

储能锂离子电池系统关键技术专刊



## 多尺度分解下GRU-MLR组合的锂电池剩余使用寿命预测方法

武明虎<sup>1,2</sup>, 岳程鹏<sup>2</sup>, 张凡<sup>1,2</sup>, 李俊晓<sup>3</sup>, 黄伟<sup>2</sup>, 胡胜<sup>1,2</sup>, 唐靓<sup>2</sup>

(<sup>1</sup>湖北工业大学太阳能高效利用及储能运行控制湖北省重点实验室, <sup>2</sup>湖北工业大学电气与电子工程学院, 湖北 武汉 430068; <sup>3</sup>郑州日产汽车有限公司, 河南 郑州 450046)

**摘要:** 准确预测锂电池的剩余使用寿命(remaining useful life, RUL)可以及时了解电池内部的性能退化情况, 降低电池的使用风险并为日常维护提供可靠的理论依据。为了提高预测结果的准确性和稳定性, 提出了一种基于集合经验模态分解(ensemble empirical mode decomposition, EEMD)、门控循环单元网络(gated recurrent unit, GRU)和多元线性回归(multiple linear regression, MLR)相结合的锂电池RUL预测模型。该模型首先采用EEMD算法将锂电池容量数据分解为若干个高频分量和低频分量, 以此减少容量数据中的噪声干扰, 然后针对各个分量的特点, 分别利用GRU和MLR网络基于获得的高频和低频序列建立预测子模型, 最后叠加融合各个子模型的预测值得到锂电池的RUL结果, 通过使用NASA和Oxford提供的锂电池公开数据, 并采用不同的预测起点与其他单一模型和组合模型进行对比。实验结果表明, EEMD-GRU-MLR预测模型能够提供准确的RUL结果, 相比于LSTM、GRU和EEMD-GRU预测模型, 最大平均绝对误差分别降低了0.0311、0.0234、0.0182, 最大均方根误差分别降低了0.0235、0.0153、0.0098, 证明了本模型具有较好的锂电池RUL预测能力。

**关键词:** 锂电池; 剩余使用寿命; 集合经验模态分解; 门控循环单元网络; 多元线性回归

doi: 10.19799/j.cnki.2095-4239.2023.0298

中图分类号: TM 912

文献标志码: A

文章编号: 2095-4239 (2023) 07-2220-09

## Combined GRU-MLR method for predicting the remaining useful life of lithium batteries via multiscale decomposition

WU Minghu<sup>1,2</sup>, YUE Chengpeng<sup>2</sup>, ZHANG Fan<sup>1,2</sup>, LI Junxiao<sup>3</sup>, HUANG Wei<sup>2</sup>,  
HU Sheng<sup>1,2</sup>, TANG Jing<sup>2</sup>

(<sup>1</sup>Hubei University of Technology, Hubei Provincial Key Laboratory of Solar Energy Efficient Utilization and Energy Storage Operation Control; <sup>2</sup>School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, Hubei, China; <sup>3</sup>Zhengzhou Nissan Automobile Co., Ltd., Zhengzhou 450046, Henan, China)

**Abstract:** Accurately predicting the remaining useful life (RUL) of lithium batteries can ensure timely understanding of the internal performance degradation of the battery, reduce the risks associated with battery use, and provide a reliable theoretical basis for routine maintenance. To improve the accuracy and stability of prediction results, a lithium-battery RUL prediction model based on the combination of ensemble empirical mode decomposition (EEMD) and gated recurrent unit (GRU) with multiple linear regression (MLR) is proposed. First, the model decomposes the lithium-battery capacity data into several high-frequency and low-frequency

收稿日期: 2023-05-04; 修改稿日期: 2023-05-21。

基金项目: 湖北省重点研发计划项目(2021BGD013), 湖北省科技计划项目(2022BEC017), 湖北省自然科学基金项目(2022CFA007)。

第一作者: 武明虎(1975—), 男, 博士, 教授, 研究方向为智能电网、动力电池安全管理, E-mail: 18239368097@163.com; 通讯作者: 张凡, 讲师, 研究方向为电磁场理论及工程应用、智能信号处理, E-mail: 15938907139@163.com。

引用本文: 武明虎, 岳程鹏, 张凡, 等. 多尺度分解下GRU-MLR组合的锂电池剩余使用寿命预测方法[J]. 储能科学与技术, 2023, 12(7): 2220-2228.

**Citation:** WU Minghu, YUE Chengpeng, ZHANG Fan, et al. Combined GRU-MLR method for predicting the remaining useful life of lithium batteries via multiscale decomposition[J]. Energy Storage Science and Technology, 2023, 12(7): 2220-2228.

components using the EEMD algorithm to reduce noise interference in the capacity data. Then, based on the characteristics of each component, the model builds prediction submodels based on the obtained high-frequency and low-frequency sequences using the GRU and MLR networks, respectively. Finally, the predicted values of each submodel are superimposed and fused to obtain the RUL of the battery based on the public data on lithium batteries provided by NASA and Oxford; furthermore, using different prediction starting points, the obtained results are compared with those of other single and combined models. The experimental results show that the EEMD-GRU-MLR prediction model can provide accurate RUL results, compared with LSTM, GRU, and EEMD-GRU prediction models, with the maximum mean absolute error decreased by 0.0311, 0.0234, and 0.0182, respectively, and the maximum root mean square error decreased by 0.0235, 0.0153, and 0.0098, respectively. This proves the satisfactory ability of the proposed EEMD-GRU-MLR model to predict the RUL of lithium batteries.

**Keywords:** lithium battery; remaining useful life; ensemble empirical mode decomposition; gated recurrent unit network; multiple linear regression

锂电池因其能量密度高、自放电率低、循环寿命长等优点被大量应用在电子产品、新能源汽车以及储能系统等众多领域,然而随着充放电循环周期的增加,锂电池会出现可用容量下降、内阻增大等性能退化现象,最终将会失效。在电池剩余使用寿命(remaining useful life, RUL)预测研究中通常将电池容量作为健康特征,用来定量描述电池健康状况的退化程度,使用电池容量作为表征电池性能的健康特征能够直观反映电池的退化情况<sup>[1]</sup>。通常认为当电池容量衰减至70%~80%时表示锂电池的使用寿命结束(end of life, EOL)<sup>[2]</sup>,如果在失效前无法及时更换电池,将会给设备运行带来巨大的安全风险,严重影响系统运行稳定性和可靠性<sup>[3]</sup>。因此,对锂电池的剩余使用寿命进行准确预测,提前获取电池状态的相关信息,在衰退到安全阈值之前及时更换,可以有效减少电池事故的发生。

当前对于锂电池RUL预测主要有模型法和数据驱动法,基于模型的方法可以较好地反映电池的外部动态特性。文献[4]基于构建的电化学模型模拟电池充放电工作过程,分析电池容量衰减的影响因素,进而预测出电池RUL,但是由于电化学模型是动态和非线性的,很难建立准确的电池退化模型。文献[5]在等效电路模型的基础上研究锂电池的内部参数,文献[6]采用拓展的等效电路模型来进行锂电池状态估计,并得到较为精确的结果,但电池内部反应机制过于复杂,难以精确描述电池结构和理化

现象。文献[7]构建了无迹粒子滤波算法的等效电路模型,文献[8]基于改进粒子滤波算法实现了锂电池的RUL预测,虽然对预测精度有所改进,但其模型搭建和计算过程都较为复杂,这些缺点极大阻碍了基于模型的方法在实际中的应用。

与之相比,基于数据驱动的方法步骤较少、操作方便,具有较强的实用性<sup>[9]</sup>。基于数据驱动的方法无需了解电池内部复杂的反应机理,只需从外部特性的历史数据中挖掘性能退化的规律,就能精确地构建出RUL预测模型<sup>[10]</sup>。文献[11]提出一种基于差分电压和Elman神经网络的方法,通过分析电池差分电压曲线和充放电曲线,提取电池容量的退化特征作为健康特征,构建电池容量为输出的Elman神经网络,提高了锂电池RUL预测精度。文献[12]通过使用随机森林算法对电池容量数据分解出来的每个分量进行重要性排序,避免了波动分量里的噪音对模型预测能力的影响,且又保留了波动分量里的特征信息。对于锂电池性能退化过程中存在的容量再生问题,文献[13]提出了一种多尺度逻辑回归(logistic regression, LR)和高斯过程回归(gaussian process regression, GPR)相结合的预测方法,使用经验模态分解(empirical mode decomposition, EMD)将容量数据分解为整体退化、部分回升以及各种波动,从而削弱了容量再生现象对状态评估的影响。文献[14]采用EMD算法将容量数据分解为高频和低频两种分量,分别通过Elman和长短期记忆

(long short term memory, LSTM)网络建模,并叠加预测结果得出RUL。但这种方法忽视了EMD本身的局限性,EMD在分解过程中会产生模态混叠现象,无法根据前期的容量退化趋势完成精确的性能评估,而集合经验模态分解(ensemble empirical mode decomposition, EEMD)算法克服了模态混叠现象,分解结果更为彻底、重构误差更小,在提升预测模型的精度方面具有突出的优势。文献[15-16]使用LSTM神经网络较好地预测出RUL结果,并且降低了预测误差,但是网络结构较复杂,参数量过多。文献[17]构建了基于变分模态分解(variational modal decomposition, VMD)与门控循环单元(gated recurrent unit, GRU)相结合的RUL预测模型,因为GRU所需参数更少,可在确保模型精度的同时,加快模型的收敛速度。

基于以上分析,本工作选择以锂电池容量数据作为健康特征,提出了一种基于EEMD多尺度分解下GRU与多元线性回归(multiple linear regression, MLR)组合的锂电池RUL预测方法。该方法首先采用EEMD算法将容量数据分解为高频分量和低频分量,然后分别使用GRU和MLR网络对所分解的退化数据进行趋势预测,再对各个预测结果进行叠加重构,这样既可以准确反映出电池退化的整体趋势,又能够捕捉到高频分量中隐藏的退化信息,提高了预测精度。最后选取NASA和Oxford提供的锂电池数据集作为研究对象来评估模型的性能,验证本模型的准确性和稳定性。实验结果表明,该预测模型能够克服锂电池在寿命预测过程中存在的剧烈波动,准确挖掘到锂电池容量变化过程的潜藏特征,具有性能稳定且精度更高等优点。

## 1 基于EEMD-GRU-MLR锂电池寿命预测模型

### 1.1 集合经验模态分解

EMD可以将复杂信号分解为有限个本征模态函数(intrinsic mode function, IMF),但EMD在分解时容易产生一个IMF分量包含不同时间尺度特征成分的模态混叠现象,从而使IMF失去原本的含义。EEMD是由Wu等<sup>[18]</sup>提出的基于噪声辅助分析而改进的EMD方法,其原理是进行 $n$ 次重复EMD分解信号的过程,通过在每次分解过程中都向初始信号加入零均值、固定方差的白噪声,利用白噪声

均值为零的特性,抵消噪声影响。将集成平均后的结果作为最终结果,有效消除了EMD算法的模态混叠现象,实现了信号在适当时间尺度的自动分布,提升了分解效率。通过EEMD算法,信号被分解成不同时间尺度下的IMF分量,相比于初始信号,各IMF分量波动幅度降低,对其进行趋势预测可以获得更加准确的预测结果。

由于锂电池的容量退化曲线并不是平滑无波动的,而是存在着容量再生现象,是包含全局退化和局部回升不同尺度下的混合信号。如果预测时不加以区分退化趋势部分和局部震荡部分,直接进行训练会对预测结果的精确度造成一定影响,所以采用EEMD提取出容量退化数据中的局部特征,极大降低了容量再生现象产生的震荡信号对模型预测性能的影响。EEMD算法的具体步骤如下:

(1) 向初始信号 $x(t)$ 中添加白噪声序列 $w_i(t)$ 获取新信号 $X_i(t)$ :

$$X_i(t) = x(t) + w_i(t) \quad (1)$$

式中, $i$ 为添加白噪声的次数。

(2) 将 $X_i(t)$ 进行EMD分解,得到各阶IMF分量和的形式及分解后的剩余分量 $r_{es}$ :

$$X_i(t) = \sum_{j=1}^n c_{ij}(t) + r_{es} \quad (2)$$

式中, $c_{ij}(t)$ 为第 $i$ 次添加白噪声后分解得到的第 $j$ 个IMF分量, $j$ 的取值范围为 $1 \sim n$ 。

(3) 重复以上两个步骤 $M$ 次,并将每次得到的IMF分量相加再求均值作为最终结果:

$$c_j(t) = \frac{1}{M} \sum_{i=1}^M c_{ij}(t) \quad (3)$$

式中, $c_j(t)$ 为对初始信号进行EEMD分解后得到的第 $j$ 个IMF分量平均值。

### 1.2 多元线性回归

在回归分析中存在两个及两个以上的自变量,而且当多个自变量与因变量之间是线性关系时,所进行的回归分析就是多元线性回归。对于周期性强、趋势平稳的曲线,相比于常见的神经网络,该回归分析方法具有预测精度更高,参数易于调节和运行速度快等优势。电池容量数据中低频分量趋势比较平缓,采用MLR既不需要确定具体参数,且预测效果和收敛速度也较好,MLR的矩阵表达式和展开式分别为:

$$Y = X \times \beta + \mu \quad (4)$$



$$\begin{bmatrix} y_2 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1n} \\ 1 & x_{21} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \cdots & x_{nn} \end{bmatrix} \times \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_n \end{bmatrix} + \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{bmatrix} \quad (5)$$

式中,  $\mathbf{Y}$  为待预测数据,  $\mathbf{X}$  为历史数据,  $\beta$  为回归系数,  $\mu$  为随机扰动。利用最小二乘法进行参数求解, 即可得到回归函数, 其公式为:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (6)$$

### 1.3 门控循环单元

GRU 是对 LSTM 神经网络模型结构进行了优化, 合并了遗忘门和输入门为更新门, 减少了网络的参数量, 加快了收敛速度, 同时有效减小数据过拟合的风险。锂电池容量数据衰减至失效的过程具有时间序列特征, 而 GRU 神经网络适合对时间序列进行精准分析, 同时由于容量数据中高频分量波动较大, 采用 GRU 神经网络可以有效捕捉其中的特征参数, 能够对锂电池的 RUL 进行很好的预测。GRU 网络结构如图 1 所示。




图 1 GRU 网络内部结构图

Fig. 1 Internal structure diagram of GRU network

状态与输出的计算公式如下:

$$r_t = \sigma(\mathbf{W}_r \cdot [h_{t-1}, x_t]) \quad (7)$$

$$z_t = \sigma(\mathbf{W}_z \cdot [h_{t-1}, x_t]) \quad (8)$$

$$\tilde{h}_t = \tanh(\mathbf{W}_h \cdot [r_t h_{t-1}, x_t]) \quad (9)$$

$$h_t = (1 - z_t)h_{t-1} + z_t \tilde{h}_t \quad (10)$$

式中,  $r_t$  为重置门,  $h_{t-1}$  为前一时刻的隐藏状态,  $x_t$  为当前时刻的输入,  $z_t$  为更新门,  $\tilde{h}_t$  为重置门计算的隐藏状态,  $h_t$  为更新门对隐藏状态的更新,  $\mathbf{W}_r$ 、 $\mathbf{W}_z$  和  $\mathbf{W}_h$  为权重矩阵,  $\sigma$  和  $\tanh$  为激活函数。

### 1.4 EEMD-GRU-MLR 预测模型建立

由于锂电池容量数据是含有强滞后相关性特征的时序数据, 为避免使用单一模型对锂电池进行 RUL 预测会产生精确度不足等问题, 本工作提出一种 EEMD-GRU-MLR 组合预测模型, 其流程图如图 2 所示。

种 EEMD-GRU-MLR 组合预测模型, 其流程图如图 2 所示。

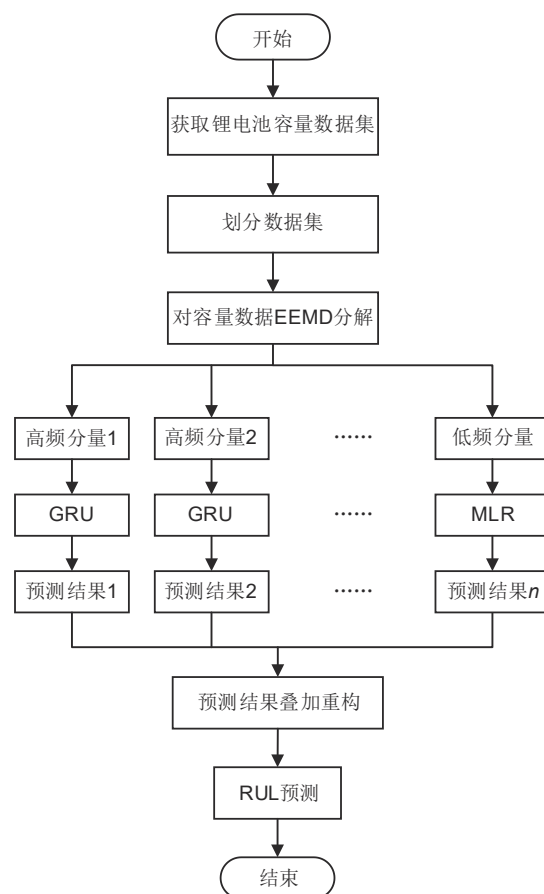


图 2 EEMD-GRU-MLR 模型整体流程图

Fig. 2 Overall flow chart of EEMD-GRU-MLR model

其主要流程如下:

(1) 选择容量数据作为反映电池性能退化的健康特征;

(2) 设定第  $T$  个循环周期为预测起点, 将第 1~ $T$  个循环周期的数据作为训练集, 以第  $T$  个循环周期之后的数据作为测试集验证预测模型;

(3) 利用 EEMD 算法将容量序列分解为有限个高频分量和低频分量;

(4) 结合 GRU 和 MLR 网络基于获得的高频分量和低频分量序列分别建立子预测模型, 通过对训练集的充分学习, 建立容量前期与后期的映射关系。其中, GRU 网络为双层结构, 且 GRU 网络的神经元个数多以  $2^n$  递加, 本工作设定神经元个数为 128, 采用 Adam 优化策略, 迭代次数为 300;

(5) 将测试集数据代入训练好的 GRU 模型和


MLR模型中,对未知的序列进行预测,并将预测结果进行有效集成;

(6) 经过迭代预测得到起点后每一个循环的容量预测值,将预测的容量结果与失效阈值进行对比,以此来判定锂电池的性能退化状况,进而计算出RUL结果。


## 2 实验结果与分析

### 2.1 实验数据集介绍与分析

本实验采用两组锂电池数据集验证所提方法的预测性能,第一组数据来自NASA锂电池数据集<sup>[19]</sup>,额定容量为2.0 Ah,选用其中的B0005、B0006、B0007号电池作为测试对象,以额定容量的70%看作锂电池的失效阈值,即1.4 Ah,考虑到B0007号电池容量没有下降到1.4 Ah以下,故设置为1.42 Ah。第二组数据来自Oxford电池老化数据集<sup>[20]</sup>,额定容量为740 mAh,选用编号为Cell1、Cell2的电池作为测试对象,以额定容量的80%看作锂电池的失效阈值,即590 mAh。其两组电池容量随充放电循环周期的变化如图3所示。



(a) NASA数据集容量退化曲线



(b) Oxford数据集容量退化曲线

图3 电池容量退化曲线

Fig. 3 Capacity degradation curves of batteries

从图3可以看出随着循环周期的增加,电池容量呈现退化趋势,因受电池内部电化学反应机理等因素的影响,退化曲线还存在着容量回升现象,这给电池RUL的精准预测带来了困难。因此,将容量序列进行分解可以有助于预测模型更好地学习潜在特征信息。

### 2.2 EEMD分解结果分析

以B0005号锂电池容量衰减数据为例,采用EEMD算法将容量信号分解为按频率从高到低排列的IMF1~IMF5,分解结果如图4所示,其中IMF1~IMF3曲线起伏较大,波动性强,可作为高频分量;IMF4和IMF5曲线平缓,与初始容量趋势相似,且没有容量重生现象,可作为低频分量。




图4 基于EEMD的B0005容量序列分解

Fig. 4 B0005 capacity sequence decomposition based on EEMD

### 2.3 实验数据处理

使用第1~ $T$ 个循环周期的容量数据作为输入进行模型训练,以第 $T$ 个循环周期之后的容量数据作为输出验证预测模型,分别为:

$$\begin{cases} C_{\text{train}} = \{C_1, C_2, C_3, \dots, C_{T-1}, C_T\} \\ C_{\text{test}} = \{C_{T+1}, C_{T+2}, \dots, C_{n-1}, C_n\} \end{cases} \quad (11)$$

由于数据集中可用数据较少,故采用滑动窗口的方法对数据进行分割,并逐一输入到网络中,滑动预测后续循环的电池容量。此外还需对数据采用线性归一化消除数据量纲带来的影响,将输入数据都转换到[0,1]的范围,从而提升预测精度,计算式

如式(12)所示：

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (12)$$

式中,  $x_{\text{norm}}$  为归一化后的数据,  $x$  为原始数据,  $x_{\max}$ 、 $x_{\min}$  分别表示原始数据集中的最大值和最小值。

## 2.4 模型评价指标

为更全面地评估模型的性能, 采用如下3个指标进行评价, 分别是绝对误差(absolute error, AE)、平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE), 其计算公式见式(13)~(15)。

$$AE = |T_{\text{RUL}} - \hat{T}_{\text{RUL}}| \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x(i) - \hat{x}(i)| \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [x(i) - \hat{x}(i)]^2} \quad (15)$$

式中,  $T_{\text{RUL}}$  为真实情况下电池寿命结束时的所在周期数,  $\hat{T}_{\text{RUL}}$  为RUL预测值,  $n$  为预测循环周期数,  $x(i)$  为容量实际值,  $\hat{x}(i)$  为容量预测值。

## 2.5 实验结果对比分析

为验证本工作提出的EEMD-GRU-MLR组合模型的优越性, 分别与其他三种模型进行对比分析, 各预测模型的具体描述见表1。

表1 方法说明

Table 1 Methods statement

实验方法	模型名称
M1	LSTM
M2	GRU
M3	EEMD-GRU
M4	EEMD-GRU-MLR

图5展示了当预测起点  $T$  为80时, 四种预测方法在NASA数据集下的RUL预测结果, 其评价指标对比见表2。

通过图5中四种方法的预测效果可以看出, 本工作所提方法M4的预测曲线更贴近实际的容量退化曲线, 尤其是在容量回升阶段表现更佳, 能够准确捕捉容量波动趋势。而只使用LSTM、GRU单一模型的M1、M2方法, 在预测初期可以拟合到真实容量的变化, 但到预测中后期对真实容量的偏差逐渐增大。从图中可以发现M3曲线和M4曲线比M1和M2曲线更贴近真实曲线, 这是由于EEMD算法




图5 四种方法的RUL预测结果-NASA

Fig. 5 RUL prediction results for four methods-NASA

将容量信号分解为多个IMF分量, 能够有效降低噪声干扰, 进一步提高预测精度。同理, 对比M4曲线和M3曲线与真实曲线的拟合程度, 可以看出M4曲线在平滑部分更贴近真实曲线, 这是由于MLR对低频分量的拟合精度更高。

表2给出了不同预测方法在NASA数据集下的评价指标, 从表中的数据可知, M1、M2和M3方法的最大MAE和RMSE分别为0.0402、0.0325、0.0273和0.0428、0.0346、0.0291, 而M4方法的最大MAE和最大RMSE分别为0.0091和0.0193,

表2 四种方法的评价指标对比-NASA					
Table 2 Comparison of evaluation indexes of four methods-NASA					
电池编号	预测方法	RUL 预测值	AE	MAE	RMSE
B0005	M1	138	13	0.0402	0.0428
	M2	133	8	0.0325	0.0346
	M3	131	6	0.0273	0.0291
	M4	124	1	0.0091	0.0149
B0006	M1	114	5	0.0342	0.0395
	M2	113	4	0.0255	0.0307
	M3	112	3	0.0180	0.0245
	M4	109	0	0.0079	0.0193
B0007	M1	—	—	0.0361	0.0388
	M2	—	—	0.0277	0.0300
	M3	167	7	0.0103	0.0145
	M4	158	2	0.0075	0.0142

M4方法在NASA数据集下的AE值均较小，整体不超过两个循环周期。相比于其他三种方法，在同等条件下M4方法的误差评判指标均为最小值，证明了本工作所提方法具有较高的预测精度。

为进一步测试M4方法的预测性能，将预测起点 $T$ 分别设置为60、80和100进行RUL预测，图6展示了M4方法在不同起点下的预测结果，其评价指标对比见表3。


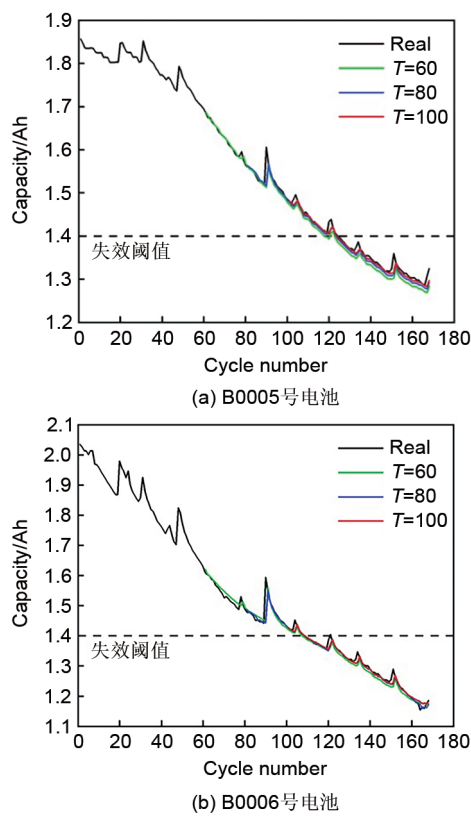


图6 不同起点的RUL预测结果-NASA  
Fig. 6 RUL prediction results for different starting points-NASA

表3 不同起点的评价指标对比-NASA					
Table 3 Comparison of evaluation indexes of different starting points-NASA					
电池编号	预测起点	RUL 预测值	AE	MAE	RMSE
B0005	60	118	7	0.0128	0.0178
	80	124	1	0.0091	0.0149
	100	124	1	0.0059	0.0099
B0006	60	108	1	0.0122	0.0200
	80	109	0	0.0079	0.0193
	100	109	0	0.0070	0.0118
B0007	60	156	4	0.0106	0.0158
	80	158	2	0.0075	0.0142
	100	159	1	0.0048	0.0080

结合图6和表3可知，M4方法在预测起点为80和100时都能给出较为准确的RUL结果，当预测起点为60时，由于训练数据减少，模型未能得到充分学习和训练，导致预测精度有所下降。当预测起点为100时，该方法的预测精度最优，但相比于预测起点为80时的性能提升并不大。由B0005号电池在起点为60的预测结果可知，预测曲线在第118个循环周期的容量数值降至1.4 Ah以下，达到失效阈值，但随后又因容量波动回升至1.41 Ah，最后在第123个循环周期时，再次降至失效阈值以下。B0006号电池在不同预测起点下的RUL绝对误差均较小，这是因为在预测初期，模型能够很好地追踪到容量的变化，所以预测误差较小，但随着循环周期的增加，中后期的预测误差也会逐渐增大。以上实验结果表明，本工作所提出的预测方法在预测起点不同的情况下依旧可以有效预测出电池容量的整体退化趋势。



此外，为了验证本工作所提方法在不同电池数据下的鲁棒性和适应性，将该方法应用到 Oxford 电池老化数据集，并与其他三种方法进行对比，同时将每块测试电池的预测起点  $T$  设置为 40。其预测结果如图 7 所示，评价指标对比见表 4。

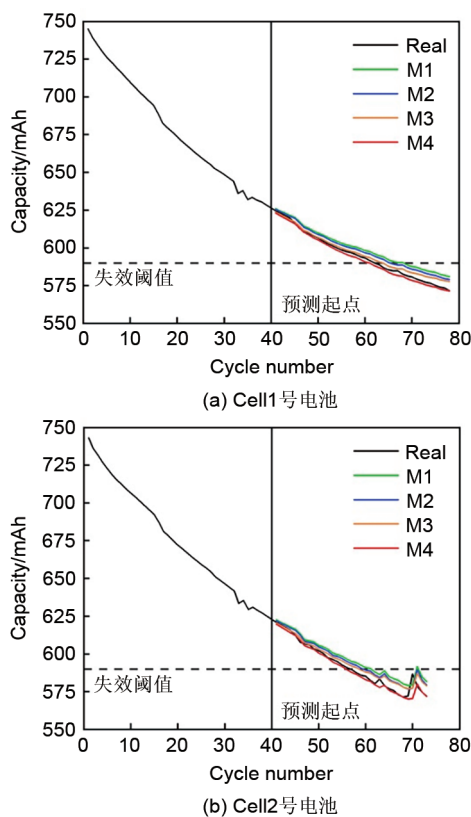


图 7 四种方法的 RUL 预测结果-Oxford  
Fig. 7 RUL prediction results for four methods-Oxford

表 4 四种方法的评价指标对比-Oxford  
Table 4 Comparison of evaluation indexes of four methods-Oxford

电池编号	预测方法	RUL 预测值	AE	MAE	RMSE
Cell1	M1	69	6	0.0054	0.0058
	M2	66	3	0.0034	0.0036
	M3	64	1	0.0018	0.0022
	M4	62	1	0.0013	0.0014
Cell2	M1	62	5	0.0059	0.0065
	M2	60	3	0.0045	0.0052
	M3	59	2	0.0034	0.0043
	M4	56	1	0.0018	0.0033

由图 7 的预测结果可以看出本工作所提方法的预测曲线最贴近真实的容量退化曲线，均有比其他三种预测方法更高的预测精度，同时实验数据集的变

化未对本工作方法的预测效果产生较大影响，反映出本工作方法具有一定稳定性和泛用性。表 4 给出了四种预测方法在 Oxford 数据集中预测结果的评价指标，其中 M1、M2 和 M3 方法的最大 MAE 和 RMSE 分别为 0.0059、0.0045、0.0034 和 0.0065、0.0052、0.0043，而 M4 方法的最大 MAE 和最大 RMSE 分别为 0.0018 和 0.0033，均有一定程度的改善，可见本工作所提方法在 RUL 预测上具有更好的优势。

### 3 结 论

针对锂电池剩余使用寿命预测，本工作提出了一种基于 EEMD-GRU-MLR 组合模型的 RUL 预测方法，将容量数据作为健康特征，并使用 EEMD 分解为高频分量和低频分量，通过叠加重构子模型 GRU 和 MLR 的预测结果来得到 RUL。选用 NASA 和 Oxford 实验数据并设置不同的预测起点，采用多种实验方案验证了该方法的优越性和可靠性，得出的主要结论如下。

(1) 通过 EEMD 算法将锂电池容量序列分解为多个 IMF 分量，相比于初始容量数据曲线具有更简单的波动规律和显著的频率特征，可以有效减弱容量回升和测试误差等噪声干扰，降低数据的复杂度和不稳定性，进一步简化预测模型的学习难度，从而减小预测偏差，提高了预测精度。

(2) 将 IMF 分量分为高频和低频，并分别使用合适的网络进行针对性预测，能够有效捕捉到数据的特征信息，通过整合两种网络的预测结果，可以得到更为精确的 RUL 结果，大大提高了预测方法的准确性和稳定性。

(3) 本工作所提出的 EEMD-GRU-MLR 组合模型相比于 LSTM、GRU 和 EEMD-GRU 预测模型，最大平均绝对误差分别降低了 0.0311、0.0234、0.0182，最大均方根误差分别降低了 0.0235、0.0153、0.0098，绝对误差均为最小值，对于不同数据集的锂电池 RUL 预测均有较高的预测精度，相较于其他同类预测方法具有一定的优势，可有效应用于锂电池 RUL 预测。

### 参 考 文 献

[1] 胡天中, 余建波. 基于多尺度分解和深度学习的锂电池寿命预测[J]. 浙江大学学报(工学版), 2019, 53(10): 1852-1864.  
HU T Z, YU J B. Life prediction of lithium-ion batteries based on multiscale decomposition and deep learning[J]. Journal of Zhejiang



- University (Engineering Science), 2019, 53(10): 1852-1864.
- [2] 梁海峰, 袁芑, 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.
- [3] 李超然, 肖飞, 樊亚翔, 等. 基于卷积神经网络的锂离子电池SOH估算[J]. 电工技术学报, 2020, 35(19): 4106-4119.  
LI C R, XIAO F, FAN Y X, et al. An approach to lithium-ion battery SOH estimation based on convolutional neural network[J]. Transactions of China Electrotechnical Society, 2020, 35(19): 4106-4119.
- [4] KHODADADI SADABADI K, JIN X, RIZZONI G. Prediction of remaining useful life for a composite electrode lithium ion battery cell using an electrochemical model to estimate the state of health[J]. Journal of Power Sources, 2021, 481: doi: 10.1016/j.jpowsour.2020.228861.
- [5] 严干贵, 蔡长兴, 段双明, 等. 锂离子储能电池成组方式优化[J]. 电力自动化设备, 2021, 41(4): 148-153.  
YAN G G, CAI C X, DUAN S M, et al. Grouping mode optimization of lithium-ion energy storage battery[J]. Electric Power Automation Equipment, 2021, 41(4): 148-153.
- [6] 杨新波, 郑岳久, 高文凯, 等. 基于改进等效电路模型的高比能量储能锂电池系统功率状态估计[J]. 电网技术, 2021, 45(1): 57-66.  
YANG X B, ZHENG Y J, GAO W K, et al. Power state estimation of high specific energy storage lithium battery system based on extended equivalent circuit model[J]. Power System Technology, 2021, 45(1): 57-66.
- [7] 谢滢馨, 王顺利, 史卫豪, 等. 一种用于高保真锂电池SOC估计的无迹粒子滤波新方法[J]. 储能科学与技术, 2021, 10(2): 722-731.  
XIE Y X, WANG S L, SHI W H, et al. A new method of unscented particle filter for high-fidelity lithium-ion battery SOC estimation[J]. Energy Storage Science and Technology, 2021, 10(2): 722-731.
- [8] 焦自权, 范兴明, 张鑫, 等. 基于改进粒子滤波算法的锂离子电池状态跟踪与剩余使用寿命预测方法[J]. 电工技术学报, 2020, 35(18): 3979-3993.  
JIAO Z Q, FAN X M, ZHANG X, et al. State tracking and remaining useful life predictive method of Li-ion battery based on improved particle filter algorithm[J]. Transactions of China Electrotechnical Society, 2020, 35(18): 3979-3993.
- [9] 姚芳, 张楠, 黄凯. 锂离子电池状态估算与寿命预测综述[J]. 电源学报, 2020, 18(3): 175-183.  
YAO F, ZHANG N, HUANG K. Review of state estimation and life prediction for lithiumion batteries[J]. Journal of Power Supply, 2020, 18(3): 175-183.
- [10] 杨彦茹, 温杰, 史元浩, 等. 基于CEEMDAN和SVR的锂离子电池剩余使用寿命预测[J]. 电子测量与仪器学报, 2020, 34(12): 197-205.  
YANG Y R, WEN J, SHI Y H, et al. Remaining useful life prediction for lithium-ion battery based on CEEMDAN and SVR[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(12): 197-205.
- [11] 李练兵, 李思佳, 李洁, 等. 基于差分电压和Elman神经网络的锂离子电池RUL预测方法[J]. 储能科学与技术, 2021, 10(6): 2373-2384.  
LI L B, LI S J, LI J, et al. RUL prediction of lithium-ion battery based on differential voltage and Elman neural network[J]. Energy Storage Science and Technology, 2021, 10(6): 2373-2384.
- [12] 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.
- [13] YU J B. State of health prediction of lithium-ion batteries: Multiscale logic regression and Gaussian process regression ensemble[J]. Reliability Engineering & System Safety, 2018, 174: 82-95.
- [14] LI X Y, ZHANG L, WANG Z P, et al. Remaining useful life prediction for lithium-ion batteries based on a hybrid model combining the long short-term memory and Elman neural networks[J]. Journal of Energy Storage, 2019, 21: 510-518.
- [15] 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.
- [16] 张少凤, 张清勇, 杨叶森, 等. 基于滑动窗口和LSTM神经网络的锂离子电池建模方法[J]. 储能科学与技术, 2022, 11(1): 228-239.  
ZHANG S F, ZHANG Q Y, YANG Y S, et al. Lithium-ion battery model based on sliding window and long short term memory neural network[J]. Energy Storage Science and Technology, 2022, 11(1): 228-239.
- [17] 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.
- [18] WU Z H, HUANG N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [19] SAHA B, GOEBEL K. Battery data set[R]. NASA Ames Prognostics Data Repository, 2007.
- [20] BIRKL C. Diagnosis and prognosis of degradation in lithium-ion batteries[D]. Oxford, South East England, UK: University of Oxford, 2017.