方法对原始数据进行预处理。该方法在电池容量数据中加入自适应分解的白噪声, 并多次进行分解, 得到多个 IMF 分量和一个残差序列, 可以提取到容量数据中存在的再生现象。图 6 是 B0005 子集经过 CEEMDAN 方法分解后得到的 IMF 序列和残差序列, 图 7 是所提方法的实验流程图。

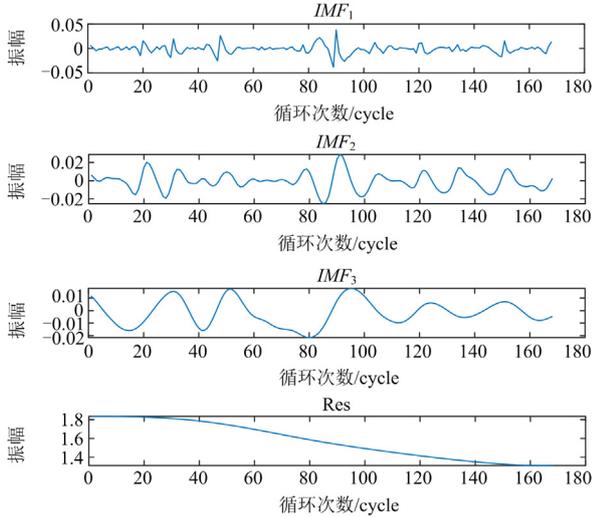


图 6 B0005 电池 CEEMDAN 图

Fig. 6 B0005 battery CEEMDAN diagram

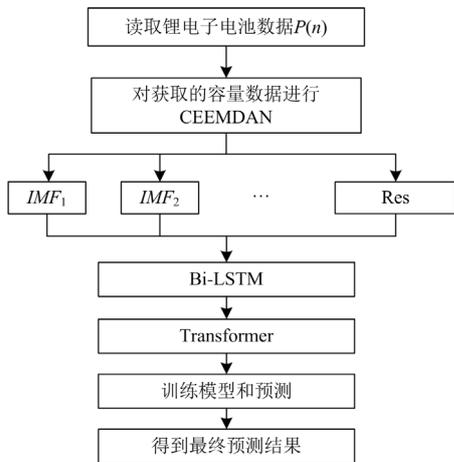


图 7 CEEMDAN-BiLSTM-Transformer RUL 预测流程图

Fig. 7 CEEMDAN-BiLSTM-Transformer RUL prediction flowchart

具体的 RUL 预测流程如下所述。

- 1) 使用 CEEMDAN 方法分解电池容量数据, 得到多个 IMF 分量和一个残差序列。
- 2) 将每个 IMF 分量和一个残差序列的前 30% 数据作为训练集, 其余的数据作为测试集。
- 3) 基于划分好的 IMF 分量和残差, 以循环次数作为时间步长, 使用 BiLSTM-Transformer 网络模型

进行训练。

4) 根据训练好的网络模型, 把测试集中各 IMF 分量和一个残差序列分别输入到模型中进行预测。

5) 将预测得到的各 IMF 分量和一个残差序列进行求和, 并与原始数据进行各项指标的计算和 RUL 预测。

2.3 预测指标

为了更好地体现所提方法的有效性, 本文选取几个常用的评价指标, 包括平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和绝对误差(absolute error, AE)。

$$e_{MAE} = \frac{1}{j} \sum_{v=b}^{j+b-1} |y_{true}(v) - y_{pred}(v)| \quad (29)$$

$$e_{RMSE} = \sqrt{\frac{1}{j} \sum_{v=b}^{j+b-1} |y_{true}(v) - y_{pred}(v)|^2} \quad (30)$$

$$e_{MAPE} = \frac{1}{j} \sum_{v=b}^{j+b-1} \left| \frac{y_{true}(v) - y_{pred}(v)}{y_{true}(v)} \right| \times 100\% \quad (31)$$

$$e_{AE} = |R_{UL_{true}} - R_{UL_{pred}}| \quad (32)$$

式中: b 表示预测的起点; j 表示预测长度; y_{true} 和 y_{pred} 分别表示容量的真实数据和预测数据; $R_{UL_{true}}$ 和 $R_{UL_{pred}}$ 分别表示容量达到失效阈值时的真实循环次数与预测循环次数。

3 实验结果分析

为验证 CEEMDAN-BiLSTM-Transformer 方法的有效性, 本文将其与 CEEMDAN-BiLSTM、CEEMDAN-Transformer 以及 BiLSTM-Transformer 方法进行对比分析。分别将 B0005、B0006、B0007 和 B0018 电池数据子集中前 30% 的数据作为训练集, 除 B0018 电池数据集以外, 其余 3 个数据集预测起点为第 50 个循环周期, B0018 数据集的预测起点为第 40 个循环周期。实验预测结果如图 8 所示。同时, 以 B0007 号电池为例, 计算预测值和真实值之间的误差并进行绘制, B0007 号电池误差分布如图 9 所示。

通过图 8 可以看出: 使用 BiLSTM-Transformer 方法在 B0007 和 B0018 子集上整体预测效果不佳; 使用 CEEMDAN-BiLSTM 方法在 B0018 子集的中后期预测效果不佳; 使用 CEEMDAN-Transformer 方法在 B0006 和 B0018 两个子集后期的预测效果不佳; 本文提出的方法在 4 个电池子集上具有较好的拟合效果, 没有出现明显的过拟合现象。

通过图 9(a)可得, 本文方法的预测值与真实值之间的最大误差为 0.02 Ah, 99.2%的容量误差都集中在 0.02 Ah 以内。通过图 9(b)可得, CEEMDAN-BiLSTM 模型的预测值与真实值之间的最大误差为 0.03 Ah, 89.0%的容量误差都集中在 0.02 Ah 以内。由图 9(c)可得, CEEMDAN-Transformer 模型的预测值与真实值之间的最大误差为 0.04 Ah, 90.7%的容量误差都集中在 0.02 Ah 以内。由图 9(d)可得, BiLSTM-Transformer 模型的预测值与真实值之间的最大误差为 0.06 Ah, 70.3%的容量误差都集中在 0.02 Ah 以内。结合图 9 可得, 当容量误差接近 0 Ah 时, 本文方法核密度峰值达到 73.62 Ah^{-1} , 分别比 CEEMDAN-BiLSTM、CEEMDAN-Transformer 和 BiLSTM-Transformer 方法分别提高了 69.75%、116.98%和 270.14%。因此, CEEMDAN-BiLSTM-Transformer 方法可以较好地捕捉电池容量衰退信息, 具有更小的预测误差。

为更好地体现模型的性能, 本文对比不同方法下 RUL 预测结果, 如表 1 所示。CEEMDAN-

BiLSTM-Transformer 方法在 4 个电池子集上, MAE、RMSE 和 MAPE 的值均最小。在 B0007 子集上 AE 最小, 其他 3 个子集上 AE 仅与最好的方法相差一个循环周期。以 B0007 子集为例, 本文方法与 CEEMDAN-BiLSTM 方法相比, 其 MAE、RMSE 和 MAPE 分别降低了 46.5%、45.8%和 46.0%, 且 AE 减少了 3 个循环周期。与 CEEMDAN-Transformer 方法相比, 其 MAE、RMSE 和 MAPE 分别降低了 54.9%、48.8%和 55.2%, 且 AE 减少了 2 个循环周期。与 BiLSTM-Transformer 方法相比, 其 MAE、RMSE 和 MAPE 分别降低了 72.8%、70.5%和 72.8%, 且 AE 减少了 4 个循环周期。由此可得, 本文方法在各项指标上都表现良好。

在更少的训练数据的情况下, 本文方法可以更精确地预测电池 RUL。以 B0005 电池为例, 不同方法的电池寿命预测起点及绝对误差如表 2 所示, 可见本文方法具有更早的预测起点, 可供模型训练学习的特征更少, 并且当容量降到失效阈值时, AE 最小。

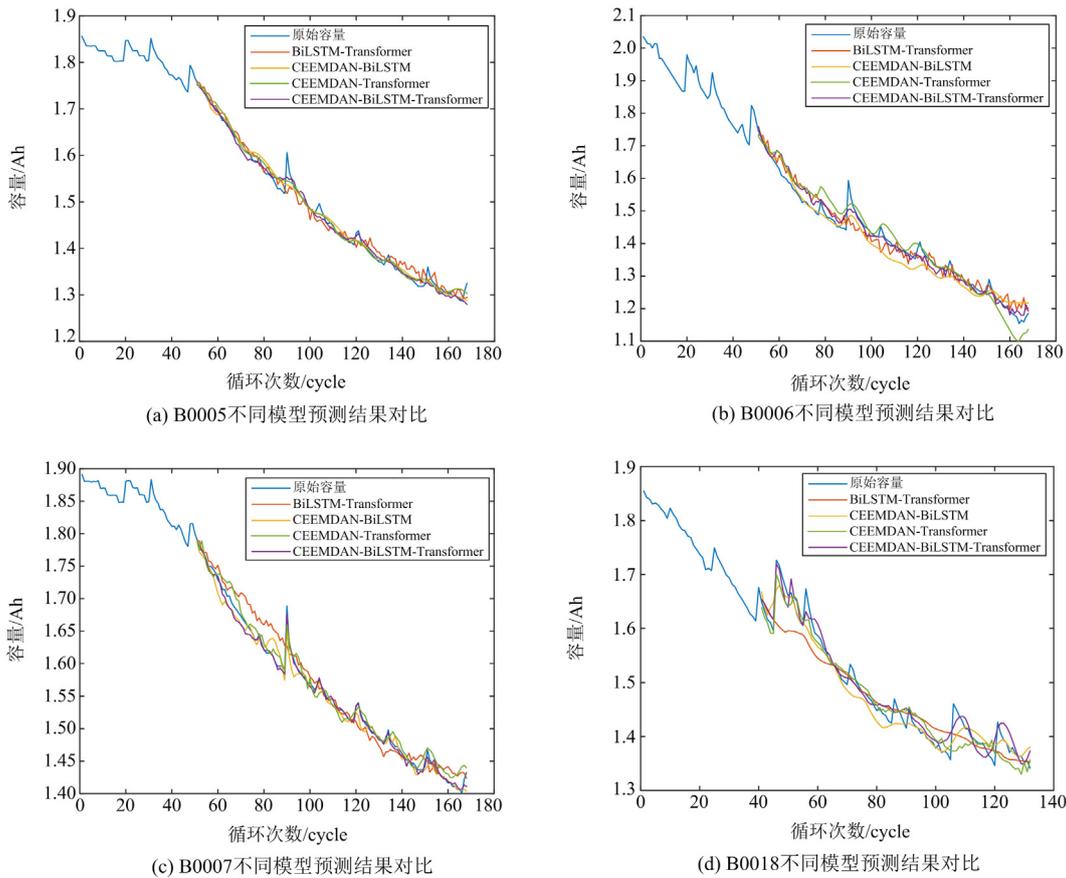


图 8 不同方法间实验结果对比

Fig. 8 Comparison of experimental results between different methods

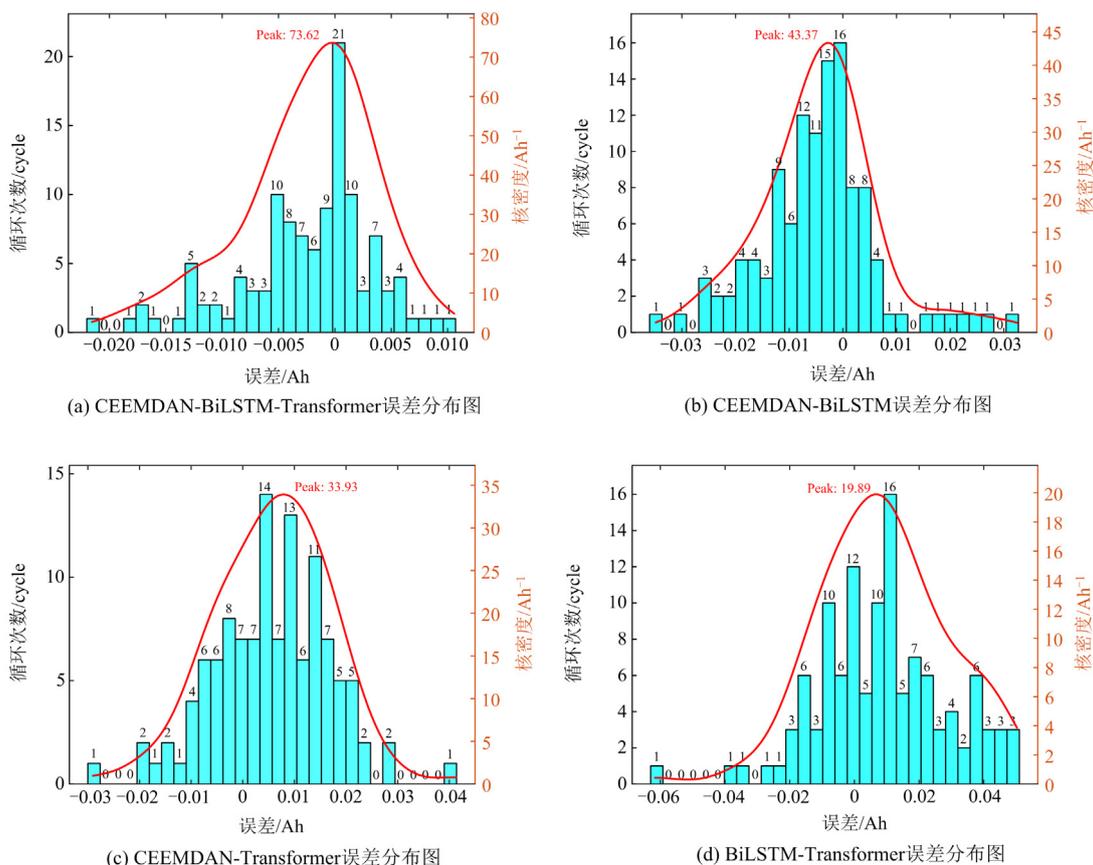


图 9 B0007 号电池不同方法的误差分布图

Fig. 9 Error distribution diagram of different methods for B0007 battery

表 1 不同方法下 RUL 预测结果

Table 1 RUL prediction results with different methods

电池型号	预测模型	MAE	RMSE	MAPE/%	AE/cycle
B0005	CEEMDAN-BiLSTM	0.0089	0.0129	0.6074	1
	CEEMDAN-Transformer	0.0086	0.0120	0.5840	0
	BiLSTM-Transformer	0.0135	0.0176	0.9327	4
	CEEMDAN-BiLSTM-Transformer	0.0081	0.0120	0.5583	1
B0006	CEEMDAN-BiLSTM	0.0272	0.0330	1.9763	10
	CEEMDAN-Transformer	0.0274	0.0342	1.9645	2
	BiLSTM-Transformer	0.0247	0.0314	1.7500	6
	CEEMDAN-BiLSTM-Transformer	0.0173	0.0231	1.2084	3
B0007	CEEMDAN-BiLSTM	0.0086	0.0118	0.5443	3
	CEEMDAN-Transformer	0.0102	0.0125	0.6569	2
	BiLSTM-Transformer	0.0169	0.0217	1.0796	4
	CEEMDAN-BiLSTM-Transformer	0.0046	0.0064	0.2940	0
B0018	CEEMDAN-BiLSTM	0.0172	0.0235	1.1522	0
	CEEMDAN-Transformer	0.0194	0.0250	1.3174	2
	BiLSTM-Transformer	0.0261	0.0357	1.7218	4
	CEEMDAN-BiLSTM-Transformer	0.0149	0.0185	1.0139	1

表 2 不同方法电池寿命预测的起点及绝对误差比较

Table 2 Comparison of starting point and absolute error of life prediction by different methods

模型	预测起点	AE/cycle
LSTM ^[27]	90	16
PA-LSTM ^[28]	90	3
CEEMDAN-CNN-LSTM ^[29]	80	1
CEEMDAN-Transformer-DNN ^[30]	90	1
ARIMA-LSTM ^[31]	76	7
CEEMDAN-BiLSTM-Transformer	50	1

综上所述,本文方法的预测结果可以很好地拟合原始容量退化数据,无明显的过拟合现象,且得到了较小的MAE、RMSE、MAPE和AE。因此,本文方法具有较高的预测精度。

4 结论

针对锂离子电池容量退化数据存在的容量再生现象和非线性性,本文提出了一种结合序列分解和深度学习模型的锂离子电池RUL预测方法。首先,使用CEEMDAN方法对原始数据进行分解,得到的若干IMF分量和一个残差。相比于原始数据,提取到的容量再生现象呈现了一定的周期性。其次,使用BiLSTM网络提取数据之间的时间关系特征。最后,使用Transformer提取不同位置的数据特征并进行拼接,接入全连接层完成RUL预测。实验结果显示MAE、RMSE、MAPE和AE最低可达到0.0046、0.0064、0.2940%和0个循环周期。同时,与其他方法相比,本文方法只需要使用前50个数据进行训练,当容量达到失效阈值时,其AE仅为1个循环周期,体现了本文方法的预测准确性。

本文方法仅针对锂离子电池的特性进行了RUL预测分析。在未来的工作中将使用磷酸铁锂电池、碱性电池以及其他类型的电池进行泛化性验证,并根据它们的特性对方法进行改进。此外,不仅限于使用单一容量特征进行预测,结合温度、电压和电流等其他间接相关特征,并通过分析不同指标特征间的相关关系,从而预测电池RUL和健康状态。

参考文献

- [1] 李正力, 李肖辉, 王京, 等. 锂离子电池储能电站热失控预警与防护研究进展[J]. 高压电器, 2024, 60(1): 87-99.
LI Zhengli, LI Xiaohui, WANG Jing, et al. Research progress on thermal runaway warning and protection of lithium-ion battery in energy storage power station[J]. High Voltage Apparatus, 2024, 60(1): 87-99.
- [2] HU Xiaosong, CAO Dongpu, EGARDT B. Condition monitoring in advanced battery management systems:

- moving horizon estimation using a reduced electrochemical model[J]. IEEE/ASME Transactions on Mechatronics, 2017, 23(1): 167-178.
- [3] ALIPOUR M, YIN Litao, TAVALLAEY S S, et al. A surrogate-assisted uncertainty quantification and sensitivity analysis on a coupled electrochemical-thermal battery aging model[J]. Journal of Power Sources, 2023, 579.
- [4] 宋胜, 李云伍, 赵颖, 等. 锂离子电池片段数据的荷电状态估计研究[J]. 电源技术, 2022, 46(7): 734-738.
SONG Sheng, LI Yunwu, ZHAO Ying, et al. Research on SOC estimation based on fragment data of lithium-ion battery[J]. Chinese Journal of Power Sources, 2022, 46(7): 734-738.
- [5] XIA Quan, YANG Dezhen, WANG Zili, et al. Multiphysical modeling for life analysis of lithium-ion battery pack in electric vehicles[J]. Renewable and Sustainable Energy Reviews, 2020, 131.
- [6] FENG Xuning, WENG Caihao, HE Xiangming, 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.
- [7] LI Sai, FANG Huajing, SHI Bing. Remaining useful life estimation of lithium-ion battery based on interacting multiple model particle filter and support vector regression[J]. Reliability Engineering & System Safety, 2021, 210.
- [8] HSU C, XIONG Rui, CHEN N, et al. Deep neural network battery life and voltage prediction by using data of one cycle only[J]. Applied Energy, 2022, 306.
- [9] SAXENA S, WARD L, KUBAL J, et al. A convolutional neural network model for battery capacity fade curve prediction using early life data[J]. Journal of Power Sources, 2022, 542.
- [10] WANG F, AMOGNE Z, CHOU J, et al. Online remaining useful life prediction of lithium-ion batteries using bidirectional long short-term memory with attention mechanism[J]. Energy, 2022, 254.
- [11] CATELANI M, CIANI L, FANTACCII R, et al. Remaining useful life estimation for prognostics of lithium-ion batteries based on recurrent neural network[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [12] 叶林峰, 石元博, 黄越洋. 基于BiGRU网络的锂电池寿命预测[J]. 电源技术, 2021, 45(5): 598-601.
YE Linfeng, SHI Yuanbo, HUANG Yueyang. Lithium battery life prediction based on BiGRU network[J]. Chinese Journal of Power Sources, 2021, 45(5): 598-601.
- [13] 邹红波, 柴延辉, 杨钦贺, 等. 基于混合ISSA-LSTM的锂离子电池剩余使用寿命预测[J]. 电力系统保护与控制, 2023, 51(19): 21-31.
ZOU Hongbo, CHAI Yanhui, YANG Qinhe, et al. Remaining useful life prediction of lithium-ion batteries

- based on hybrid ISSA-LSTM[J]. *Power System Protection and Control*, 2023, 51(19): 21-31.
- [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 Pengkai, ZHANG Xinyan, ZHANG Guanghao. 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] HONG S, KANG M, KIM J, et al. Sequential application of denoising autoencoder and long-short recurrent convolutional network for noise-robust remaining-useful-life prediction framework of lithium-ion batteries[J]. *Computers & Industrial Engineering*, 2023, 179: 109231.
- [16] SONG Wenbin, WU Di, SHEN Weiming, et al. A remaining useful life prediction method for lithium-ion battery based on temporal transformer network[J]. *Procedia Computer Science*, 2023, 217: 1830-1838.
- [17] ORCHARD M, TANG L, SAHA B, et al. Risk-sensitive particle-filtering-based prognosis framework for estimation of remaining useful life in energy storage devices[J]. *Studies in Informatics and Control*, 2010, 19(3): 209-218.
- [18] 李洪, 张营, 邹博雨, 等. 基于 EMD-GPR 的锂离子电池剩余寿命预测方法研究[J]. *农业装备与车辆工程*, 2021, 59(11): 60-63.
LI Yang, ZHANG Ying, ZOU Boyu, et al. Research on residual life prediction method of lithium ion battery based on EMD-GPR[J]. *Agricultural Equipment & Vehicle Engineering*, 2021, 59(11): 60-63.
- [19] 张朝龙, 赵筛筛, 何怡刚. 基于集成经验模态分解与集成机器学习的锂离子电池剩余使用寿命预测方法[J]. *电力系统保护与控制*, 2023, 51(13): 177-186.
ZHANG Chaolong, ZHAO Shaishai, HE Yigang. Remaining useful life prediction method for lithium-ion batteries based on ensemble empirical mode decomposition and ensemble machine learning[J]. *Power System Protection and Control*, 2023, 51(13): 177-186.
- [20] HE Yaoyao, WANG Yun. Short-term wind power prediction based on EEMD-LASSO-QRNN model[J]. *Applied Soft Computing*, 2021, 105.
- [21] LI Hua, LIU Tao, WU Xing, et al. Research on test bench bearing fault diagnosis of improved EEMD based on improved adaptive resonance technology[J]. *Measurement*, 2021, 185.
- [22] 申永鹏, 谢俊超, 梁伟华, 等. 电动汽车混合储能系统 CEEMD-PE 能量管理策略[J]. *电力系统保护与控制*, 2023, 51(13): 122-131.
SHEN Yongpeng, XIE Junchao, LIANG Weihua, et al. Electric vehicle hybrid energy storage system CEEMD-PE energy management strategy[J]. *Power System Protection and Control*, 2023, 51(13): 122-131.
- [23] 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.
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.
- [24] 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: 4144-4147.
- [25] 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 Haoyi, HE Xiaoxia, LIANG Jiajia, 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.
- [26] SAHAAND B, GOEBEL K. Battery data set, NASA AMES prognostics data repository[J]. NASA Ames Research Center, 2007.
- [27] ALMAITA E, ALSHKOOR S, ABDELSALAM E, et al. State of charge estimation for a group of lithium-ion batteries using long short-term memory neural network[J]. *Journal of Energy Storage*, 2022, 52.
- [28] QU Jiantao, LIU Feng, MA Yuxiang, et al. A neural-network-based method for RUL prediction and SOH monitoring of lithium-ion battery[J]. *IEEE Access*, 2019, 7: 87178-87191.
- [29] GUO Xifeng, WANG Kaize, YAO Shu, et al. RUL prediction of lithium ion battery based on CEEMDAN-CNN BiLSTM model[J]. *Energy Reports*, 2023, 9: 1299-1306.
- [30] CAI Yuxiang, LI Weimin, ZAHID T, et al. Early prediction of remaining useful life for lithium-ion batteries based on CEEMDAN-transformer-DNN hybrid model[J]. *Heliyon*, 2023, 9(7).
- [31] QIN Xiaoli, ZHAO Qi, ZHAO Hongbo, et al. Prognostics of remaining useful life for lithium-ion batteries based on a feature vector selection and relevance vector machine approach[C] // 2017 IEEE International Conference on Prognostics and Health Management (ICPHM), June 19-21, 2017, Dallas, USA: 1-6.

收稿日期: 2023-11-27; 修回日期: 2024-01-07

作者简介:

刘斌(1983—), 男, 博士, 副教授, 硕士生导师, 研究方向为系统可靠性及寿命预测; E-mail: liubin@tyust.edu.cn

吉春霖(2000—), 男, 通信作者, 硕士研究生, 研究方向为电池剩余寿命预测。E-mail: jj1328318271@163.com

(编辑 姜新丽)