

VMD-CNN-MLSTM 锂电池 RUL 多步预测

李世钧

中国计量大学, 中国·浙江 杭州 310018

摘要: 针对锂离子电池剩余使用寿命预测中的容量再生噪声和非线性特征难题, 提出一种 VMD-CNN-Mogrifier LSTM 多步预测模型。采用 NASA B5、B6 电池数据, 经变分模态分解有效抑制模态混叠, 其正交性指标显著优于 EMD; 结合 CNN 提取深层特征, 并利用 Mogrifier LSTM 优化时序建模。实验表明, 该模型在 B5 和 B6 电池上的预测误差均优于对比模型, 为锂电池 RUL 精准预测提供了有效方案。

关键词: 锂离子电池; 剩余使用寿命; 变分模态分解; 卷积神经网络; 多步预测

VMD-CNN-MLSTM Lithium battery RUL multi-step prediction

Li Shijun

CHINA JILIANG UNIVERSITY, China Zhejiang Hangzhou 310018

Abstract: To address the challenges of capacity regeneration noise and nonlinear characteristics in predicting remaining service life (RUL) of lithium-ion batteries, this study proposes a multi-stage prediction model combining VMD-CNN-Mogrifier LSTM. Using NASA's B5 and B6 battery datasets, the model employs variational mode decomposition (VMD) to effectively suppress modal aliasing, demonstrating significantly better orthogonality metrics than Empirical Mode Decomposition (EMD). By integrating CNN for deep feature extraction and optimizing temporal modeling through Mogrifier LSTM, the model outperforms comparison approaches in both B5 and B6 battery predictions. Experimental results confirm that this RUL prediction framework provides an effective solution for precise lithium battery lifespan estimation.

Keywords: Lithium-ion batteries; Remaining service life; Variational mode decomposition; Convolutional neural network; Multi-step prediction

0 引言

在“双碳”目标驱动下, 锂离子电池广泛应用于电动汽车、储能系统等领域, 但其循环过程中存在的容量衰退与再生现象, 显著增加了 RUL 预测难度, 误判易引发安全事故^[1]。现有预测方法中, 模型驱动方法依赖电化学机理, 泛化能力差; 数据驱动方法(如 LSTM)虽能捕捉时序依赖, 但难以有效处理容量再生噪声, 且 EMD 分解存在模态混叠问题。为此, 本文构建 VMD-CNN-Mogrifier LSTM 模型, 通过 VMD 抑制模态混叠、CNN 挖掘深层特

征、Mogrifier LSTM 增强时序建模能力, 实现端到端多步 RUL 预测^[2]。

1 理论基础

1.1 变分模态分解 (VMD)

VMD 为自适应信号分解算法, 核心是通过迭代优化变分问题, 将复杂信号分解为 K 个具明确中心频率与有限带宽的本征模态函数, 无模态混叠。

1.1.1 约束变分问题

设原始锂电池容量信号为 $f(t)$, 需分解为 K 个 IMF 分

$\{u_k(t)\}_{k=1}^K$ 量, VMD 的约束变分问题定义见下式。

$$\begin{cases} \min_{\{\omega_k\}, \{\lambda\}} \sum_{k=1}^K \left\| \partial_t \left(\left(\delta(t) + \frac{j}{\pi t} \right) \circ u_k(t) \right) e^{-j\omega_k t} \right\|_2^2 \\ \text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \end{cases}$$

∂_t 为时间偏导, $\delta(t)$ 为 Dirac 函数, 表示卷积运算,

ω_k 为第 k 个 IMF 的中心频率

1.1.2 无约束转化

引入拉格朗日乘子 $\lambda(t)$ 与二次惩罚项 α , 将约束变分问题转化为无约束问题 (见下式)。

$$\mathcal{L}(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left(\left(\delta(t) + \frac{j}{\pi t} \right) \circ u_k(t) \right) e^{-j\omega_k t} \right\|_2^2 +$$

$$\left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle$$

1.1.3 迭代优化求解

采用交替方向乘法更新 IMF 与中心频率, 收敛条件为相邻迭代 IMF 变化量 $<10^{-7}$ (下式)

$$\hat{u}_k^{(n+1)}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i^{(n)}(\omega) + \frac{\hat{\lambda}^{(n)}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^{(n)})^2} \quad (a)$$

$$\omega_k^{(n+1)} = \frac{\int_0^\infty \omega |\hat{u}_k^{(n+1)}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{(n+1)}(\omega)|^2 d\omega} \quad (b)$$

1.2 卷积神经网络 (CNN)

1.2.1 卷积层

滑动卷积提取局部特征, 如下式。

$$X_j^L = f \left(\sum_{i=1}^m X_i^{L-1} \circ K_{ij}^L + b_j^L \right)$$

X_i^{L-1} 为第 L-1 层第 i 个特征图, K_{ij}^L 为卷积核 (本文 $3 \times 1, 32$ 个), b_j^L 为偏置项。

1.2.2 池化层

最大池化降维减参, 如下式。

$$X_j^L = f(\text{down}(X_j^{L-1}))$$

注: $\text{down}(\cdot)$ 为下采样函数, (池化核 2×1 , 步长 2)。

1.2.3 ReLU 激活层

解决梯度消失, 见下式。

$$f(x) = \max(0, x)$$

1.2.4 全连接层

映射特征向量, 设 2 层 (神经元 128、64), 为后续模块提供输入。

1.3 Mogrifier LSTM

Mogrifier LSTM 为传统 LSTM 改进版, 通过输入与隐藏状态交替调制增强门控能力^[9]。

1.3.1 交替机制

设调制轮数 $r=2$, 平衡精度与计算量 (见下式)。

$$h_{\text{prev}}^i = 2\sigma(R^i x^{i-1}) \odot h_{\text{prev}}^{i-2}, \quad i \in [1, 3, \dots, r] \quad (a)$$

$$x^i = 2\sigma(Q^i h_{\text{prev}}^{i-1}) \odot x^{i-2}, \quad i \in [2, 4, \dots, r] \quad (b)$$

$x^{-1}=x$ (初始输入), $h_{\text{prev}}^0 = h_{\text{prev}}^{\square}$ (初始隐藏状态), $\sigma(\cdot)$ 为 sigmoid 函数, Q^i, R^i 经低秩分解减参。

1.3.2 门控与状态更新

调制后的输入 x^\uparrow 与隐藏状态 h_{prev}^\dagger 代入传统 LSTM 门控公式。

表1 NASA B5、B6 锂电池实验参数

电池编号	充电截止电压	充电电流	放电电流	放电截止电压	额定容量	环境温度	失效循环次数
B5	4.2 V	1.5 A	2 A	2.7 V	2 Ah	25°C ± 1°C	125
B6	4.2 V	1.5 A	2 A	2.5 V	2 Ah	25°C ± 1°C	109

表2 模型训练参数

参数类型	参数值
数据集划分	训练集70%、验证集15%、测试集15%
批大小	32
学习率	0.001
最大迭代次数	100
正则化	L2 (惩罚系数0.001)

$$f_t = \sigma(W_f[h_{prev}^\dagger, x^\dagger] + b_f) \quad (a)$$

$$i_t = \sigma(W_i[h_{prev}^\dagger, x^\dagger] + b_i) \quad (b)$$

$$\tilde{C}_t = \tanh(W_C[h_{prev}^\dagger, x^\dagger] + b_C) \quad (c)$$

$$C_t = f_t \odot C_{prev} + i_t \odot \tilde{C}_t \quad (d)$$

$$o_t = \sigma(W_o[h_{prev}^\dagger, x^\dagger] + b_o) \quad (e)$$

$$h_t = o_t \odot \tanh(C_t) \quad (f)$$

W_f, W_i, W_C, W_o 为门控权重矩阵, b_f, b_i, b_C, b_o 为偏置项, 隐藏层神经元数量设为 64, 输出层为 1 个神经元。

2 实验设计与数据预处理

2.1 数据集与参数

采用 NASA B5、B6 数据集, 实验参数如表 1, 终止条件为容量降至初始容量 70%, B5 失效循环 125 次, B6 失效循环 109 次。

2.2 数据预处理

异常值剔除为 3σ 准则;

数据平滑为 5 点移动平均, 公式为:

$$y_t' = \frac{y_{t-2} + y_{t-1} + y_t + y_{t+1} + y_{t+2}}{5}$$

标准化: Z-score 标准化至 $[-1, 1]$, 公式为: $y_t'' = \frac{y_t' - \mu}{\sigma}$

预处理后 B5 电池容量噪声被抑制, 保留衰退趋势

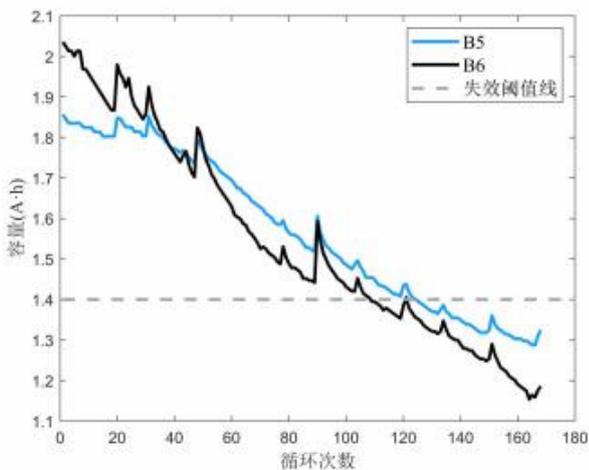


图1 B5 电池容量预处理前后对比

2.3 训练参数

模型训练参数统一, 如表 2, 采用 Adam 优化器、MSE 损失函数, 早停机制 (验证损失连续 10 次不下降则

停止)。

3 模型构建

模型采用“分解 - 特征提取 - 时序预测”三级架构, 步骤如下。

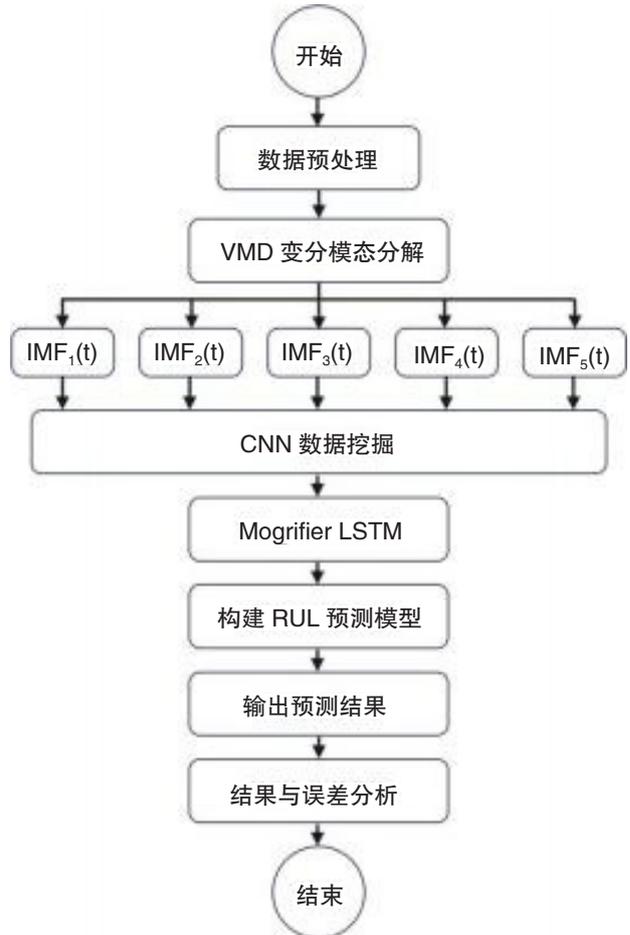
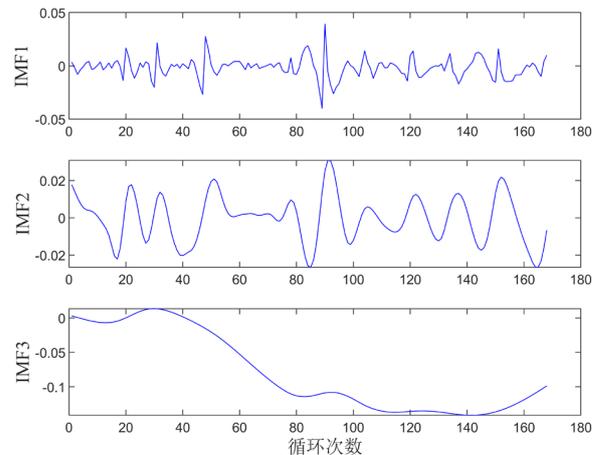
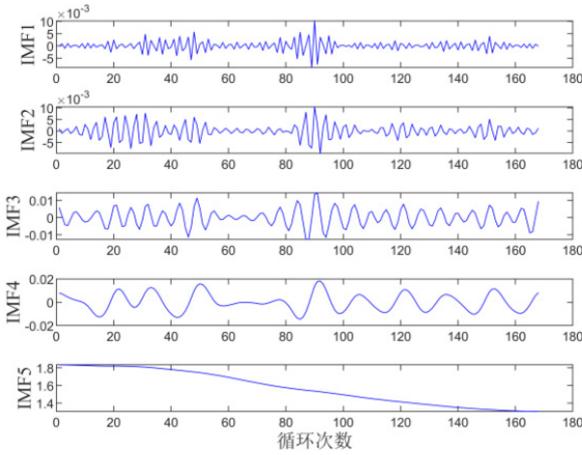


图2 VMD-CNN-MogriifierLSTM模型流程图

VMD 分解: 设 $K=5$, 得 5 个 IMF 与残差, VMD 的 $IO=0.00002$ 远小于 EMD, 无模态混叠。



(1) EMD分解结果



(2) VMD分解结果

图3 EMD与VMD分解结果对比

IMF 重构：基于皮尔逊相关性定权重（表4），IMF5 相关性 0.99763，IMF1 相关性 0.02380，重构序列 $S_{rec} \sum_{k=1}^5 \omega_k \cdot IMF_k$ 。

CNN 特征提取：滑窗 10 划样本，经卷积、池化、全连接层输出 64 维特征。

MogrifierLSTM 预测：输入 64 维特征，调制后预测容量，逆标准化得结果。

表3 EMD与VMD分解IO对比

分解方法	IO
EMD	0.04112
VMD	0.00002

表4 VMD分解各IMF与原始容量相关性

模态分量	皮尔逊相关系数
IMF1	0.02380
IMF2	0.03229
IMF3	0.05079
IMF4	0.11705
IMF5	0.99763

4 实验结果

4.1 VMD 分解效果

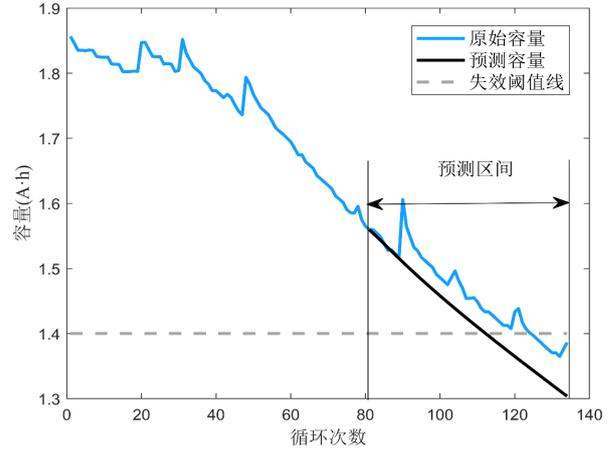
VMD 分解后数据 SNR 从 25.3 dB 升至 42.1 dB，RMSE 从 0.082 Ah 降至 0.021 Ah（表5），有效剥离噪声^[4]。

表5 VMD分解前后数据质量指标

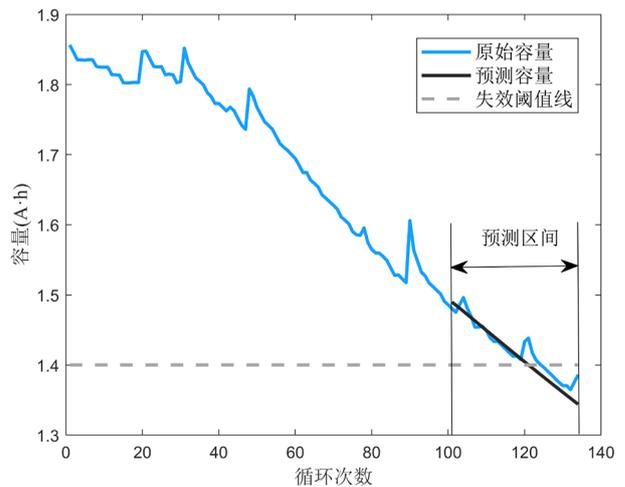
数据类型	SNR (dB)	RMSE (Ah)
预处理后	25.3	0.082
VMD重构后	42.1	0.021

4.2 RUL 预测结果

B5 电池：100 周期起点 MAE=0.0284 Ah、MAPE=2.14%，优于 CNN（0.1725Ah、12.90%）、LSTM（0.2876Ah、21.88%）（表6，图4）。



(a) 预测起点为80



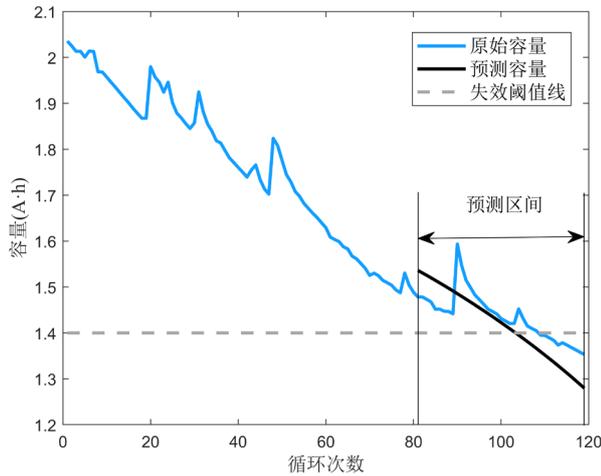
(b) 预测起点为100

图4 B5电池RUL预测结果

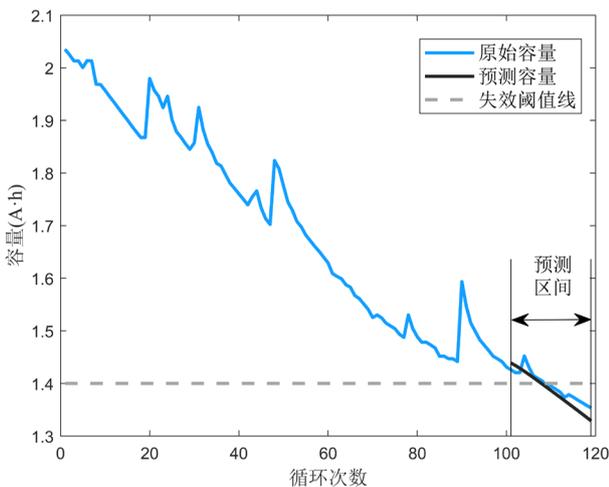
表6 B5电池预测误差对比

预测起点	模型	MAE(Ah)	MAPE(%)
80	CNN	0.1512	11.10
	LSTM	0.2067	14.99
	本文模型	0.1238	9.12
100	CNN	0.1725	12.90
	LSTM	0.2876	21.88
	本文模型	0.0284	2.14

B6 电池：100 周期起点 MAE=0.1154 Ah、MAPE=8.75%，优于 CNN（0.3067Ah、23.06%）、LSTM（0.3434Ah、26.46%）（表 7，图 5）。



(a)预测起点为80



(b)预测起点为100

图5 B6电池RUL预测结果

表7 B6电池预测误差对比

预测起点	模型	MAE(Ah)	MAPE(%)
80	CNN	0.2223	16.41
	LSTM	0.3275	23.97
	本文模型	0.1985	14.95
100	CNN	0.3067	23.06
	LSTM	0.3434	26.46
	本文模型	0.1154	8.75

4.3 消融实验

B5 电池 100 周期起点消融结果（表 8）显示：无 VMD 的模型 MAE=0.0876 Ah，无 CNN 的模型 MAE=0.1542 Ah，传统 LSTM 的模型 MAE=0.0568 Ah，本文模型最优。

表8 消融实验结果

模型	MAE (Ah)	MAPE (%)
CNN-MogrifierLSTM	0.0876	6.38
VMD-LSTM	0.1542	11.56
VMD-CNN-LSTM	0.0568	4.27
本文模型	0.0284	2.14

5 结语

本文表明 VMD 可有效抑制模态混叠，分解后数据质量显著提升；CNN 能挖掘深层非线性特征，降低预测误差；Mogrifier LSTM 增强时序建模能力，优于传统 LSTM；所提模型在 B5、B6 电池预测中均最优，为锂电池 RUL 预测提供可靠方案。

参考文献：

[1] Dong G, Chen Z, Wei J, et al. Battery Health Prognosis Using Brownian Motion Modeling and Particle Filtering[J]. IEEE Transactions on Industrial Electronics, 2018, 65(11): 8646-8655.

[2] Yuli Z, Bo J, Jianguo Z, et al. Adaptive state of health estimation for lithium-ion batteries based on RC equivalent circuit model[J]. Journal of Energy Storage, 2021, 39: 102564.

[3] Szegegy C, Toshev A, Erhan D. Mogrifier LSTMs[J]. Advances in Neural Information Processing Systems, 2019, 32: 11508-11519.

[4] 车云弘, 邓忠伟, 李佳承等. 基于数据驱动的电化学

统泛化 SOH 估计方法[J]. 机械工程学报, 2022,58(24):253-263.

作者简介: 李世钧 (1999-), 男, 汉族, 山西阳泉人, 中国计量大学, 研究生学历, 研究方向: 电子信息。