《工程科学学报》录用稿，https://doi.org/10.13374/j.issn2095-9389.2020.06.30.007 ©北京科技大学 2020

基于 CEEMDAN-LSTM 组合的锂离子电池寿命预测方法

史永胜[1)]，施梦琢[1)]，丁恩松[2)]，洪元涛[1)]，欧阳[1)]

1）陕西科技大学电气与控制工程学院，西安 710021 2）江苏润寅石墨烯科技有限公司，扬州 225600

通信作者 E-mail:84770540@qq.com

摘 要 锂离子电池进行准确的寿命预测在电池健康管理中具有重要意义。针对目前锂离子电池寿命预测结果不准确的问题，文中提出了一种多模态分解的锂离子电池组合预测模型，从而学习锂离子电池退化过程的微小变化。该方法在单一 LSTM 预测模型的基础上，采用了自适应噪声完全集成的经验模态分解(CEEMDAN)算法将锂电池容量分为主退化趋势和若干局部退化趋势，然后使用长短期记忆神经网络（LSTMNN）算法分别对所分解的若干退化数据进行寿命预测，最后将若干预测结果进行有效集成。验证结果表明，所提出的 CEEMDAN-LSTM 锂离子电池组合预测模型最大 MAPE 不超过 1.5%，平均相对误差在 3%以内，且优于其他预测模型。

关键词 电池健康管理；锂离子电池；剩余使用寿命；长短期记忆神经网络；自适应噪声完全集成经验模态分解

分类号 TM912

The Combined Prediction Method Of Lithium-ion Battery Life Based on CEEMDAN-LSTM

SHI Yong-sheng[1)]，SHI Meng-zhuo[1)]，DING En-song[2)]，HONG Yuan-tao[1)]，OU Yang[1)]

1) College of Electrical and Control Engineering, Shanxi University of Since and Technology, Xi'an 710021, China;

2) Jiangsu Runyin Graphene Technology Co., Yangzhou 225600, China;

Corresponding author，E-mail:847705460@qq.com

ABSTRACT

As a new generation of new energy battery, lithium-ion battery is widely used in various fields, including electronic products, electric vehicles, power supply and so on, due to its advantages of high energy density, light weight, long cycle life, small self-discharge, no memory effect and no pollution. With the wide application of lithium ion battery, more and more research on the performance of lithium ion battery has been done. The lithium ion battery state of health assessment become a hot spot, a new piece of lithium ion battery longest running under full charge state, and after repeated charge and discharge, the irreversible chemical changes have taken place in its internal, leading to a fall in the maximum available capacity of lithium ion batteries, when lithium ion battery capacity declined to 70-80% of the rated capacity lithium ion battery failure. In some large industrial equipment, once the battery failure may lead to electrical equipment damage, resulting in safety accidents. Therefore, it is of great significance to predict the remaining usable life of lithium ion battery for improving system reliability. As for the inaccurate prediction of lithium-ion battery life at present. In this paper, a combination prediction model for lithium ion batteries with multimode decomposition is presented, To learn about small changes in the degradation process of lithium-ion batteries This method is based on the LSTM prediction model. complete ensemble empirical mode decomposition with adaptive noise(CEEMDAN) algorithm is used to divide capacity into mainly degradation trend and some local degradation trend. Then introduce Long Short-Term Memory Neural Network (LSTMNN) algorithm to carry out respectively the capacity prediction of decomposed degradation data. Finally, some prediction results are integrated effectively. The maximum MAPE of the proposed CEEMDAN-LSTM lithium-ion battery combination prediction model does not exceed 1.5%. The average relative error is less than 3%, which is better than the other prediction model.

KEY WORDS : Battery health management; Lithium-ion batteries; Remaining useful life; Long and short

录用稿件，非最终出版稿

term memory neural network; CEEMDAN

1 引言

锂离子电池在长期的使用过程中，伴随着充放电循环次数的增多，电池内部发生了一些不可逆的化学反应，导致内阻增大，性能衰退[1-4]。可靠的寿命预测技术不仅可以更加有效使用电池，更能降低故障发生率[5]。锂离子电池的剩余使用寿命（Remaining Useful Life，RUL）即在一定的工作条件下，电池从全新开始到寿命终止 EOL（End of Life）所经历的充放电循环周期数，一般容量衰减 20%达到 EOL。

目前对于锂离子电池寿命预测的方法主要分为模型法和数据驱动法，基于模型法的锂离子电池预测技术已经较为成熟[6]。目前数据驱动的预测方法依旧是主流，基于数据驱动方法能够在不建立复杂电池模型的基础上探索电池外部参数和内部状态之间的关系[7]。Yun 等人[8]利用了充放电时间来评价锂离子电池的健康状态，并利用贝叶斯方法对锂电池健康状态评估。如 Park K 等人[9]考虑了使用电压、电流、温度、充电曲线等多个测量数据，并结合 LSTM 算法构建了锂离子电池寿命预测模型。Xiong 等人[10]利用 LSTM-RNN 预测模型构造锂离子电池容量退化长期相关性，在线预测时比一般模型所需的在线数据少 20%-25%。Wei 等人[11]建立了基于线性优化重采样粒子滤波（LORPF）的锂离子电池 RUL 预测方法，其预测误差小于 5%。但是因为部分电池有严重的容量重生现象，因此很难准确追踪电池容量退化趋势。

针对锂电池寿命衰退过程存在的容量重生问题，Yu 等人[12]提出一种多尺度逻辑回归（LR）和高斯过程回归（GPR）结合的锂离子电池寿命预测方法，采用了经验模态分解（EMD）方法将电池容量序列分解为全局退化、局部再生，从而减少了局部再生现象对寿命预测的影响。Zhou 等人[13]提出一种基于时间卷积网络（TCN）预测模型并采用了经验模态分解（EMD）技术对离线数据进行去噪处理，避免了局部再生造成的 RUL 预测误差。其预测模型具有起点影响小、预测精度高、鲁棒性强的特点。Li 等人[14]将经验模态分解与 LSTM 和 Elman 神经网络结合起来，使用 EMD 算法将数据分为若干层，分别建立了低频预测模型和高频预测模型。

传统的 EMD 算法在模态分解过程中常常伴随着模态混叠并且分解不够完全，不能根据循环前期的容量退化趋势进行可靠的寿命预测。而改进的自适应噪声完全集成的经验模态分解（CEEMDAN）算法，具有分解更为充分、重构误差更小、而且运算时间短等一系列优点，在提取复杂序列的波动模式进而提升预测模型的精度方面具有突出的优势。且近年来 LSTM 预测模型以其优异的性能在故障诊断和预测领域都得到了很广泛的应用，文献[15-18]都使用 LSTM 或其改进算法对齿轮、发电机、卫星锂离子电池等进行了寿命预测，均得到了优异的预测结果。

综上所述，为综合两者算法的优势，本文提出了一种 CEEMDAN 和 LSTM 的组合锂离子电池寿命预测方法。克服了锂离子电池在寿命预测过程中存在的剧烈波动，可以准确捕捉到锂离子电池容量变化过程的微小变化，并使用了公开数据验证了组合预测模型的预测性能。

2 基本理论

2.1 CEEMDAN 理论

CEEMDAN 理论是在经验模态分解(EMD)算法的基础上发展的，EMD 相当于是一种自适应正交基的时频信号处理方对未知的非线性信号的处理方法，不需要预先的分析与研究，就可以直接开始分解，且会自动按照一些固定模式按层次分好，不需要人为干预与设置，但是实上采用 EMD 的分解方法对信号处理会出现频率混叠的现象，也叫模态混叠。

为解决此问题，EEMD（总体经验模态分解）算法针对 EMD 方法的不足提出噪声辅助数据分析方法，在每次信号分解过程都对原始信号加入了零均值、固定方差的白噪声，解决了模态混叠，但是处理过程中加入的高斯白噪声很难消除。为此在 EEMD 的基础上，通过在分解过程加入自适应白噪声进一步改进 EEMD，提出了 CEEMDAN 算法，有效克服了 EEMD 分解不完备和重构误差大的问题[19-

录用稿件，非最终出版稿

[20]。CEEMDAN 算法实现的具体步骤如下：

步骤 1 对锂离子电池容量序列 $C(t)$添加白噪声容量序列，如公式（1）所示：

$$C_i(t) = C(t) + \beta_i n_i(t) \tag{1}$$

式中：$C_i(t)$表示第 i 次添加了白噪声的容量序列，$n_i(t)$表示了第 i 次添加的服从标准正态分布的高斯白噪声，β_k表示第 k 个信噪比。

步骤 2 使用 EMD 算法对 $C_i(t)$信号进行 N 次重复分解，通过均值计算得到第一个模态分量 imf_1(t), 并且通过公式（2）求出第一个余量信号 $R_1(t)$。

$$R_1(t) = C(t) - imf_1(t) \tag{2}$$

步骤 3 求出第二个模态函数和余量，对信号 $R_1(t) + \beta_1 E_1(n_i(t))$ 进行 N 次重复分解并求均值。$E_k()$为经过 EMD 分解产生的第 k 个分量。由公式（3）（4）得到第二个模态分量 imf_2 以及第二个余量信号 $R_2(t)$。

$$imf_2 = \frac{1}{N}\sum_{i=1}^{N} E_1(R_1(t) + \beta_1 E_1(n_i(t))) \tag{3}$$

$$R_2(t) = R_1(t) - imf_2(t) \tag{4}$$

步骤 4 对于后面每个阶段，k=3,4……K 求解方法都类同于步骤 3，得到的第 k+1 个模态分量 imf_{k+1} 和第 k+1 个余量 R_{k+1} 信号。

步骤 5 重复步骤 4，直到所得到余量信号不能再继续分解，即余量序列极值点数小于或等于两个，满足分解的终止条件。最终信号被分解为：

$$C(t) = R(t) + \sum_{i=1}^{k} imf_k(t) \tag{5}$$

2.2 LSTM 预测模型

LSTM 是一种循环神经网络，是 Hochreiter 为解决传统 RNN 梯度消失或梯度爆炸的问题而提出的一种特殊结构[21-25]。通常用于解决长时间序列的长期依赖性，图 1 所示为 LSTM 的总体结构图。

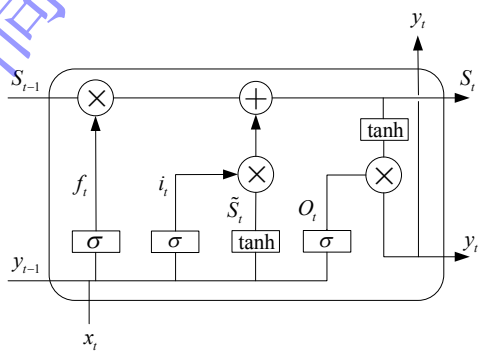

图 1 LSTM 总体结构图

Fig.1 LSTM structure diagram

LSTM 结构的关键点在于三个门（gate）控制，分别为遗忘、输入门、输出门。遗忘门决定了上一时刻的单元状态 S_{t-1} 有多少保留到当前时刻单元状态 S_t，其计算如(6)所示。

$$f_t = \sigma(W_f \cdot [y_{t-1}, x_t] + b_f) \tag{6}$$

录用稿件，非最终出版稿

其中 W_f为遗忘门的权重矩阵，x_t表示 t 时刻输入层向量，y_{t-1}表示 t-1 时刻输出层向量，b_f表示遗忘门偏置矩阵，f_t表示遗忘门输出矩阵，σ()表示 sigmoid 激活函数。经过激活函数之后单元状态 S_t输出一个 0 到 1 之间的实数向量，1 表示完全保留，0 表示完全舍弃该状态值。

输入门决定了当前网络时刻的输入 x_t有多少保存到单元状态 S_t，计算公式如下：

$$i_t = \sigma(W_i \cdot [y_{t-1}, x_t] + b_i) \tag{7}$$

$$\tilde{S}_t = \tanh(W_S \cdot [y_{t-1}, x_t] + b_S) \tag{8}$$

$$S_t = f_t \times S_{t-1} + i_t \times \tilde{S}_t \tag{9}$$

式中:W_i和 b_i分别为输入门权值矩阵和偏置。并使用 tanh 函数构建一个新的单元状态 $\tilde{S}_t$，输出门决定了最终将要输出的信息，计算公式如下：

$$O_t = \sigma(W_O \cdot [y_{t-1}, x_t] + b_O) \tag{10}$$

$$y_t = O_t \tanh(S_t) \tag{11}$$

式中:W_O和 b_O分别为输出门权值矩阵和偏置。

3 CEEMDAN-LSTM 组合预测方法框架

本文所提出的 CEEMDAN-LSTM 组合预测模型结构如图 2 所示。大致预测步骤可理解为合成-分解-再合成，大致分为 4 步。

步骤 1 将锂电池容量退化数据 $C_i(t)$作为锂离子电池预测参数。

步骤 2 利用 CEEMDAN 算法对 $C_i(t)$信号进行分解，根据式（1）~（5）将 C(t)分解为 n 组 imf（t）和 1 组 $R(t)$信号。

步骤 3 将分解后的 $imf(t)$和 1 组 $R(t)$信号分为一定比例的训练集和测试集，并分别代入训练好的 LSTM 模型中。

步骤 4 对 LSTM 模型的预测结果进行有效集成，得到最终的锂离子电池寿命预测结果。

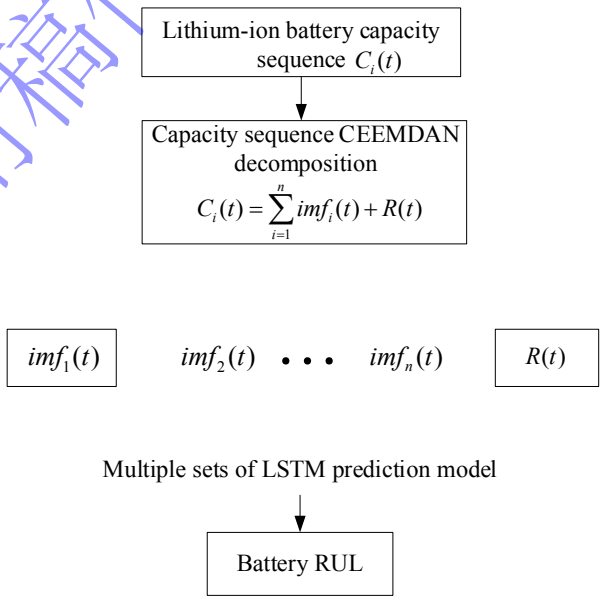

图 2 组合模型预测框图

录用稿件，非最终出版稿

Fig.2 Block diagram of combination prediction model

4 实验及结果分析

4.1 锂离子电池充放电实验

为了研究锂离子电池的容量衰减，美国马里兰大学先进生命周期工程研究中心（Center for Advanced Life Cycle Engineering, CALCE）对锂离子电池进行了充放电实验并获得了大量实验数据[26]，每个数据集记录了有关充电、放电、测量电阻的信息。本文研究了其中 CX2 和 CS2 两种不同型号的钴酸锂($LiCoO_2$)电池，包括了 CS33、CS34、CS37、CS38 和 CX36、CS37 共 6 个电池，详细规格参数如表 1 所示。

表 1 $LiCoO_2$ 电池详细参数

Tab.1 LiCoO2 battery details

battery	Anode and cathode materials	size /mm	weight /g
CS2	$LiCoO_2$ cathode/graphite anode	5.4*33.6*50.6	21.1
CX2	$LiCoO_2$ cathode/graphite anode	6.6*33.8*50	28

实验中所有电池充电为先恒流后恒压充电模式，放电为恒流放电。具体过程为：充电时以 0.5C 的倍率恒流充电，当电池电压达到 4.2V 再进行恒压充电，达到截止电流（50mA）停止充电。放电时采用恒流放电，放电截止电压为 2.7V。其中 CS33 和 CS34 以 0.5C 的倍率放电，CS37、CS38 和 CX36、CX37 以 1C 的倍率放电。重复上述充放电实验直到锂离子电池达到寿命阈值，即总容量的 80%（CX 从 1.35Ah 降至 1.08Ah，CS 从 1.1Ah 降至 0.88Ah）停止。所有实验均在室温（24℃）下进行。如图 3 所示为六块锂离子电池放电过程中容量随循环次数的衰减曲线。

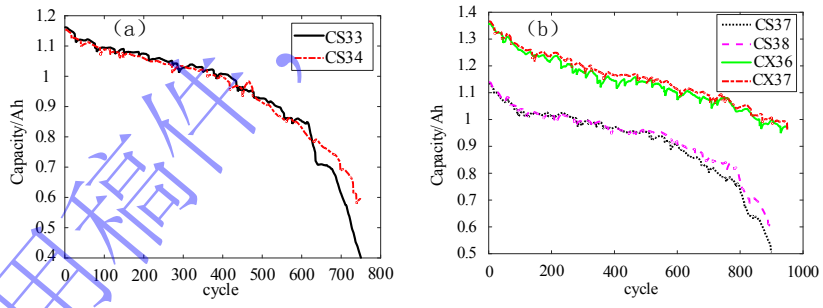

图 3 锂离子电池容量衰减数据.（a）CS33、CS34；（b）CS37、CS38、CX36、CX37

Fig.3 Capacity degradation data of lithium-ion batteries（a）CS33、CS34；（b）CS37、CS38、CX36、CX37

4.2 CEEMDAN 锂离子电池容量序列分解结果分析

本文以 CS33 电池剩余容量衰减数据为例，将容量信号分解为频率从高到底排列的若干个本征模态函数(imfs)和一个残差信号(R),极大地消除了锂离子电池容量衰减过程的噪声信号。分解结果如图 4 所示（其中 imf 的单位都为 Ah），可以看到，分解之后的余量信号光滑且没有容量重生现象，可以很大程度提高锂离子电池的寿命预测精度。

录用稿件，非最终出版稿

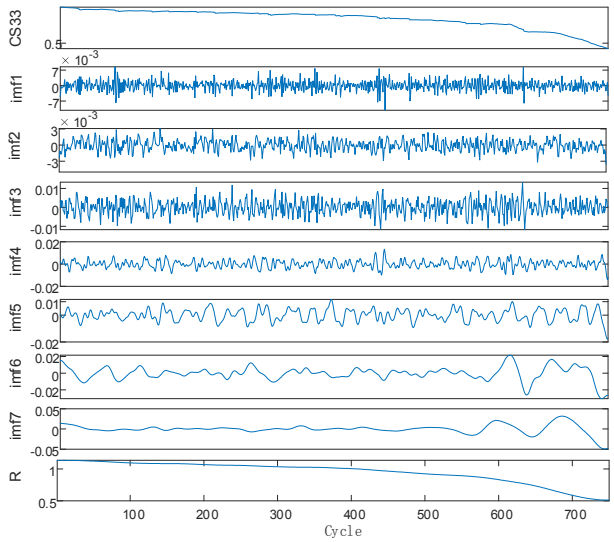

图 4 基于 CEEMDAN 的 CS33 容量序列分解

Fig.4 CS33 capacity sequence decomposition based on CEEMDAN

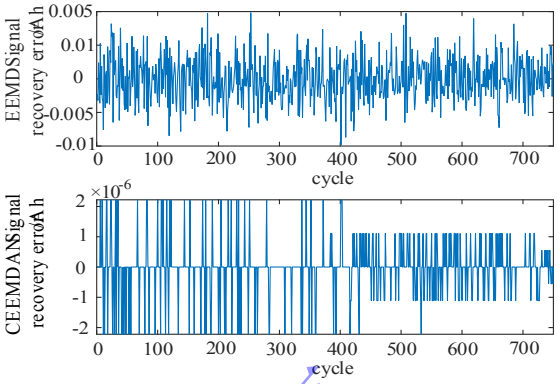

图 5 CS33 两种算法重构误差对比

Fig.5 Comparison of reconstruction errors between two algorithms

如图 5 所示为 EEMD 算法和 CEEMDAN 算法的分解重构误差比较图，明显可以看出 CEEMDAN 算法的重构误差小于 EEMD 算法。

4.3 模型评价

为全面分析所选方法的有效性，本文选择以下三个指标来评估模型的性能，有均方根误差(RMSE)，平均绝对百分比误差(MAPE)，平均绝对误差(MAE)，计算公式如下。

$$RMSE=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(C_i-\tilde{C}_i)^2} \tag{12}$$

$$MAPE=\frac{1}{n}\sum_{i=1}^{n}\frac{|C_i-\tilde{C}_i|}{C_i} \tag{13}$$

$$MAE=\frac{1}{n}\sum_{i=1}^{n}|C_i-\tilde{C}_i| \tag{14}$$

式中：C_i和$\tilde{C}_i$分别代表实际容量值和预测容量值，n代表样本数。

4.4 锂电池寿命预测结果分析

本次实验为了体现 CEEMDAN-LSTM 组合模型的性能，分别选取了 EMD-LSTM 模型和 LSTM 进行对比说明。本次研究采用的 LSTM 参数设置如表 2 所示，为了避免 LSTM 模型在训练过程中发生过拟合现象，在训练时当迭代次数达到 250 次时学习率降低为初始值的十分之一。

表 2 LSTM 预测模型参数设置

Tab.2 LSTM prediction model parameter setting

number of iterations	Number of hidden layers	Number of hidden cell	Initial learning rate
500	1	200	0.002

训练时，分别使用了数据集的 50%和 30%的全寿命循环数据来训练模型，然后将剩余的 50%和 70%全寿命循环数据来测试模型，得到最终的预测结果如下图 6 所示。M1 表示 LSTM 预测模型，M2

录用稿件，非最终出版稿

表示 EMD-LSTM 预测模型，M3 表示 CEEMDAN-LSTM 预测模型。

(1)首先使用 50%数据集对三种模型进行训练

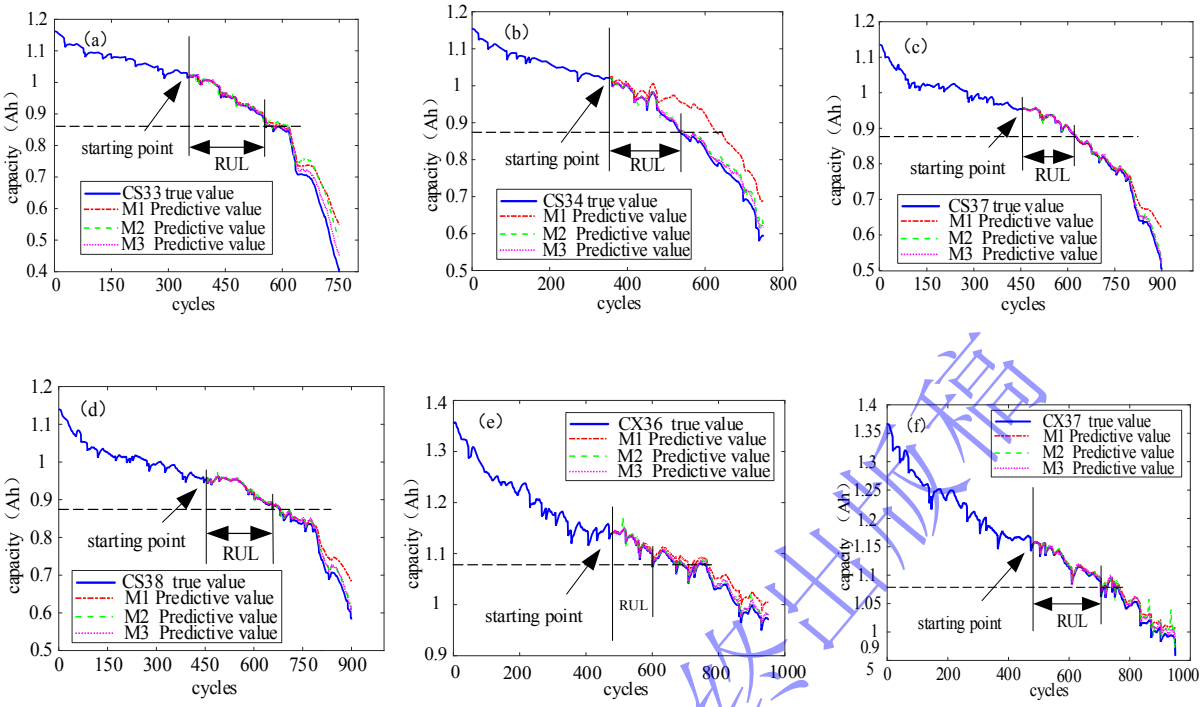

图 6 50%训练集电池预测结果.（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

Fig.6 50% training set battery prediction results（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

如上图 6 所示为 50%训练集时的 6 块锂离子电池容量预测结果。图 6（b）使用 LSTM 模型对 CS34 容量预测时预测波动比较大，而使用 CEEMDAN-LSTM 组合预测模型可以很好地跟随容量退化曲线，预测误差较小。且对于 6 块不同型号、工作在不同放电倍率下的锂离子电池，使用文中所提出的 CEEMEDAN-LSTM 组合预测模型的寿命预测方法均有较高的预测精度。

如图 7 给出了六块锂离子电池的估算误差曲线，可以从中更好比较三种预测算法的性能。

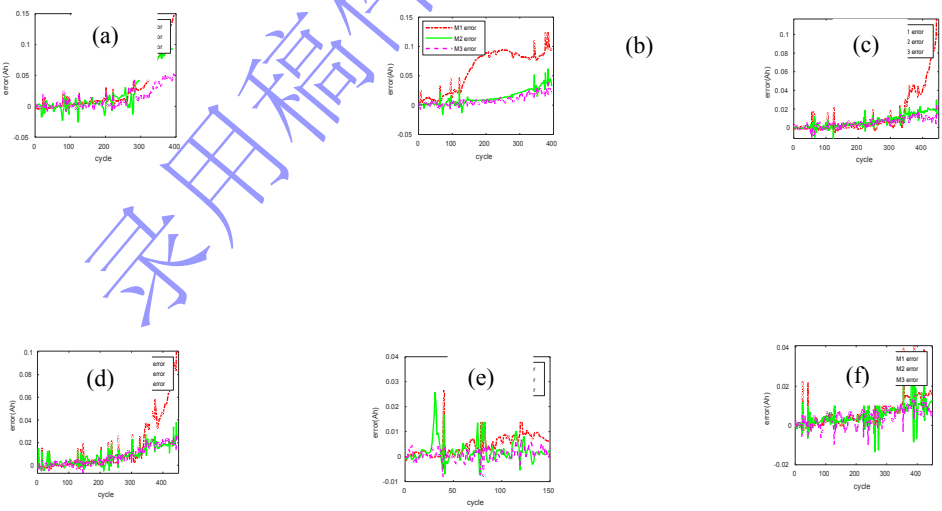

图 7 相对误差曲线（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

录用稿件，非最终出版稿

Fig.7 Relative error curve （a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

如下图 8 绘制出了不同算法下六块锂离子电池预测结果的评价指标。其中 RMSE 和 MAPE 越小，代表预测模型的预测精度越高。

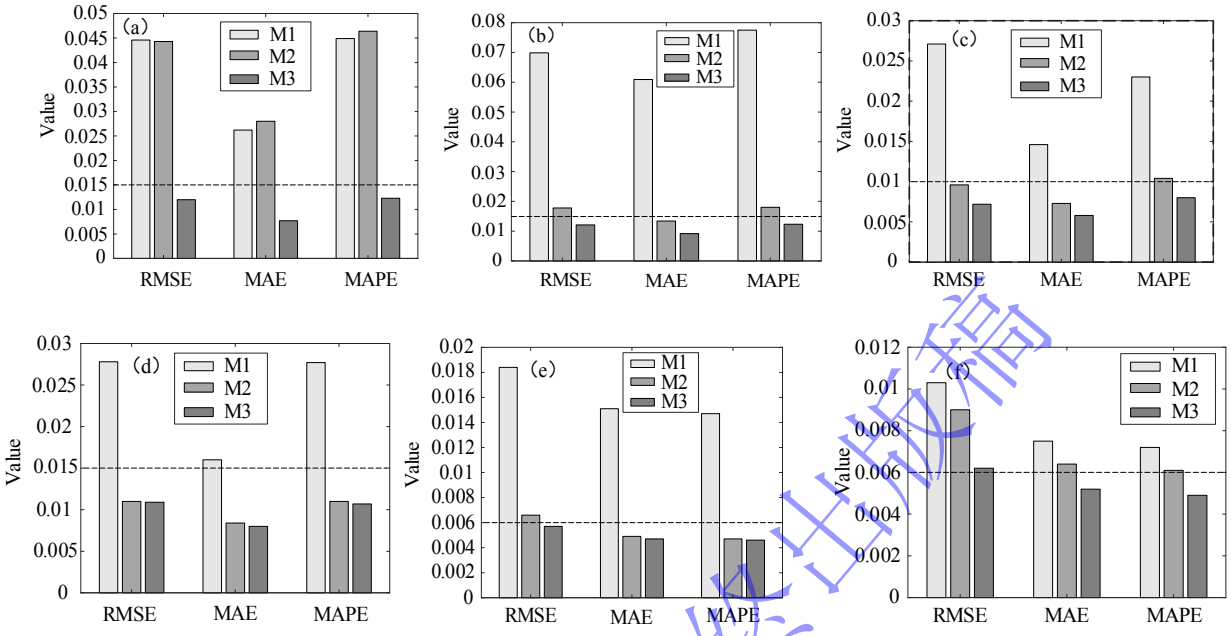

图 8 50%训练集电池预测误差.（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

Fig.8 50% training set battery prediction error（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

图 8 中显示了组合预测模型 CEEMDAN- LSTM 预测的各项性能指标均优于其他两种方法，准确率高，最大 RMSE 不超过 2%，最大 MAPE 控制在 1.5%之内。其中 CX36 和 CX37 两块锂离子电池的最大 MAPE 在 0.6%之内，具有很高的预测精度。

根据容量衰减到初始容量的 80%为限作为寿命阈值，从而预测锂离子电池达到寿命终止时的可用循环次数。并使用 RUL_{er} 和 P_{er} 来衡量寿命预测精度。公式如下所示。

$$RUL_{er} = | RUL_{pr} - RUL_{tr} | \tag{15}$$

$$P_{er} = \frac{| RUL_{pr} - RUL_{tr} |}{RUL_{tr}} \tag{16}$$

式中：RUL_{er} 为锂离子电池 *RUL* 预测误差；RUL_{pr} 为锂离子电池 *RUL* 预测值；RUL_{tr} 为锂离子电池 *RUL* 真实值。P_{er} 为锂离子电池预测的相对误差。

对锂离子电池寿命预测误差进行总结，寿命预测误差及相对误差 p_{er} 如表 3 所示。

表 3 50%训练集锂电池寿命预测误差

Tab.3 50% training set lithium battery life prediction error

Model	battery	RUL_{tr}	RUL_{pr}	RUL_{er}	P_{er}
LSTM	CS33	198	201	3	0.0152
	CS34	176	269	93	0.5284
	CS37	167	169	2	0.0120
	CS38	201	223	22	0.1095
	CX36	191	192	1	0.0076
	CX37	224	227	3	0.0134
EMD-LSTM	CS33	198	198	0	0

录用稿件，非最终出版稿

	CS34	176	183	7	0.0398
	CS37	167	169	2	0.0114
	CS38	201	222	21	0.1045
	CX36	191	192	1	0.0062
	CX37	224	225	1	0.0045
CEEMDAN-LSTM	CS33	198	197	1	0.0051
	CS34	176	176	0	0
	CS37	167	171	4	0.0239
	CS38	201	223	22	0.1095
	CX36	191	192	1	0.0062
	CX37	224	224	0	0

根据表 3 进行分析，可以得到文中新预测模型 CEEMDAN-LSTM 对于 6 块电池的预测平均相对误差最小，不会出现较大的波动，如 CS34 使用 LSTM 模型进行预测时，相对误差高达 52.8%，而 CS38 使用 EMD-LSTM 模型预测剩余寿命时，其相对误差也达到 10.45%。比较而言，使用 CEEMDAN-LSTM 组合模型时只有 CS38 预测结果较差，相对误差为 10.95%，但是综合六块电池预测结果，CEEMDAN-LSTM 组合模型的平均相对误差也只有 2.41%。体现了组合模型较好的适应性。

(2)为了根据寿命前期的容量衰退趋势来预测锂离子电池的剩余使用寿命，使用 30%数据集对预测模型进行训练，三种模型预测结果如下图 9 所示。

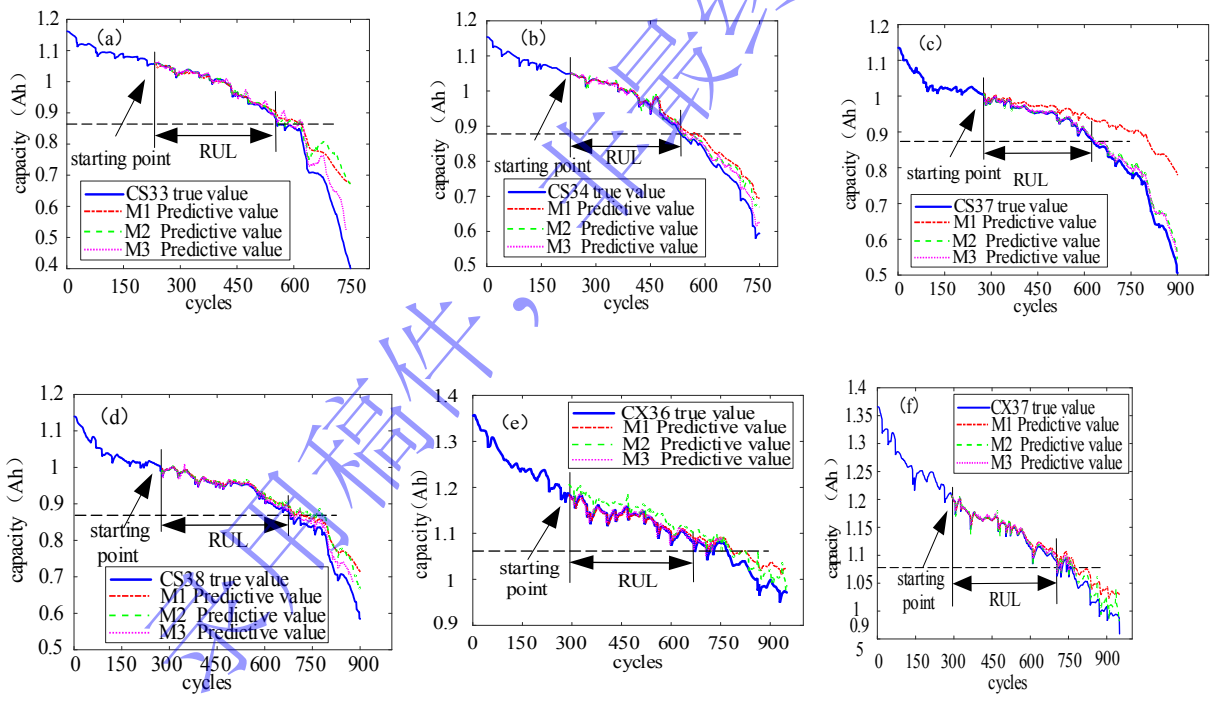

图 9 30%训练集锂离子电池预测结果.（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

Fig.9 30% training set battery prediction error（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

如图 9 表示了使用 30%的训练数据对模型训练得到了 6 块电池容量预测结果，因为模型训练不够充分，预测效果有一定误差。如图 9（a）所示，从 275 的预测起点开始直到第 600 次循环左右，EMD-LSTM 模型的预测结果一直比较稳定，和初始容量保持一定的相关性，但 600 次循环之后，EMD-LSTM 模型预测结果产生了很大的误差。而 CEEMDAN-LSTM 组合预测模型在训练数据较少的情况下依旧可以很好拟合锂离子电池退化趋势，稳定性均优于其他两种算法。

如图 10 总结了 30%训练集的所有锂离子电池的预测性能指标。

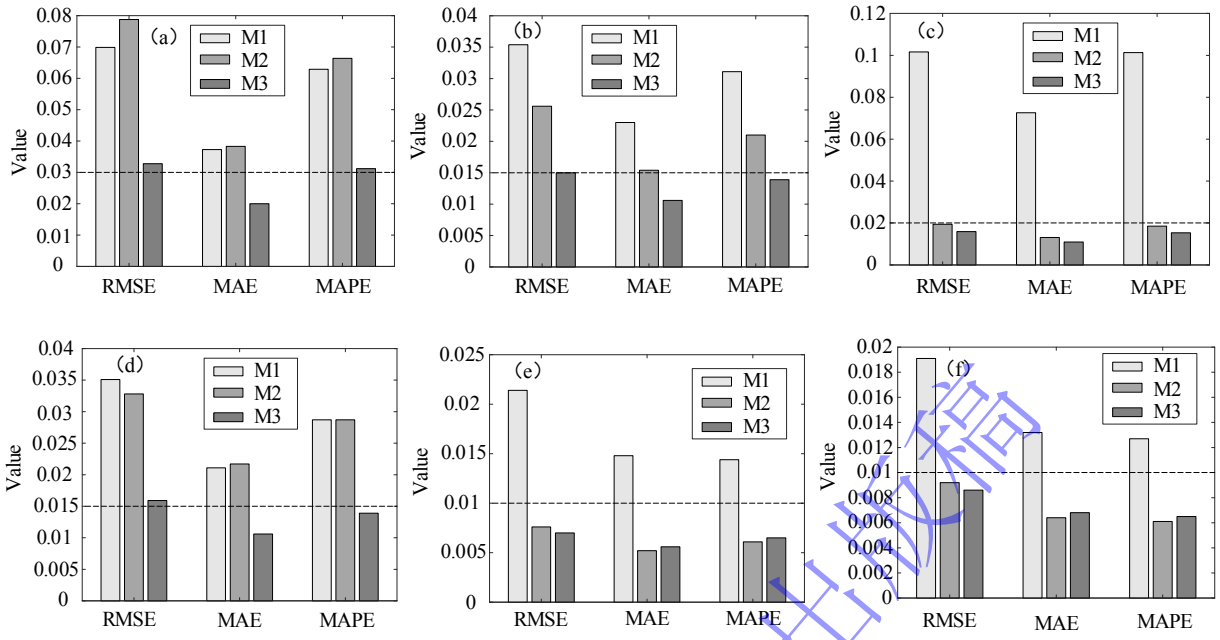

图 10 30%训练集电池预测误差.（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

Fig.10 30% training set battery prediction error（a）CS33;（b）CS34;（c）CS37;（d）CS38；（e）CX36；（f）CX37

由图 10 可以看出只有 CS33 的预测 MAPE 值超过 3%，其余均在 1.5%之内，预测效果均优于其他两种算法。与前文相似，计算出 30%训练集时各型号锂电池的寿命预测结果如表 4 所示。

由表 4 所示，训练数据仅为 30%时，LSTM 模型预测误差较大，不能很好地拟合锂离子电池容量退化趋势。CEEMDAN-LSTM 组合寿命预测模型中最大相对误差为 6.5%，六块平均相对误差为 2.04%。且只有 CS38 这一块电池的 RUL_{er} 超过了 20，其主要原因还是 CS38 的剩余容量在寿命阈值附近波动较大，造成预测的不准确，但相对于其他两种模型精度都有一定的提升。

为进一步说明本组合方法在锂离子电池预测精度，将该方法与其他机器学习的方法进行了比较说明。实验使用 CS33 电池数据集，训练数据都为总数据集的 30%，利用 BP 神经网络、支持向量机 SVR、极限学习机 ELM 的方法分别对锂离子电池进行预测，如表 5 所示。

表 4 30%训练集锂电池寿命预测误差

Tab.4 30% training set lithium battery life prediction error

Model	battery	RUL_{tr}	RUL_{pr}	RUL_{er}	P_{er}
LSTM	CS33	323	346	23	0.0712
	CS34	301	325	24	0.0797
	CS37	347	527	180	0.5187
	CS38	381	408	27	0.0709
	CX36	381	385	4	0.0105
	CX37	414	419	5	0.0121
EMD-LSTM	CS33	323	324	1	0.0031
	CS34	301	304	3	0.0100
	CS37	347	354	7	0.2018
	CS38	381	408	27	0.0708
	CX36	381	430	49	0.1286
	CX37	414	414	0	0

录用稿件，非最终出版稿

CEEMDAN-LSTM	CS33	323	323	0	0
	CS34	301	309	8	0.0266
	CS37	347	353	6	0.0173
	CS38	381	406	25	0.0656
	CX36	381	376	5	0.0131
	CX37	414	414	0	0

表 5 不同算法预测精度

Tab.5 The prediction accuracy of different algorithms

Battery	Training data	algorithm	*RMSE*/Ah	*MAPE*/Ah	*MAE*/Ah
CS33	50%	BPNN	0.1471	0.1649	0.1043
		ELM	0.0650	0.0626	0.0367
		SVR	0.0297	0.0304	0.0244
		CEEMDAN-LSTM	0.0120	0.0123	0.0077
CS33	30%	BPNN	0.1727	0.1794	0.1172
		ELM	0.1216	0.1244	0.0805
		SVR	0.0708	0.0726	0.0692
		CEEMDAN-LSTM	0.0327	0.0312	0.0200

如表 5 所示，以同一样本数据，CEEMDAN-LSTM 组合算法和几种常用的机器学习算法进行了比较，在训练数据量偏少时，BPNN、SVR、ELM 的预测精度均有所下降，而 CEEMDAN-LSTM 组合预测算法却仍然有很高的预测精度，体现了组合预测算法对数据的充分训练提高了预测精度，并减小了对数据的强依赖性，唯一不足是训练时间较长。

5 结论

本文提出了一种新的组合 CEEMDAN-LSTM 寿命预测模型对锂离子电池的剩余寿命进行有效的学习和预测。主要结论有：

（1）文中提出的 CEEMDAN-LSTM 组合模型对于不同型号和不同放电倍率的锂离子电池寿命预测均有较高的精度，而且在训练数据减少的情况下对预测结果的影响也不大。预测模型具有一定的泛化性和鲁棒性。

（2）通过与 EMD-LSTM 和 LSTM 及其他机器学习算法的对比，所提出组合模型预测精度相对 EMD-LSTM、LSTM 模型均有一定的提升，预测结果中最大 MAPE 不超过 1.5%，平均相对误差在 3%以内。

（3) 因为引入 CEEMDAN 分解算法，影响了 LSTM 模型的训练时间，所以组合预测模型的训练时间与 LSTM 模型相比较长。后续的工作将在此基础上改进，在提高预测精度的基础上，也可以节省模型训练时间。

录用稿件，非最终出版稿

参考文献

[1] Wang Y Z，Ni Y L，Zheng Y Q, et al. Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Support Vector Regression Optimized and Ant Lion Optimizations[J/OL]. *Proceedings of the CSEE*[2020-06-16]. http://kns.cnki.net/kcms/detail/11.2107.TM.20200427.1423.009.html.
（王瀛洲,倪裕隆,郑宇清,史学伟,王建国.基于 ALO-SVR 的锂离子电池剩余使用寿命预测[J/OL].中国电机工程学报:1-12[2020-06-16]. http://kns.cnki.net/kcms/detail/11.2107.TM.20200427.1423.009.html.）

[2] LIU D T, ZHOU J B, LIAO H T, et al. A health indicator extraction and optimization framework for lithium-ion battery degradation modeling and prognostics. *IEEE Transactions on Systems*, 2015, 45(6): 915-928.

[3] Pan H P, Lv Z Q, Fu B, et al. Online Estimation of Lithium-ion Battery's State of Health Using Extreme Learning Machine. *Automotive Engineering*, 2017,39(12):1375-1381+1396.
(潘海鸿,吕治强,付兵,等.采用极限学习机实现锂离子电池健康状态在线估算.汽车工程,2017,39(12):1375-1381+1396.)
[4] Xiong R. *Battery Management Algorithm for Electric Vehicles*. Battery Management Algorithm for Electric Vehicles, 2020.
[5] Zhu J, Tan T, Wu L, et al. RUL prediction of lithium-ion battery based on improved DGWO-ELM method in a random discharge rates environment. *IEEE Access*, 2019, 7: 125176–125187.
[6] Chen L, Chen J, Wang H M.et al. Prediction of Battery Remaining Useful Life Based on Wavelet Packet Energy Entropy. *Trans China Electrotech Soc*, 2020,35(08):1827-1835.
(陈琳,陈静,王惠民,等. 基于小波包能量熵的电池剩余寿命预测.电工技术学报,2020,35(08):1827-1835.)
[7] Zhang Y, Xiong R, He H, et al. Lithium-Ion Battery Remaining Useful Life Prediction with Box-Cox Transformation and Monte Carlo Simulation. *IEEE Transactions on Industrial Electronics*,2019,66(2): 1585–1597.
[8] Yun Z H, Qin W H. Remaining Useful Life Estimation of Lithium-Ion Batteries Based on Optimal Time Series Health Indicator. *IEEE Access*, 2020 , 8:55447-55461.
[9] Park K, Choi Y, Choi W J, et al. LSTM-Based Battery Remaining Useful Life Prediction with Multi-Channel Charging Profiles. *IEEE Access*, 2020, 8: 20786–20798.
[10] Zhang Y, Xiong R, He H, et al. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries. *IEEE Transactions on Vehicular Technology*,2018,67(7):5695–5705.
[11] Wei H Y， An J J， Chen J, et al, R UL Prediction of Lithium- ion Battery Based on Improved Particle Filtering Algorithm. *Automotive Engineering*, 2019,41(12):1377-1383.
（韦海燕,安晶晶,陈静,等.基于改进粒子滤波算法实现锂离子电池 RUL 预测.汽车工程,2019,41(12):1377-1383）
[12] Yu J. State of health prediction of lithium-ion batteries: Multiscale logic regression and Gaussian process regression ensemble. *Reliability Engineering and System Safety*, Elsevier Ltd,2018,174(2): 82–95.
[13] Zhou Y P, Huang M H. Lithium-ion batteries remaining useful life prediction on a mixture of empirical mode decomposition and ARIMA modeal. *Microelectronics Reliabilty*,2016,65:265-273.
[14] Li X, Zhang L, Wang Z, 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. *Journal of Energy Storage*, Elsevier, 2019, 21(11): 510–518.
[15] Sayah M, Guebli D, Al Masry Z, Zerhouni N. Robustness testing framework for RUL prediction Deep LSTM networks. *ISA Trans*. 2020; S0019-0578(20)30276-7.
[16] Wang, C.; Lu, N.; Wang, S.; Cheng, Y.; Jiang, B. Dynamic Long Short-Term Memory Neural-Network- Based Indirect Remaining-Useful-Life Prognosis for Satellite Lithium-Ion Battery. *Applied. Sciences.* 2018, *8*, 2078.
[17] Bruneo D, De Vita F. On the Use of LSTM Networks for Predictive Maintenance in Smart Industries. *ieee international conference on smart computing*, 2019: 241-248.
[18] Haoran Yan, Yi Qin, Sheng Xiang, Yi Wang, Haizhou Chen,Long-term gear life prediction based on ordered neurons LSTM neural networks,*Measurement*,Volume 165,2020,108205.
[19] Hu T Z, Yu J B. Life prediction of lithium-ion batteries based on multiscale decomposition and deep learning. *Journal of Zhejiang University (Engineering Science)*, 2019,53(10):1852-1864.
(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.浙江大学学报(工学版),2019,53(10):1852-1864.)
[20] Zhang C L, He Y G, Yuan L F. Prediction Approach for Remaining Useful Life of Lithium-ion Battery Based on EEMD and MKRVM. *Proceedings of the CSU-EPSA*, 2018,30(07):38-44.
(张朝龙,何怡刚,袁莉芬.基于EEMD和MKRVM的锂电池剩余寿命预测方法.电力系统及其自动化学报,2018,30(07):38-44.)
[21] Qi H M. Research on Prediction method of remaining life of lithium battery based on deep learning. Harbin: Harbin Institute of Technology,2019.
(齐昊明. 基于深度学习的锂电池剩余寿命预测方法研究[D].哈尔滨工业大学,2019.)
[22] Li J L, Li X Y, et al. A Directed Acyclic Graph Network Combined With CNN and LSTM for Remaining Useful Life Prediction. *IEEE Access*, 2019,7:75461-75474.
[23] Zhou Y T, Huang Y N, Pang J B, et al. Remaining useful life prediction for supercapacitor based on long short-term memory neural network. *Journal of Power Sourc*e, Elsevier,2019,440(3):227149.
[24] Yu Y, Hu C H, Si X S, et al. Averaged Bi-LSTM networks for RUL prognostics with non-life-cycle labeled dataset. *Neurocomputing*, Elsevier,2020,402,134-137.
[25] Yang F F, Zhang S H, Li W H, et al. State of charge estimation of lithium-ion batteries using LSTM and UKF. *Energy*, Elsevier, 2020,15(6):117664.
[26] Liu J，Chen Z Q, Huang D Y, et al. Remaining useful life of Lithium-ion batteries based on time interval of equal charging voltage difference, *Journal of Shanghai jiao tong University*, 2019,53(09):1058-1065.
（刘健,陈自强,黄德扬,等.基于等压差充电时间的锂离子电池寿命预测.上海交通大学学报,2019,53(09):1058-1065.）

录用稿件，非最终出版稿

录用稿件，非最终出版稿