

DOI:10.19651/j.cnki.emt.2210207

基于 VMD 和优化的 LSTM 锂离子电池寿命预测方法 *

叶 鑫¹ 王海瑞¹ 李远博¹ 朱贵富²

(1. 昆明理工大学信息工程与自动化学院 昆明 650500; 2. 昆明理工大学信息化建设管理中心 昆明 650500)

摘要: 针对锂电池使用过程中存在容量回升造成非平稳的容量退化趋势,造成模型的预测精度容易受到干扰的问题,提出一种基于变分模态分解(VMD)与贝叶斯优化(BO)的长短期记忆神经网络(LSTM)的锂电池剩余寿命预测方法。首先,通过变分模态分解将原始容量退化序列进行分解,得到有限个模态分量;然后对分解之后的分量进行降噪、重构;最后,使用贝叶斯优化的长短期记忆神经网络算法对处理之后的数据进行寿命预测,获得最终的锂电池剩余寿命(RUL)预测结果。通过 CALCE 中心的锂离子电池数据集进行实验,所提出的 VMD-BO-LSTM 锂电池组合预测模型具有较高的预测精度与稳定性,实验采用的电池均方根误差的平均值小于 7%,且优于其他预测模型。

关键词: 锂离子电池;剩余使用寿命;变分模态分解;贝叶斯优化;长短期记忆神经网络

中图分类号: TM912 文献标识码: A 国家标准学科分类代码: 520

Remaining useful life prediction method of lithium-ion battery based on variational mode decomposition and optimized LSTM

Ye Xin¹ Wang Hairui¹ Li Yuanbo¹ Zhu Guifu²

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China;
2. Information Technology Construction Management Center, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Aiming at the non-stationary capacity degradation trend caused by the capacity recovery during the use of lithium batteries, which makes the prediction accuracy of the model vulnerable to interference, a long short-term memory network (LSTM) prediction method of lithium battery remaining useful life based on variational mode decomposition (VMD) and bayesian optimization (Bo) is proposed. Firstly, the capacity data of lithium battery is decomposed by variational modal decomposition, and a finite number of modal components are obtained; Then the decomposed components are denoised and reconstructed; Finally, the Bayesian optimized long and short-term memory neural network algorithm is used to predict the service life of the processed data, and the final prediction result of remaining useful life (RUL) of lithium battery is obtained. Through the experiment on the lithium-ion battery data set of CALCE center, the proposed VMD-BO-LSTM lithium battery combination prediction model has high prediction accuracy and stability, and the average value of the root mean square error of the battery used in the experiment is less than 7%, and is better than other prediction models.

Keywords: lithium-ion battery; remaining useful life; variational mode decomposition; bayesian optimization; long short-term memory network

0 引言

锂离子电池被广泛应用于国防军事、汽车、家用电器、通信、航空航天等领域,与传统的电池相比,锂电池具有输出电压高、自放电低、循环寿命长、可靠性高等优点^[1]。但是随着锂电池的长时间使用,锂电池的充放电循环次数也在不断增加,电池的老化程度也在不断加重,锂电池剩余使

用寿命(remaining useful life, RUL)也逐渐缩短,降低了设备的安全性和可靠性^[2]。因此,为了保证用电设备使用的安全可靠,有必要对锂电池 RUL 进行预测。

现有的锂电池剩余寿命预测方法主要分为基于模型的 RUL 预测方法和基于数据驱动的 RUL 预测方法^[3],基于模型的方法需要依赖复杂的电池模型,容易受到噪声的干扰,其适应性较差,并且需要学习电池内部的物理化学反应

收稿日期:2022-06-04

* 基金项目:国家自然科学基金(61263023,61863016)项目资助

和电池失效模型才能实现锂电池 RUL 的预测^[4-5]。数据驱动方法不考虑电池内部的物理化学反应和电池失效模型, 提取电池的容量、电流、电压等数据, 分析出电池健康状态和容量变化趋势, 预测锂电池的剩余使用寿命^[6]。因此, 基于数据驱动的方法可以避免基于模型方法适应性较差的缺点。数据驱动的方法主要有: 基于失效数据的预测方法、基于退化数据的预测方法、基于多源数据融合的预测方法^[7]。基于数据驱动的融合方法将多个方法进行结合, 改善了单一的方法在寿命预测领域得到的效果并不理想的缺点, 杨彦茹等提出了一种基于完全集成经验模态分解与自适应噪声(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)和多输入单输出支持向量机回归(support vector regression, SVR)相结合的锂离子电池 RUL 预测方法, 将健康因子由 CEEMDAN 分解, 得到一系列相对稳定的序列, 以 CEEMDAN 分解的健康因子作为 SVR 预测模型的输入, 以容量作为输出, 实现锂电池 RUL 预测^[8]。Chen 等^[9]提出了一种基于 Transformer 神经网络的锂离子电池 RUL 预测方法, 首先通过自动去噪编码器(denoising auto-encoder, DAE)缓解电池容量再生问题, 然后将重构之后的容量序列作为结果, 采用 Transformer 来预测 RUL, 该方法相比传统的算法在预测 RUL 方面表现更好。吴琼等^[10]提出了一种利用遗传算法优化 BP 神经网络的锂离子电池剩余容量估算方法, 通过主成分分析将锂电池健康因子进行降维处理, 利用遗传算法优化 BP 神经网络的连接权值, 对锂离子电池进行 RUL 预测。黄凯等^[11]提出了一种完全集成经验模态分解(CEEMDAN)结合长短期记忆神经网络(long short-term memory network, LSTM)的预测方法, 首先使用 CEEMDAN 对容量退化序列进行分解降噪, 然后进行相关性分析, 只选择残差作为降噪处理后的容量序列, 采用 LSTM 来建立锂电池 RUL 预测模型, 该方法具有更高的预测精度。

基于上述分析, 提出一种 VMD (variational mode decomposition, VMD) 结合贝叶斯优化的 LSTM 预测模型。变分模态分解能够在排除噪声干扰的前提下提取电池容量退化特征。LSTM 是一种特殊的递归神经网络(recurrent neural network, RNN), 具有学习长期依赖信息的能力, 可以有效地处理时间序列数据。并且 LSTM 算法广泛应用于故障诊断和寿命预测领域, 文献[12-13]都使用 LSTM 或优化 LSTM 算法对航空发电机、轴承等方面进行寿命预测, 均得到了较为准确的预测结果。由于 LSTM 参数设置复杂, 选择不同的超参数会对模型的预测准确率产生不同的影响, 人工调优需要经过大量的尝试来确定模型最优的超参数组合, 效率较低, 贝叶斯优化(bayesian optimization, BO)不需要对目标函数进行大量的评估就可以得到最终的最优解, 可以解决 LSTM 网络超参数的选择问题^[14]。实验表明, VMD-BO-LSTM 预测方法能够有效

预测锂电池的 RUL。

1 理论背景

1.1 变分模态分解

与类变分模态分解(empirical mode decomposition, EMD)方法不同, VMD 可以指定信号分解后模态分量的个数, 其整体框架主要包括构造变分问题和求解变分问题, 处理非平稳信号有较好的效果, 并且具有较好的分解能力及抗噪声干扰等优点^[15]。由于锂电池使用过程中会受到容量回升现象和随机干扰等因素的影响, 因此需要使用 VMD 对其进行处理, 达到去除噪声干扰, 更好地提取电池容量退化特征的目的。

对于信号 $f(t)$, 首先是构造变分问题, 其约束条件的变分问题为:

$$\min_{\{u_k, w\}} \left\{ \sum_{k=1}^K \partial_t \left[\left(\delta(t) + \frac{j}{\pi} \right) * u_k(t) \right] * e^{-jw_k t} \right\} \|_2^2 \quad (1)$$

$$\text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \quad (2)$$

式中: $\{u_k\}$ 为分解得到的 k 个模态分量(IMF); $\{w_k\}$ 为各 IMF 中心频率; $*$ 表示卷积运算; t 为函数时间导数; ∂_t 表示求偏导; δ 为单位脉冲函数, $f(t)$ 为原始信号。

其次, 求解变分问题, 式(1)可以通过引入一个惩罚因子 α 和拉格朗日乘数算子 λ 来将一个有约束的变分问题转换为一个无约束的变分问题。

$$\begin{aligned} & \Gamma(\{u_k\}, \{w_k\}, \lambda) = \\ & \alpha \left\{ \sum_{k=1}^K \partial_t \left[\left(\delta(t) + \frac{j}{\pi} \right) * u_k(t) \right] * e^{-jw_k t} \right\} \|_2^2 + \\ & (f(t) - \sum_{k=1}^K u_k(t)) \|_2^2 - (\lambda(t), f(t) - \sum_{k=1}^K u_k(t)) \end{aligned} \quad (3)$$

式(2)通过交替方向乘子算法更新 u_k^{N+1} 、 w_k^{N+1} 、 λ^{N+1} 的值, 反复迭代直到满足收敛条件。

$$\widehat{u}_k^{N+1}(w) = \frac{\widehat{f}(w) - \sum_{i=k}^K \widehat{u}_i(w) + \frac{\widehat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2} \quad (4)$$

$$w_k^{N+1} = \frac{\int_0^\infty w |\widehat{u}_k(w)|^2 dw}{\int_0^\infty |\widehat{u}_k(w)|^2 dw} \quad (5)$$

式中: $\widehat{u}_k^{N+1}(w)$ 为当前剩余分量的维纳滤波, w_k^{N+1} 为当前模态分量功率谱的重心, $\widehat{u}_k(w)$ 为傅里叶变换, $u_k(t)$ 为实部。

1.2 贝叶斯优化

贝叶斯优化是在方程未知的情况下, 根据概率方法快速预估最大值或最小值的一种算法, 克服了人工调参、网格搜索优化方法效率低的缺点。该算法将目标函数前期的评估结果用来建立目标函数的概率代理模型, 需要利用前期的评估信息来选择下一组超参数, 提高了超参数的搜索效

率和超参数的质量,使模型的预测精度和适应能力得到提高^[16]。

$$x^* = \operatorname{argmin}_{x \in X} f(x) \quad (6)$$

式中: $f(t)$ 为未知待优化的黑盒函数; X 为候选集区域。

贝叶斯优化算法的关键部分包括模型和采集函数。其中高斯模型具有灵活性和可变性的优势,高斯过程是一种用概率来描述函数分布的模型,它使我们得以结合先验知识对数据进行概率预测,大大减少了模型参数的个数。采样函数则是对整个候选集进行评估以便快速获得最优解。本文选择高斯过程和 PI 函数作为概率代理模型和采集函数。

1.3 长短期记忆神经网络

长短期记忆神经网络(LSTM)有效地解决了 RNN 梯度爆炸和梯度消失的问题^[17]。状态单元(Cell State)和门(Gate)是 LSTM 神经网络的核心概念,用于筛选历史信息,使 LSTM 的适应性更强,其神经元结构如图 1 所示,更新过程和原理公式为:

1) 计算遗忘门 f_t , 有选择地遗忘信息:

$$f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f) \quad (7)$$

2) 计算输入门 i_t , 有选择地存储信息:

$$i_t = \sigma(W_i h_{t-1} + U_i x_t + b_i) \quad (8)$$

3) 计算目前时刻的细胞状态值 \bar{c}_t :

$$\bar{c}_t = \tanh(W_c h_{t-1} + U_c x_t + b_c) \quad (9)$$

4) 计算输出门 o_t , 得到目前时刻的预测结果:

$$o_t = \sigma(W_o h_{t-1} + U_o x_t + b_o) \quad (10)$$

5) 形成新的细胞状态值 c_t :

$$c_t = f_t \odot c_{t-1} + i_t \odot \bar{c}_t \quad (11)$$

6) 计算目前时刻隐藏层的输出值 h_t :

$$h_t = o_t \odot \tanh(c_t) \quad (12)$$

式中: x_t 为当前时刻 t 所对应的输入状态; h_t 为当前时刻 t 所对应的隐藏层的输出值; $W_f, U_f, W_i, U_i, W_c, U_c, W_o, U_o$ 为权重矩阵; b_f, b_i, b_c, b_o 为偏置项; σ 为 sigmoid 函数, 定义为 $0 \sim 1$; \tanh 为双曲正切函数, 定义为 $-1 \sim 1$ 。

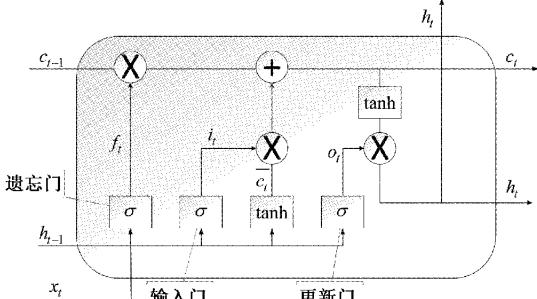


图 1 LSTM 神经元结构

2 基于 VMD 和优化的 LSTM 预测方法

2.1 数据集介绍

采用马里兰大学 CALCE 中心的锂离子电池数据集验

证本文算法的性能^[18]。选取标号 CS2_35, CS2_36, CS2_37, CS2_38 的电池进行测试。CALCE 锂电池数据集的容量序列退化趋势如图 2 所示。

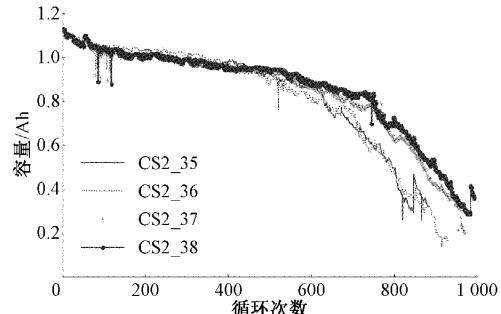


图 2 电池容量退化曲线

2.2 VMD 降噪

电池容量退化序列经过 VMD 分解,可以减少容量回升对电池容量序列的干扰影响。经过多次试验和观察得到 VMD 的最终参数,模态分量个数 K 设置为 5, 惩罚系数 α 设置为 171。以 CS2_35 号电池为例,容量退化序列和经过分解得到的模态分量如图 3 所示,重构后的容量序列如图 4 所示。将原始容量退化序列和四块电池分解的模态分量进行皮尔逊相关性分析,结果如表 1 所示。

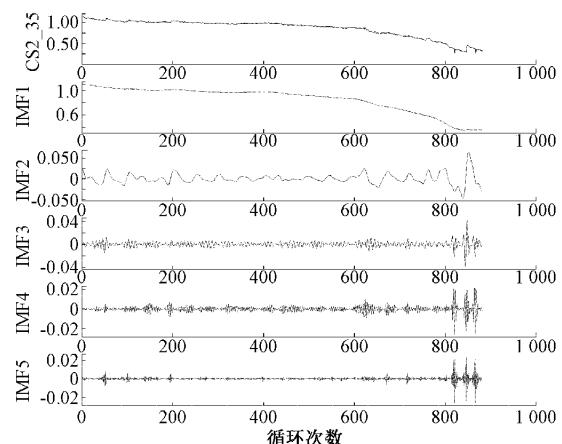


图 3 CS2_35 号电池 VMD 分解得到的模态分量

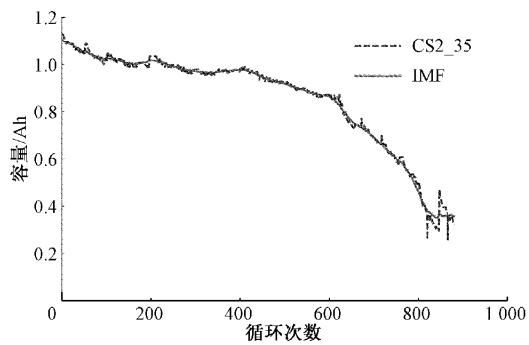


图 4 重构之后的容量退化曲线

表 1 原始容量与分解得到的 IMF 的相关系数

分量	CS2_35	CS2_36	CS2_37	CS2_38
IMF1	0.991 813	0.983 513	0.989 176	0.981 714
IMF2	0.057 146	0.005 213	0.002 569	0.003 301
IMF3	0.001 176	0.000 868	0.001 051	0.000 922
IMF4	0.000 379	0.000 397	0.000 456	0.000 531
IMF5	0.000 238	0.000 205	0.000 218	0.000 243

通过比较分解得到的模态分量与原容量退化序列,部分相关性较低的模态分类,可以被当作噪声舍弃。经过表 1 分析,选取与原始容量相关系数高的模态分量 IMF1 进行重构。从图 4 中可以看出,重构之后的容量序列有效地反映了电池容量的全局退化趋势。因此,为了避免噪声信号的影响,本文将重构之后的容量序列作为降噪处理后的容量序列。

2.3 超参数优化

本文采用贝叶斯优化算法对文中 VMD-LSTM 网络模型进行超参数寻优。超参数优化结果如表 2 所示。

表 2 超参数优化结果

模型	超参数	范围	贝叶斯
LSTM	输入数据的特征维数	100~1 000	389
	隐藏层的维数	100~300	149
	模型堆叠的层数	1~3	2
	迭代次数	100~2 000	1 781
	学习率	0.000 1~0.01	0.000 2

2.4 基于贝叶斯优化的 LSTM 预测模型

通过 LSTM 模型训练重构之后电池容量退化序列,利用前一段时刻的容量退化序列进行预测得到下一时刻的序列。贝叶斯优化的 LSTM 模型流程如图 5 所示。

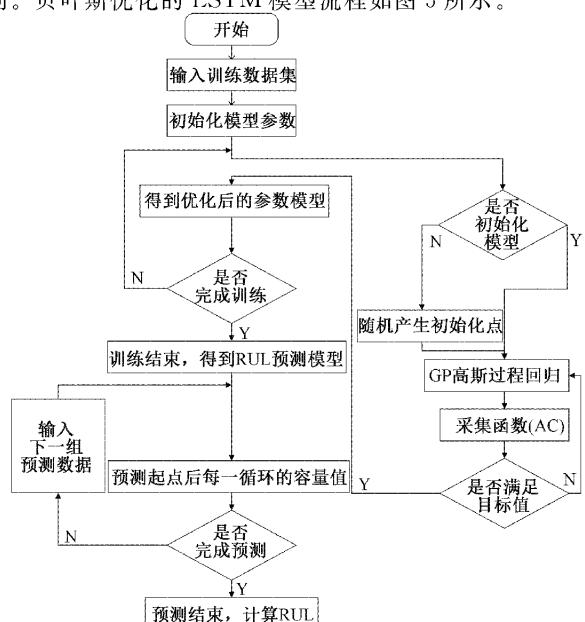


图 5 贝叶斯优化的 LSTM 模型流程

2.5 模型评估标准

采用平均绝对误差(MAE)、均方根误差(RMSE)和均方误差(MSE)作为预测模型的评估标准,公式为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |x(i) - \hat{x}(i)| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x(i) - \hat{x}(i))^2} \quad (14)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (x(i) - \hat{x}(i))^2 \quad (15)$$

式中: n 为预测循环周期数; $x(i)$ 为锂电池容量序列的真实值; $\hat{x}(i)$ 为锂电池容量序列的预测值。

上述评估标准可以用来衡量模型预测曲线的拟合程度和预测效果,因此选择作为模型的评估标准。评估标准越小,表明模型的预测准确度越高。

3 实验验证结果分析

实验所选取测试的电池的测试温度均为 1 ℃,容量额定值为 1.1 Ah,所有的电池首先以 0.55 A 恒流充电,使电池的电压上升到 4.2 V 的充电截至电压,再以 4.2 V 恒压充电,当充电的电流降至 50 mA 后,然后以 0.55 A 的恒流放电,使电池的电压下降到 2.7 V 的放电截至电压。重复上述充电、放电的过程,根据 IEEE 标准 1188-1996,当 CALCE 数据集中的 CS2_35 等锂电池实际容量下降到的 0.88 Ah,就认为电池达到失效阈值,即锂电池达到寿命终止标准(end of life, EOL),便需要及时更换^[19]。

为验证本文提出的 VMD-BO-LSTM 方法的可靠性,将本文方法与单一的预测模型 MLP、RNN、LSTM 进行对比,其中 MLP 为 M1,RNN 为 M2,LSTM 为 M3,本文方法为 M4,表 3 为各个模型设置的参数,选用 MAE、RMSE、MSE 对以上模型的结果进行评估,图 6 分别为各个方法的 RUL 预测结果,图 7 为各块电池的评价指标,表 4 为实验选取电池的平均评价指标。

表 3 模型参数设置

模型	输入数据的特征维数	隐藏层的维数	堆叠的层数	迭代次数	学习率
M1	389	149	2	1 781	0.000 2
M2	389	149	2	1 781	0.000 2
M3	389	149	2	1 781	0.000 2
M4	389	149	2	1 781	0.000 2

由图 6 可以看出,CS2_35、CS2_36、CS2_37、CS2_38 号电池容量退化趋势存在容量回升的现象,容量退化曲线并不平稳;如图 6(a)所示,单一的 RNN 模型对 CS2_35 号电池容量的预测效果较差;如图 6(b)所示,单一的 MLP 模型预测 CS2_36 号电池容量的预测曲线与真实退化曲线拟合程度较差;如图 6(c)和图 6(d)所示,单一的 MLP 模型和

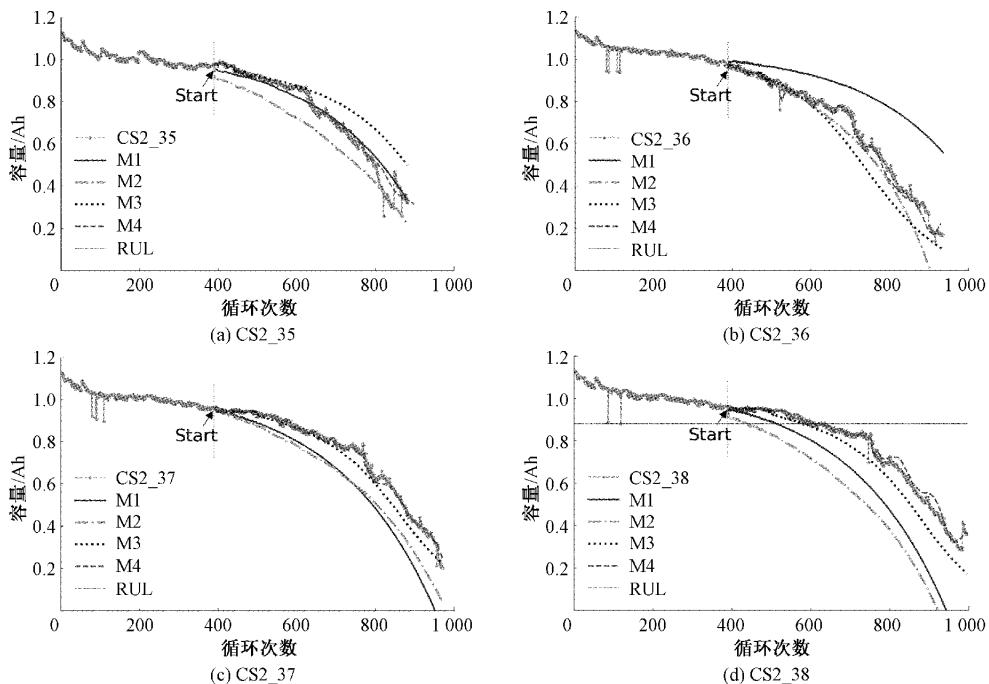


图 6 电池 RUL 预测结果

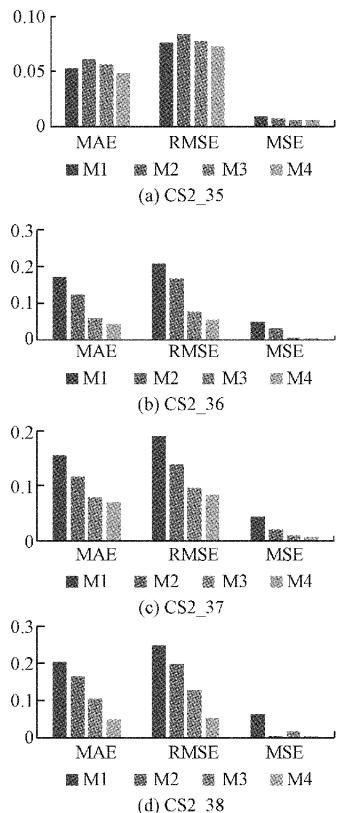


图 7 模型评估标准

RNN 模型对 CS2_37 号、CS2_38 号电池容量预测时预测精准度较低。

由于实验所选取电池的数据序列比较长, 单一的 MLP

表 4 评估指标的平均值对比

预测方法	MAE	RMSE	MSE
M1	0.146 0	0.180 8	0.041 6
M2	0.126 5	0.158 2	0.032 5
M3	0.080 1	0.099 5	0.011 4
M4	0.052 9	0.066 6	0.004 9

模型没有考虑长时间效应问题, 单一的 RNN 模型存在梯度爆炸和梯度消失的问题, 所选取的电池容量前期变化相对平稳, 而容量后期变化不稳定, 前后期变化程度不同, 单一的 LSTM 模型容易受到干扰。与 MLP、RNN 和 LSTM 单一模型相比, 本文提出的方法所得到的预测结果更加准确, 4 块电池的预测结果曲线与电池实际的容量退化曲线拟合程度较高, 预测误差较小。

如图 7(a)所示, 与其他模型相比, 单一的 RNN 模型对 CS2_35 号电池容量的预测效果最差; 如图 7(b)~(d)所示, 单一的 MLP 模型对电池容量进行预测时, 产生了较大的误差差。

如图 7 和表 4 所示, VMD-BO-LSTM 模型的预测精准度要明显高于其他模型, 其绝对平均误差的平均值、均方根误差的平均值和均方误差的平均值分别为 0.059 2、0.066 6 和 0.004 9, 分别比单一的 MLP 模型降低了 0.093 1、0.114 2、0.036 7, 比单一的 RNN 模型降低了 0.073 6、0.091 6、0.027 6, 比单一的 LSTM 模型降低了 0.027 2、0.032 9、0.006 5。证明 VMD-BO-LSTM 模型可以有效提高锂电池 RUL 的预测精准度。

4 结 论

本文提出了一种由 VMD 和贝叶斯优化的 LSTM 组成的锂电池 RUL 预测模型, 提高了预测精度, 得出的结论如下:

采用 VMD 方法能够将非平稳的锂电池容量退化趋势进行分解, 有效降低了锂电池 RUL 预测的复杂度; 经过多此寻优得到 VMD 的参数, 避免退化趋势的过度分解; 通过相关性分析将不同频率的退化分量重构后进行预测, 能够减少噪声的干扰, 使重构之后的退化趋势更加平稳。

LSTM 适合应用于时间序列预测, 本文通过 LSTM 预测模型对锂电池进行 RUL 预测。贝叶斯优化算法确定 LSTM 的超参数, 避免了手动调优效率低下的问题, 从整体上提高了 VMD-LSTM 的预测精度。

实验所使用的 VMD 算法, 模态个数和惩罚因子经过多次测试确定, 并未选择智能优化算法对其进行优化, 因此今后的实验可以利用相关优化算法优化 VMD, 从而提高锂电池 RUL 预测的准确度。

参 考 文 献

- [1] LIU D T, ZHOU J B, PENG Y. Data-driven prognostics and remaining useful life estimation for lithium-ion battery: a review [J]. Instrumentation, 2014, 1(1):59-70.
- [2] 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):14.
- [3] 刘大同, 周建宝, 郭力萌, 等. 锂离子电池健康评估和寿命预测综述 [J]. 仪器仪表学报, 2015, 36(1):1-16.
- [4] 印学浩, 宋宇晨, 刘旺, 等. 基于多时间尺度的锂离子电池状态联合估计 [J]. 仪器仪表学报, 2018, 39(8): 118-126.
- [5] 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.
- [6] 裴洪, 胡昌华, 司小胜, 等. 基于机器学习的设备剩余寿命预测方法综述 [J]. 机械工程学报, 2019, 55(8): 13.
- [7] 林娅, 陈则王. 锂离子电池剩余寿命预测研究综述 [J]. 电子测量技术, 2018, 41(4):29-35.
- [8] 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.
- [9] CHEN D, HONG W, ZHOU X. Transformer network for remaining useful life prediction of lithium-ion batteries [J]. IEEE Access, 2022, 10: 19621-19628.
- [10] 吴琼, 徐锐良. 基于 PCA 和 GA-BP 神经网络的锂电池容量估算方法 [J]. 电子测量技术, 2022, 45(6):66-71.
- [11] 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, DOI: 10.19595/j.cnki.1000-6753.tces.210860.
- [12] 张帅, 杜军, 严智. 基于输出层增强的 LSTM 发动机排气温度模型 [J]. 电子测量与仪器学报, 2019, 33(8): 124-132.
- [13] 谢锦阳, 姜媛媛, 王力. 基于 RA-LSTM 的轴承故障诊断方法 [J]. 电子测量与仪器学报, 2022, 36(6): 213-219, DOI: 10.13382/j.jemi.B2205226.
- [14] 邹智, 吴铁洲, 张晓星, 等. 基于贝叶斯优化 CNN-BiGRU 混合神经网络的短期负荷预测 [J]. 高电压技术, 2022, 48(10): 3935-3945, DOI: 10.13336/j.1003-6520.hve.20220168.
- [15] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [16] 崔佳旭, 杨博. 贝叶斯优化方法和应用综述 [J]. 软件学报, 2018, 29(10): 3068-3090.
- [17] SAMITH W. Time series forecasting: Analysis of LSTM neural networks to predict exchange rates of currencies [J]. Instrumentation, 2020, 7(4): 25-39.
- [18] LIU J, CHEN Z, HUANG D, et al. Remaining useful life prediction for lithium-ion batteries based on time interval of equal charging voltage difference [J]. Journal of Shanghai Jiaotong University, 2019.
- [19] HU X, XU L, LIN X, et al. Battery lifetime prognostics [J]. Joule, 2020, 4(2):310-346.

作者简介

叶鑫, 硕士研究生, 主要研究方向为寿命预测。

E-mail: yangzhubing_ye@kust.edu.cn

王海瑞, 博士, 教授, 主要研究方向为计算机应用基础和工程技术。

E-mail: hrwang88@163.com

李远博, 硕士研究生, 主要研究方向为数据挖掘。

E-mail: 842080306@qq.com

朱贵富(通信作者), 硕士, 工程师, 主要研究方向为图像处理。

E-mail: zhuguiyu@kust.edu.cn