

# 基于改进模态分解混合模型的锂电池剩余容量预测

宁弘扬, 惠周利, 冯娜娜, 杨明\*

(中北大学 数学学院, 山西 太原 030051)

**摘要:** 随着锂电池在生活中的广泛应用, 开发高效准确的电池剩余容量预测技术, 对于提升用户体验和保障设备稳定运行具有重要意义。采用蛇鹫优化算法(Secretary Bird Optimization Algorithm, SBOA)优化变分模态分解(Variational Mode Decomposition, VMD), 并结合高斯过程回归(Gaussian Process Regression, GPR)以及门控循环单元(Gated Recurrent Units, GRU), 构建了高效的混合预测模型, 实现了对锂电池剩余容量的高精度预测。通过与传统模型GRU、VMD-GRU比较, 表明该预测模型可以快速高效地捕捉电池退化趋势, 所提方法的平均绝对误差和均方根误差分别为0.19%和0.31%, 具有更高的预测精度和泛化性。

**关键词:** 蛇鹫优化算法; 变分模态分解; 高斯过程回归; 门控循环单元; 剩余容量预测

**中图分类号:** TM912 **文献标识码:** A **doi:** 10.62756/csjs.1671-7449.2025039

**引用格式:** 宁弘扬, 惠周利, 冯娜娜, 等. 基于改进模态分解混合模型的锂电池剩余容量预测[J]. 测试技术学报, 2025, 39(3): 313-321.

NING Hongyang, HUI Zhouli, FENG Nana, et al. Hybrid model for lithium-ion battery remaining capacity prediction based on improved variational mode decomposition[J]. Journal of Test and Measurement Technology, 2025, 39(3): 313-321.

## Hybrid Model for Lithium-Ion Battery Remaining Capacity Prediction Based on Improved Variational Mode Decomposition

NING Hongyang, HUI Zhouli, FENG Nana, YANG Ming\*

(School of Mathematics, North University of China, Taiyuan 030051, China)

**Abstract:** With the widespread application of lithium-ion batteries in daily life, the development of efficient and accurate battery state-of-charge prediction technologies is of great significance for enhancing user experience and ensuring stable device operation. An efficient hybrid prediction model that utilizes the sparrow bird optimization algorithm (SBOA) to optimize variational mode decomposition (VMD) in combination with Gaussian process regression (GPR) and gated recurrent units (GRU) is proposed. High-precision predictions of lithium-ion battery state-of-charge are achieved by this model. Comparisons with traditional GRU and VMD-GRU models reveal that the proposed model can swiftly and effectively capture battery degradation trends. The mean absolute error (MAE) and root mean square error (RMSE) of the proposed method are 0.19% and 0.31%, respectively, demonstrating higher prediction accuracy and generalization capability.

**Key words:** secretary bird optimization algorithm(SBOA); variational mode decomposition; Gaussian process regression; gated recurrent unit; remaining capacity prediction

收稿日期: 2024-09-27

基金项目: 国家自然科学基金资助项目(12272356); 山西省基础研究计划资助项目(202203021211088)

作者简介: 宁弘扬(1996-), 男, 硕士生, 主要从事数据分析与智能图像处理等研究。E-mail: 122054316@qq.com。

\* 通信作者: 杨明(1970-), 男, 副教授, 博士, 主要从事数据分析与建模、统计计算等研究。E-mail: hgsnje@163.com。

## 0 引言

随着能源科技的飞跃发展,锂电池凭借高能量密度、长循环寿命及低自放电率等优势,已成为电动汽车核心储能部件<sup>[1]</sup>。精确预测锂电池剩余容量对于预防因电池老化引发的安全隐患、优化维护策略至关重要<sup>[2]</sup>。当前,锂电池剩余容量预测主要分为模型驱动与数据驱动<sup>[3]</sup>。

模型驱动法预测精度常受限于模型复杂性与噪声干扰,易产生偏差<sup>[4]</sup>。构建等效电路模型需深厚的物理背景与复杂的参数设定。数据驱动法绕开电池内部复杂机理,简化了预测流程,增强了灵活性与适应性<sup>[5-6]</sup>。变分模态分解(Variational Mode Decomposition, VMD)作为一种新兴的信号处理技术,相较于经验模态分解(Empirical Mode Decomposition, EMD)和集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD),展现出了更高的鲁棒性和优越性<sup>[7]</sup>。蛇鹭优化算法(Secretary Bird Optimization Algorithm, SBOA)是一种2024年被提出的新型元启发式算法<sup>[8]</sup>。本文提出一种基于改进VMD、高斯过程回归(Gaussian Process Regression, GPR)与门控循环单元(Gated Recurrent Units, GRU)相结合的锂电池剩余容量预测方法,简称IVMD-GPR-GRU。该方法首先通过SBOA算法优化的VMD对锂电池原始信号进行高效分解,提取出一系列本征模态函数(Intrinsic Mode Functions, IMF);然后,对其分量分别利用优化的GPR算法和GRU算法建立与剩余容量之间的映射关系;最后,通过叠加这些分量得出锂电池剩余容量的预测结果,实现对锂电池剩余容量的精准预测。本方法通过精细的信号分解、科学的特征选择、高效的模型构建与智能的预测集成,显著提升了锂电池剩余容量预测的精度与可靠性,为电池健康管理提供了强有力的技术支持。

## 1 算法介绍

### 1.1 VMD算法

VMD作为一种先进的信号处理方法,其核心在于通过解决变分问题来迭代搜索信号的最优分解,从而实现复杂信号的精准剖析。VMD以其卓越的鲁棒性和对噪声的有效处理能力著称,能够显著减轻端点效应并有效避免模态混叠现象,

这对于处理非平稳且多变的锂电池容量数据尤为关键。因此,本文将采用VMD算法分解复杂且非平稳的锂电池容量数据。具体的分解过程如下:

第一步:变分模型的构造。将锂电池容量序列 $C$ 分解为 $K$ 个分量,并对约束变分函数构建为

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

$$s.t. \sum_{k=1}^K \mu_k = C, \quad (1)$$

式中: $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 为每个模态的中心频率; $\mu_k$ 为分解后的第 $K$ 个模态分量; $\partial_t$ 为对 $t$ 的偏导数; $\delta(t)$ 为冲击函数;\*表示卷积。

第二步:引入二次惩罚因子 $\alpha$ 以及Lagrange乘子 $\lambda(t)$ ,将约束变分问题转化为非约束变分问题。增广Lagrange表达式为

$$L[\{\mu_k\}, \{\omega_k\}, \lambda_k] =$$

$$\alpha \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{-j\omega_k t} \right\|_2^2 +$$

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

第三步:初始化 $\{\mu_k^1\}, \{\omega_k^1\}, \{\lambda^1\}$ ,令 $n=1$ 。交替方向乘子算法更新 $\{\hat{\mu}_k^{n+1}\}, \{\hat{\omega}_k^{n+1}\}, \{\hat{\lambda}^{n+1}\}$ ,寻找关于约束变分模型的最优解,更新公式为

$$\hat{\mu}_k^{n+1}(\omega) = \frac{\hat{C}(\omega) - \sum_{i \neq k} \hat{\mu}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)}, \quad (3)$$

$$\hat{\omega}_k^{n+1} = \frac{\int_0^\infty \omega |\hat{\mu}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{\mu}_k(\omega)|^2 d\omega}, \quad (4)$$

$$\hat{\lambda}^{n+1} = \hat{\lambda}^n(\omega) + T \left[ \hat{C}(\omega) - \sum_{k=1}^K |\hat{\mu}_k^{n+1}(\omega)| \right], \quad (5)$$

式中: $T$ 为噪声耐受程度。

第四步:迭代停止条件为

$$\sum_{k=1}^K \frac{\|\hat{\mu}_k^{n+1} - \hat{\mu}_k^n\|_2^2}{\|\hat{\mu}_k^n\|_2^2} < \epsilon (\epsilon > 0), \quad (6)$$

其中VMD参数为 $K$ 与 $\alpha$ 。从VMD算法模型可以看出,模态分解数量 $K$ 和惩罚系数 $\alpha$ 是影响分解效果的关键参数。因此,选择合适的 $K$ 和 $\alpha$ 对于分解处理效果至关重要。本文通过SBOA自适应获取参数。

## 1.2 SBOA 算法

SBOA 分为两个主要阶段:探索阶段和开发阶段。动物生存需要不断地寻找猎物和躲避捕食者的追捕,探索阶段模拟蛇鹭捕食蛇,而开发阶段模拟蛇鹭逃离捕食者。

### 1.2.1 蛇鹭捕猎策略(探索阶段)

蛇鹭整个捕食过程分为 3 个相等的时间间隔,分别对应蛇鹭捕食的 3 个阶段:寻找猎物、消耗猎物和攻击猎物。

1) 寻找猎物阶段的位置更新为

$$\begin{aligned} & \text{While } t < \frac{1}{3}T, \\ & X_i^{\text{new},P1} = X_i + (X_{\text{random1}} - X_{\text{random2}}) \cdot R_1, \\ & X_i = \begin{cases} X_i^{\text{new},P1}, & \text{if } F_i^{\text{new},P1} < F_i, \\ X_i, & \text{else,} \end{cases} \end{aligned} \quad (7)$$

式中:  $t$  为当前迭代次数;  $T$  为最大迭代次数;  $X_i^{\text{new},P1}$  为第  $i$  只蛇鹭在第一阶段的新状态;  $X_i$  为第  $i$  只蛇鹭的位置;  $X_{\text{random1}}$  和  $X_{\text{random2}}$  为第一阶段迭代的随机候选解;  $R_1$  为区间  $[0, 1]$  中随机生成的数;  $F_i^{\text{new},P1}$  为其目标函数的适应度值。

2) 在消耗猎物阶段,引入布朗运动(RB)来模拟蛇鹭的随机运动,捕食阶段的位置更新为

$$\begin{aligned} & RB = \text{randn}(1, Dim) \\ & \text{While } \frac{1}{3}T < t < \frac{2}{3}T, \\ & X_i^{\text{new},P1} = x_{\text{best}} + \exp((t/T)^4) \times (RB - 0.5) \times \\ & \quad (x_{\text{best}} - X_i), \\ & X_i = \begin{cases} X_i^{\text{new},P1}, & \text{if } F_i^{\text{new},P1} < F_i, \\ X_i, & \text{else,} \end{cases} \end{aligned} \quad (8)$$

式中:  $RB$  为从标准正态分布中随机生成的数;  $x_{\text{best}}$  为当前最优值。

3) 蛇鹭在攻击猎物阶段的位置更新为

$$\begin{aligned} & \text{While } t > \frac{2}{3}T, \\ & X_i^{\text{new},P1} = x_{\text{best}} + \left( \left( 1 - \frac{t}{T} \right) \cdot \left( \frac{2t}{T} \right) \right) \times X_i \times RL, \\ & X_i = \begin{cases} X_i^{\text{new},P1}, & \text{if } F_i^{\text{new},P1} < F_i, \\ X_i, & \text{else.} \end{cases} \end{aligned} \quad (9)$$

为了提高算法的优化精度,使用加权 Levy 飞行

$$RL = 0.5 \text{Levy}(Dim). \quad (10)$$

### 1.2.2 蛇鹭逃生策略(开发阶段)

当遇到威胁时,蛇鹭采用各种逃避策略来保护自己。这些策略大致可分为两种,第一种策略

是逃跑或快速奔跑,第二种策略是伪装。

用  $C_1$  代表第一种策略,  $C_2$  代表第二种策略:

if  $\text{rand} < r_i$   $C_1$ :

$$X_i^{\text{new},P2} = x_{\text{best}} + (2RB - 1) \left( 1 - \frac{t}{T} \right) \times X_i,$$

else  $C_2$ :

$$X_i^{\text{new},P2} = X_i + R_2 \times (X_{\text{random}} - K \times X_i),$$

$$X_i = \begin{cases} X_i^{\text{new},P2}, & F_i^{\text{new},P2} < F_i, \\ X_i, & \text{else,} \end{cases} \quad (11)$$

$$K = \text{round}(1 + \text{rand}(1, 1)). \quad (12)$$

SBOA 流程图如图 1 所示。

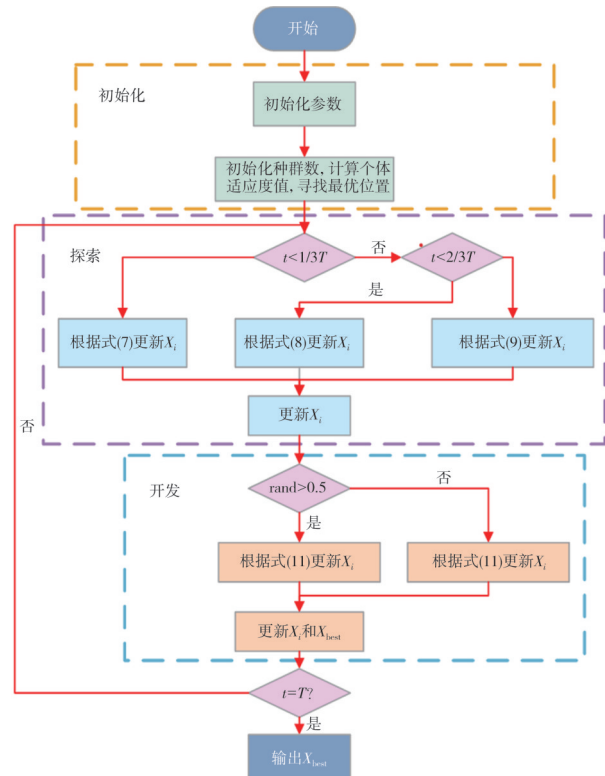


图 1 SBOA 流程图

Fig. 1 Flowchart of SBOA

## 1.3 GRU 算法

锂离子电池充放电过程蕴含复杂的时序特性。针对此类时序数据,传统循环神经网络虽有所应用,但受限于短期序列处理能力及梯度问题。而 GRU 在继承长短期记忆网络(Long Short-Term Memory, LSTM)优势的基础上,通过精简结构,去除了 1 个门控单元,从而加速了学习进程<sup>[9]</sup>。其结构如图 2 所示。

在 GRU 模型中,  $r_t$  和  $z_t$  分别代表重置门和更新门的输出,  $x_t$  作为门控单元的输入,  $\sigma$  和  $\tanh$  分别表示 Sigmoid 激活函数和  $\tanh$  激活函数,相关的

计算式表示为

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t, 1]), \quad (13)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t, 1]), \quad (14)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t, 1]), \quad (15)$$

$$h_t = (1 - z_t) \odot \tilde{h}_t + z_t \odot h_{t-1}, \quad (16)$$

$$y_t^o = \sigma(W_o[h_t, 1]), \quad (17)$$

式中： $W_z, W_r, W_h, W_o$ 为在反向传播学习中的权重参数； $\odot$ 为Hadarmard积运算。




图2 GRU结构图

Fig. 2 GRU structure diagram

#### 1.4 GPR算法

GPR无需依赖交叉验证即可实现优异的正则化效果，这得益于其基于贝叶斯推断的参数估计方法。GPR在预测时不仅输出具体的预测值，还伴随有预测结果的不确定性估计，这一特性极大地增强了模型的解释性和可靠性<sup>[10]</sup>。高斯过程表达式为

$$f(x) \sim GP(m(x), k(x, x')), \quad (18)$$

式中： $m(x)$ 为均值； $k(x, x')$ 为方差。

通常，函数的观测值会受到噪声的影响，假设噪声是加性的、相互独立的并且服从高斯分布，则

$$y = f(x) + \epsilon, \quad (19)$$

式中： $\epsilon \sim N(0, \sigma_n^2)$ 为方差是 $\sigma_n^2$ 的白噪声。

观测值的先验分布可以表示为

$$y \sim N(0, K_f(x, x) + \sigma_n^2 I_n), \quad (20)$$

式中： $I_n$ 为 $n$ 维单位矩阵。

在测试数据集 $x^*$ 中观测值 $y$ 和预测值 $y^*$ 的联合先验分布为

$$\begin{bmatrix} y \\ y^* \end{bmatrix} \sim N\left(0, \begin{bmatrix} K_f(x, x) + \sigma_n^2 & K_f(x, x^*) \\ K_f(x, x^*)^T & K_f(x^*, x^*) \end{bmatrix}\right). \quad (21)$$

后验分布 $p(y^* | x, y, x^*)$ 为

$$p(y^* | x, y, x^*) = N(y^* | \bar{y}^*, \text{cov}(\bar{y}^*)). \quad (22)$$

在构建GPR模型时，核函数 $k(x, x')$ 的选择扮演着决定性的角色，它不仅影响模型的复杂度与泛

化能力，还隐含了对潜在函数特性的先验假设。本文将LIN核函数与Matern52核函数相结合，构建了一个组合核函数作为GPR模型的基石。这一选择旨在融合两种核函数的优点：LIN核函数的简洁性与直接性，以及Matern52核函数在捕捉局部变化与复杂非线性关系方面的卓越能力。

#### 1.5 VMD-GPR-GRU模型的建立过程

基于VMD-GPR-GRU模型的锂电池剩余使用寿命预测流程如图3所示，具体步骤如下：

1) 信号预处理：对数据进行VMD分解，同时采用SBOA算法优化关键参数 $K$ 与 $\alpha$ ，得到各模态分量 $IMF_i (i=1, 2, 3)$ 。

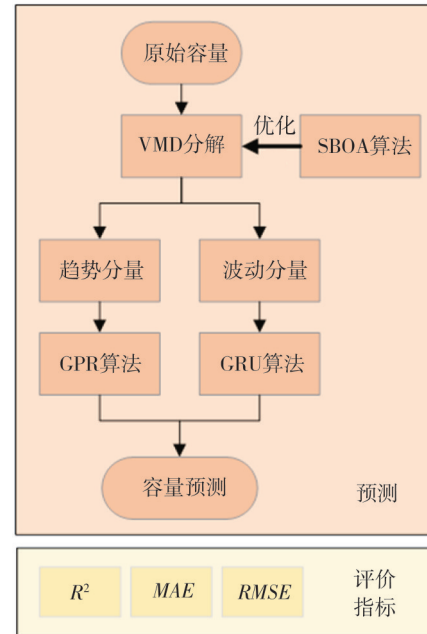


图3 锂电池剩余容量的预测流程

Fig. 3 Prediction process of remaining capacity of lithium battery

2) 特征相关性分析：通过计算各 $IMF$ 与电池容量的相关系数，定量分析分解结果与电池容量关联性，筛选得到趋势分量与波动分量。

3) 模型构建与训练：针对趋势分量 $IMF_1$ ，将 $IMF_1$ 的前50%作为训练集，后50%作为测试集，以时间序列为输入， $IMF_1$ 分量为输出，对趋势分量建立优化的GPR模型。针对其余分量 $IMF_2$ 、 $IMF_3$ ，将 $IMF_2$ 、 $IMF_3$ 的前50%作为训练集，后50%作为测试集，以时间序列为输入， $IMF_2$ 、 $IMF_3$ 分量为输出，对波动分量建立GRU模型，输出为电池容量的分量。

4) 集成预测：将基于不同 $IMF$ 分量的预测结果进行有效叠加，融合成最终的锂电池容量预测

预测值, 实现高精度的预测目标。

## 2 基于 SBOA-VMD-GPR-GRU 模型的锂电池剩余容量预测

### 2.1 锂离子电池退化数据及 VMD 处理

本文选择使用 NASA 锂电池公开数据集, 选取 4 组电池的实验数据进行仿真验证。所选取的 4 组电池的退化曲线如图 4 所示。具体运行条件如表 1 所示。

表 1 NASA 电池运行条件

Tab. 1 NASA battery operating conditions

	B05	B06	B07	B18
充电截止电压/V	4.2	4.2	4.2	4.2
放电截止电压/V	2.7	2.5	2.2	2.5
充电恒流/A	1.5	1.5	1.5	1.5
放电恒流/A	2.0	2.0	2.0	2.0
温度/°C	24	24	24	24




图 4 容量退化曲线

Fig. 4 Capacity degradation curve

为精准提取电池剩余容量退化特征, 采用 SBOA 算法优化 VMD 处理电池容量退化序列。表 2 列出了优化后的 VMD 最终参数  $K$  值。图 5 直观展示了电池退化曲线及其 VMD 分解的模态分量。

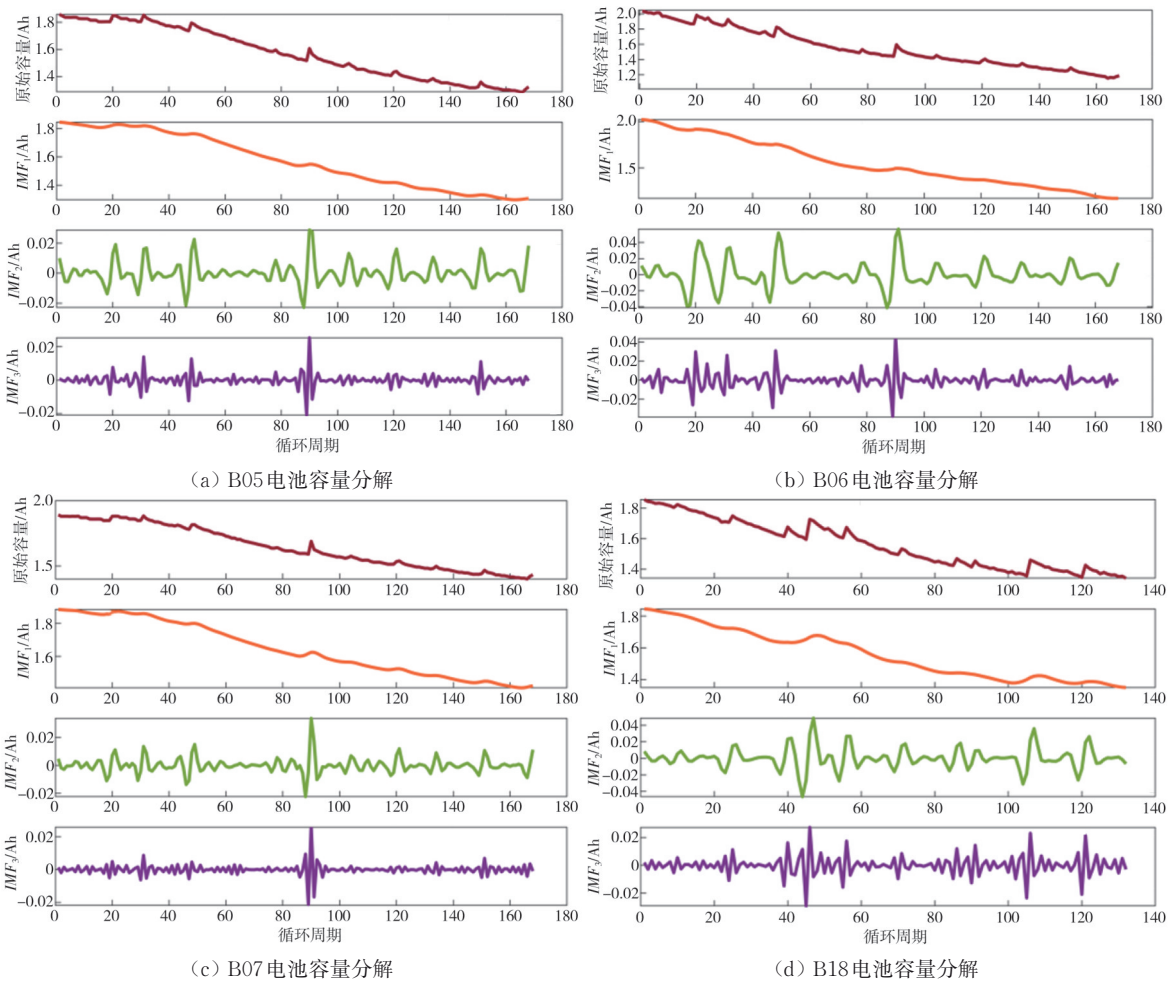


图 5 电池退化曲线和 VMD 分解结果

Fig. 5 Battery degradation curve and VMD decomposition results

由图 5 可见, 电池容量随循环次数递增而逐渐退化, 这一趋势与电池的寿命衰减规律相吻合。然

而, 在退化过程中, 还伴随着容量的再生现象, 这表明电池具有一定的恢复能力, 这可能是由于电池内

部某些可逆的化学或物理过程所导致的。VMD分解的模态分量各具特色： $IMF_1$ 精准捕捉原始数据总体趋势，与电池容量退化一致； $IMF_2$ 揭示容量再生中的波动，可能反映电池使用的特定变化或周期性因素，如充放电周期、温度波动等； $IMF_3$ 则代表高频变化，或与电池内部微观结构、化学过程紧密相关。此外，VMD技术的有效应用不仅实现了对锂电池老化数据的精准分解，还成功识别出了不同的模态分量。这些分量各自代表了电池在不同时间尺度的变化情况，为深化对电池老化机制及性能变化的理解提供了有力的支持。

表2 VMD的参数设置

Tab. 2 VMD parameter settings

	B05	B06	B07	B18
K	3	3	3	3
$\alpha$	17.928 4	19.378 4	92.982 6	10.108 1


表3展示了电池各分量与电池容量的Person相关性分析结果。

表3 电池各分量与电池容量的Person相关性

Tab. 3 Person correlation between battery components and battery capacity

	Person相关性			
	B05	B06	B07	B18
$IMF_1$	0.998 8	0.997 0	0.998 4	0.994 7
$IMF_2$	0.065 1	0.103 1	0.069 9	0.122 6
$IMF_3$	0.034 7	0.053 8	0.039 2	0.067 7

通过对比电池各分量与电池容量退化序列，得出以下结论： $IMF_1$ 与原始容量退化序列高度相关，表明它蕴含了原始数据中的主要变化模式，有效反映了数据的总体趋势，因此可视为趋势分量；相比之下， $IMF_2$ 和 $IMF_3$ 与电池容量退化序列的相关性较低，说明它们与电池容量退化趋势的关联性不强，



(a) 3组电池容量实际值与预测值

难以全面捕捉电池容量的整体变化。然而，如图5所示， $IMF_2$ 和 $IMF_3$ 能够揭示电池容量再生和波动的现象，因此可被视作波动分量。

## 2.2 剩余容量预测

本文通过引入平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Squared Error, RMSE) 和决定系数 ( $R^2$ ) 对模型的预测精度进行评价。


$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|, \quad (23)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}, \quad (24)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad (25)$$

式中： $N$ 为样本总数； $y_i$ 为剩余容量真实值； $\hat{y}_i$ 为剩余容量预测值； $\bar{y}$ 为剩余容量真实平均观测值。 $MAE$ 与 $RMSE$ 的范围为 $(0, +\infty)$ ，越接近0，表示模型的误差结果越小； $R^2$ 范围为 $(0, 1)$ ，越接近1表示模型拟合效果越好。

随后，对4组电池的剩余容量进行了建模预测，将 $IMF$ 分量的数据集均分为训练集和测试集。预测结果及误差分析如图6和表4所示。4组电池的剩余容量预测效果良好，预测误差主要集中在 $-0.02 \sim 0.02$ 之间；决定系数 $R^2$ 最高达0.9986，最低也有0.9945；而 $MAE$ 最大值为0.0025，最小值低至0.0019，充分验证了本文模型在剩余容量预测上的高精度。更重要的是，该方法能准确捕捉电池退化趋势，并有效追踪电池老化过程中的突变情况。模型在4组电池上的适用性进一步证明了其有效性。



(b) 3组电池容量误差

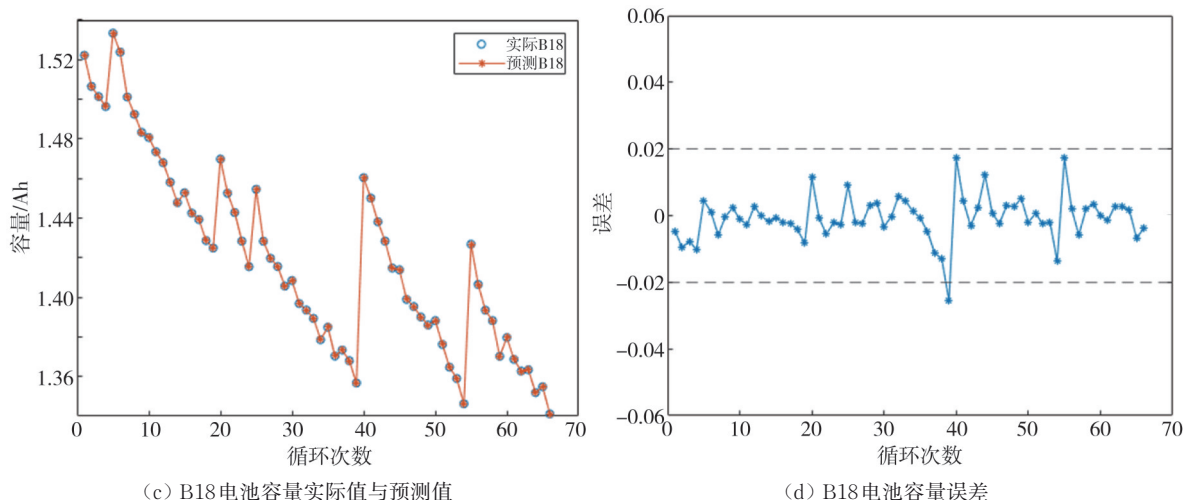


图 6 预测结果及误差分析

Fig. 6 Prediction results and error analysis

表 4 预测误差分析

Tab. 4 Analysis of prediction error

	B05	B06	B07	B18
MAE	0.001 9	0.002 4	0.001 9	0.002 5
RMSE	0.003 1	0.004 3	0.003 5	0.003 6
R <sup>2</sup>	0.998 6	0.998 1	0.997 1	0.994 5

### 2.3 剩余容量预测的比较实验

为深入评估模型预测效果,设计了多组对比实验。表 5 展示了 VMD-GPR-GRU 融合模型采用不同核函数对 4 组电池剩余容量的预测结果。误差分析显示,组合核函数模型的 MAE、RMSE 均低于单一核函数模型,而 R<sup>2</sup> 值则更高,证明组合核函数模型预测性能更佳。图 7 直观对比了不同建模方法的剩余容量预测结果,本文模型预测值与真实值高度接近,明显优于 GRU 算法和 VMD-GRU 算法,后两者预测结果偏差较大。此外,本文方法能精准捕捉电池退化趋势,有效追踪电池老化中的突变,进一步验证了其优越性能。

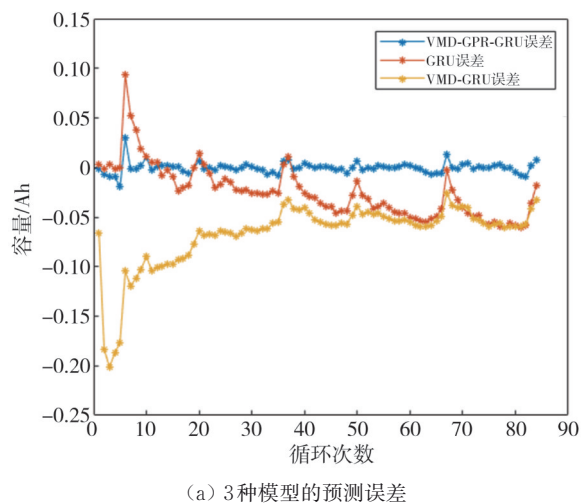
表 5 模型采用不同核函数预测误差

Tab. 5 Models use different kernel functions to predict errors

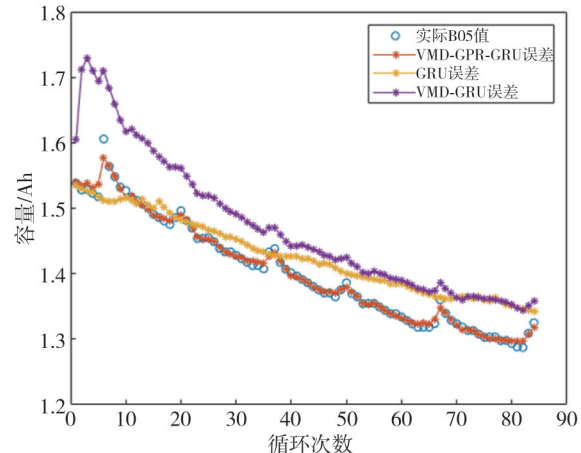
	本文方法	LIN 核函数	Matern52 核函数
B05 MAE	0.001 9	0.002 0	0.013 1
B05 RMSE	0.003 1	0.003 3	0.014 8
B05 R <sup>2</sup>	0.998 6	0.998 3	0.965 9

为深入验证本文算法的有效性,将所提算法与其他文献算法在 4 组电池数据集上的剩余容量预测结果进行了对比,详见表 6(评价指标为 RMSE)。表 6 清晰显示,对于 4 组电池,本文模型的 RMSE 值均为最低,具体为 0.003 1, 0.004 3, 0.003 5, 0.003 6。与次优算法相比,本文模型的 RMSE 分别

降低了 66.7%, 82.9%, 50.7% 和 75.3%。这一显著优势充分证明,本文模型能更精确地反映锂电池的退化趋势,预测性能卓越。



(a) 3种模型的预测误差



(b) B05 电池实际容量值与 3 种模型预测值

图 7 不同方法剩余容量预测结果对比


Fig. 7 Comparison of prediction results of residual capacity by different methods

表 6 本文模型与其他文献算法的比较


Tab. 6 Comparison between the proposed model and algorithms in other literatures

来源	模型	RMSE			
		B05	B06	B07	B18
本文	VMD-GPR-GRU	0.003 1	0.004 3	0.003 5	0.003 6
文献[11]	高斯函数-GRU	0.043 8	0.048 1	0.034 1	0.052 8
文献[12]	VMD-LSTM-GPR	0.009 3	0.025 2	0.007 1	0.014 6
文献[13]	EMD-GRU	0.034 6	0.043 3	0.035 6	0.038 1

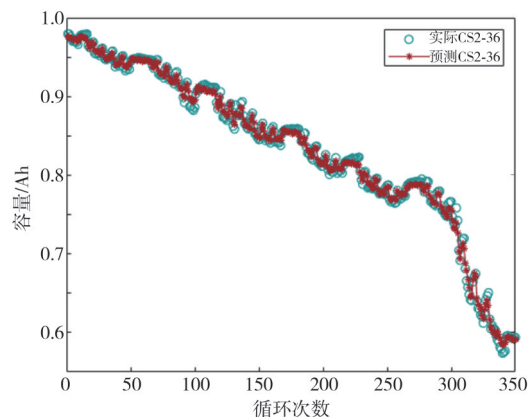
为验证模型的泛化性能,选取马里兰大学 CALCE 数据集中的 CS2-34 号电池(分解参数  $K=6, \alpha=10$ )进行预测实验。在该模型的预测结果中显示,平均  $MAE$  为 0.21%, 平均  $RMSE$  为 0.36%, 平均  $MAPE$  为 0.29%。此外,选取了马里兰大学 CALCE 数据集中的 CS2-36 号电池(分解参数  $K=6, \alpha=368.8278$ )以及文献 [14] 中 35C02 号(分解参数  $K=7, \alpha=124.7139$ )电池数据集进行预测,预测结果如图 8 所示。从图中可以看出所建模型的预测准确度较高,且预测误差较小,说明该模型具有良好的泛化能力。




(a) CS2-34 电池容量实际值与预测值




(b) CS2-34 电池容量误差




(c) CS2-36 电池容量实际值与预测值



(d) CS2-36 电池容量误差



(e) 35C02 电池容量实际值与预测值



(f) 35C02 电池容量误差

图 8 不同数据集电池的剩余容量预测结果

Fig. 8 Predicted remaining capacity of batteries in different data sets

### 3 结 论

本文提出了一种融合改进VMD、GPR与GRU的新方法,用于预测电池剩余容量。通过皮尔逊相关系数,定量分析了容量退化曲线的VMD分解结果,精选出与电池容量密切相关的趋势分量和波动分量。针对趋势分量,构建了优化的GPR模型;而对于波动分量,则采用GRU模型进行建模。这两个模型的输出分别代表电池容量的不同分量,其和即为预测的电池容量。通过多组对比实验验证,结果表明本文提出的模型能更精确地捕捉锂电池的退化趋势,展现出卓越的预测性能。

同时,模型在实际应用中面临若干潜在的局限性,其有效性在很大程度上取决于输入数据的质量。在电池领域,高质量的数据往往难以获取,因为电池性能受多种因素影响,且这些因素可能难以准确测量。数据的噪声、缺失或不一致性都可能影响模型的预测准确性。此外,在现实生活中,模型在处理极端条件(如极端温度、快速充放电等)下的电池数据时,可能表现出较大的预测误差。这是因为极端条件可能引发电池性能的显著变化,而这些变化可能超出了模型的学习范围。未来,针对上述局限性,可以考虑以下具体方向:探索将深度学习、强化学习等先进机器学习技术与当前模型相结合的可能性,以提高模型的准确性和泛化能力。收集更多来自不同来源、不同条件下的电池数据集,以更全面地评估模型的性能。通过在不同数据集上进行训练和测试,可以进一步提高模型的稳定性和可靠性。通过实验研究和理论分析,更深入地了解电池的退化机制和影响因素,并将这些研究成果转化为模型中的新特征或假设,以提高模型的准确性和实用性。

#### 参考文献:

- [1] 李钰,卓晓军,刘洋,等. 基于PCA-GWO-GRU的锂离子电池剩余使用寿命预测[J]. 矿冶工程, 2024, 44(4): 95-99.  
LI Yu, ZHUO Xiaojun, LIU Yang, et al. Prediction of remaining useful life of lithium-ion batteries based on PCA-GWO-GRU [J]. Mining and Metallurgical Engineering, 2024, 44(4): 95-99. (in Chinese)
- [2] HU X, XU L, LIN X, et al. Battery lifetime prognostics[J]. Joule, 2020, 4(2): 310-346.
- [3] LIU C, WANG Y, CHEN Z. Degradation model and

cycle life prediction for lithium-ion battery used in hybrid energy storage system[J]. Energy, 2019, 166: 796-806.

- [4] 谭星浩,刘有耀,张雪兰. 改进无迹粒子滤波的电动汽车锂电池SOC估算[J]. 传感器与微系统, 2022, 41(4): 134-137.  
TAN Xinghao, LIU Youyao, ZHANG Xuelan. Estimation of lithium battery SOC based on improved unscented particle filtering[J]. Transducer and Microsystem Technologies, 2022, 41(4): 134-137. (in Chinese)
- [5] 王瑞洁,惠周利,杨明. 基于间接健康指标的高斯过程回归对锂电池SOH预测[J]. 储能科学与技术, 2023, 12(2): 560-569.  
WANG Ruijie, HUI Zhouli, YANG Ming. Gaussian process regression based on indirect health indicators for SOH estimation of lithium battery[J]. Energy Storage Science and Technology, 2023, 12(2): 560-569. (in Chinese)
- [6] 冯娜娜,杨明,惠周利,等. 基于蚁狮优化高斯过程回归的锂电池剩余使用寿命预测[J]. 储能科学与技术, 2024, 13(5): 1643-1652.  
FENG Nana, YANG Ming, HUI Zhouli, et al. Prediction of the remaining useful life of lithium batteries based on Antlion optimization Gaussian process regression [J]. Energy Storage Science and Technology, 2024, 13(5): 1643-1652. (in Chinese)
- [7] OUYANG M, SHEN P. Prediction of remaining useful life of lithium batteries based on WOA-VMD and LSTM[J]. Energies, 2022, 15(23): 8918.
- [8] FU Y, LIU D, CHEN J, et al. Secretary bird optimization algorithm: a new metaheuristic for solving global optimization problems[J]. Artificial Intelligence Review, 2024, 57(5): 123.
- [9] GUO F, WU X, LIU L, et al. Prediction of remaining useful life and state of health of lithium batteries based on time series feature and Savitzky-Golay filter combined with gated recurrent unit neural network[J]. Energy, 2023, 270: 126880.
- [10] RASMUSSEN C E, NICKISCH H. Gaussian processes for machine learning (GPML) toolbox [J]. Journal of Machine Learning Research, 2010, 11: 3011-3015.

(下转第 329 页)