

DOI: 10.13234/j.issn.2095-2805.2024.6.188

中图分类号: TM912

文献标志码: A

基于 VMD 和 ISSA-ELM 的锂离子电池 剩余使用寿命预测

丁 恒^{1,2}, 黄 凯^{1,2}(中国电源学会会员), 田海建^{1,2}

(1. 省部共建电工装备可靠性与智能化国家重点实验室(河北工业大学), 天津 300130;

2. 河北省电磁场与电器可靠性重点实验室(河北工业大学), 天津 300130)

摘要: 准确预测锂离子电池的剩余使用寿命 RUL(remaining useful life)对提高工作环境安全性和设备可靠性等具有重要意义。为提高 RUL 预测的稳定性和精度, 提出 1 种基于去噪技术与混合数据驱动模型相结合的电池 RUL 预测方法。首先, 利用变分模态分解处理原始数据, 采用相关性分析筛选出噪声分量, 将残差与相关性较强的分量进行组合完成序列重构过程; 其次, 结合 Tent 混沌映射、正弦余弦算法和 Levy 飞行策略优化麻雀搜索算法 SSA(sparrow search algorithm), 通过寻优得到极限学习机 ELM(extreme learning machine)的最优权阈值; 最后, 采用平滑去噪数据训练改进的 SSA-ELM 模型并完成 RUL 预测, 采用 NASA 数据集验证算法有效性。实验结果表明, 所提方法预测结果的平均绝对误差和均方根误差可分别控制在 1.58% 和 2.14% 内, 具有较高的鲁棒性和预测精度, 可应用于电池 RUL 预测。

关键词: 锂离子电池; 剩余使用寿命预测; 变分模态分解; 麻雀搜索算法; 极限学习机

Prediction of Remaining Useful Life of Lithium-ion Battery Based on VMD and ISSA-ELM

DING Heng^{1,2}, HUANG Kai^{1,2}, Member, CPSS, TIAN Haijian^{1,2}

(1. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China; 2. Key Laboratory of Electromagnetic Field and Electrical Apparatus Reliability of Hebei Province, Hebei University of Technology, Tianjin 300130, China)

Abstract: Accurately predicting the remaining useful life (RUL) of lithium-ion batteries is of significance for improving the safety of working environment and the reliability of equipment. To improve the stability and accuracy of RUL prediction, a battery RUL prediction method based on the combination of denoising technology and hybrid data-driven model is proposed. First, the original data is decomposed by variational mode decomposition, and the noise components are filtered by the analysis of correlation. The residual error is combined with the components which have a strong correlation to complete the sequence reconstruction process. Second, with the combination of Tent chaotic mapping, sine cosine algorithm and Levy flight strategy, the sparrow search algorithm (SSA) is optimized, and the optimal weight threshold of extreme learning machine (ELM) is obtained. Finally, the improved SSA-ELM model is trained by using the smoothed denoised data, and the RUL prediction is completed. The NASA data sets are used to verify the effectiveness of the proposed method. Experimental results show that the average absolute error and root mean square error of the prediction result obtained using this method are controlled within 1.58% and 2.14%, respectively, indicating that this method has a high robustness and a high prediction accuracy. Therefore, the proposed

method can be applied to battery RUL prediction.

Keywords: Lithium-ion battery; remaining useful life (RUL) prediction; variational mode decomposition; sparrow search algorithm (SSA); extreme learning machine (ELM)

收稿日期: 2021-11-12; 修回日期: 2022-01-21; 录用日期:

2022-03-01; 网络首发日期: 2022-06-09

基金项目: 河北省自然科学基金资助项目(E2019202328)

This work is supported by Natural Science Foundation of Hebei Province under the grant E2019202328

锂离子电池具有质量轻、能量密度高、自放电

率低、使用寿命长等优点,被广泛应用于航空航天、电动汽车、军事通信、电子设备等诸多领域。然而,随着使用时长的增加,电池会不可避免地老化并出现故障,严重时将导致灾难性事故的发生^[1-2]。锂离子电池剩余使用寿命是指当前时刻至失效阈值前的剩余可使用循环数。准确预测电池剩余使用寿命 RUL(remaining useful life)可为电池系统的预防性维护提供决策参考,有效降低设备维护成本并防止重大危险事故发生^[3-4]。

通常,RUL 预测方法可以分为2类:基于模型的方法和数据驱动方法。基于模型的方法需要通过电池的先验知识建立可以描述退化过程的数学模型,结合多种滤波算法完成 RUL 预测^[5-6]。这种方法精度较高,但十分依赖所建立的预测模型,且受环境和电池复杂机制的影响,建立精确的退化模型有较大困难,限制了该方法在实际中的应用。

数据驱动方法通过对电池历史数据进行分析来建立相关特征,采用机器学习算法构建退化过程的前、后期映射关系,最终实现 RUL 预测。文献[7]通过支持向量回归 SVR(support vector regression)建立 RUL 预测模型,采用灰狼优化算法 GWO(grey wolf optimizer)对 SVR 重要参数进行优化,相比于极限学习机 ELM(extreme learning machine),SVR 的核函数选择较为困难;文献[8]通过果蝇优化算法 FOA(fruit fly optimization algorithm)对多个核函数进行组合,结合相关向量机 RVM(relevance vector machine)实现 RUL 预测,RVM 计算复杂度较低,但由于高稀疏性,预测结果不够稳定;文献[9]通过经验模态分解 EMD(empirical mode decomposition)将容量序列分为高频和低频2个部分,采用 Elman 神经网络和长短期记忆 LSTM(long short-term memory)神经网络分别进行预测,但该方法并未剔除原始数据中的噪声分量;文献[10]通过 CEEMDAN 对数据进行重构,设计了1种结合卷积神经网络 CNN(convolutional neural network)和 LSTM 的 RUL 预测方法,而作为深度学习,CNN 和 LSTM 更适合处理样本较多的时序预测问题;文献[11]分析了时变温度条件对电池放电容量和老化规律的影响,建立

了基于维纳过程 WP(Wiener process)的预测模型,解决了电池在温时变化条件下的 RUL 预测问题,但维纳过程不适合处理非线性和时间非齐次的数;文献[12]通过对容量退化曲线进行深入分析提取出4个重要特征,采用高斯过程回归 GPR(Gaussian process regression)预测电池 RUL,相比于 ELM,GPR 计算量大且超参数调整过程复杂;文献[13]利用小波降噪 WD(wavelet denoising)对容量数据进行处理,通过改进的鸡群优化 CSO(chicken swarm optimization)算法对 SVR 超参数进行寻优,建立 ICSO-SVR 预测模型,相比于变分模态分解 VMD(variational mode decomposition),为 WD 选择合适的基函数较繁琐。

ELM 是1种基于前馈神经网络的机器学习方法,具有较强的非线性建模能力,适用于锂离子电池的容量退化评估,即使样本数很小,也可以收敛于最优回归。文献[14]开发了1种新的 ELM,通过特征映射生成增强节点重构输入层,使模型能够快速、完整地从输入数据中获得有效的特征信息;文献[15]采用等压放电时间作为退化特征,建立了基于 ELM 的 RUL 预测模型,并采用遗传算法 GA(genetic algorithm)对 ELM 权阈值进行优化。GA 通过模拟自然界生物种群的进化行为来达到寻优目的,种群进行选择、交叉、变异操作来结合出新个体,但种群中有效信息的丢失概率也大大增加。

麻雀搜索算法 SSA(sparrow search algorithm)是1种新的元启发式算法,其灵感源于麻雀种群觅食和反捕食行为。由文献[16]可知,与粒子群优化 PSO(partical swarm optimization)、GWO 等算法相比,SSA 具有更强的优化能力和更快的效率;文献[17]通过大量实验证明了 SSA 算法在收敛速度和稳定性方面的优越性。然而,种群多样性退化和容易陷入局部最优解是 SSA 与大部分智能搜索算法共同存在的问题^[18]。为避免局部最优问题的发生,需要对原始算法进行改进来提高其性能。文献[19]采用随机游走策略对麻雀个体的位置进行优化;文献[20]将自适应超参数和突变算子搜索思想融入 SSA 并提出了改进的麻雀搜索算法 MSSA(modified sparrow search

algorithm), 在原有基础上提高了全局搜索能力。

基于上述分析, 有些方法在数据预处理方面不够完善, 有些方法本身具有局限性, 因此本文提出 1 种基于 VMD 的数据降噪方法和 ISSA-ELM 的锂离子电池 RUL 预测模型。首先, 选取容量作为反应退化趋势的特征, 采用 VMD 对原始数据进行分解, 结合相关性分析 AC(analysis of correlation)去除噪声分量并重构容量序列; 然后, 引入 Tent 混沌序列、正余弦算法及 Levy 飞行策略分别对 SSA 的种群初始化、生产者更新及跟随者位置更新这 3 个步骤进行改进并得到改进的麻雀搜索算法 ISSA(improved sparrow search algorithm); 最终, 通过 ISSA 对 ELM 的相关参数进行优化, 旨在完成建模并实现 RUL 预测。

1 数据预处理

为有效预测电池 RUL, 首先应对电池历史数据进行分析并选出合适的退化特征。与直接测量到的物理参量(电流、电压、温度等)相比, 容量可以直接反映电池的退化过程, 因此本文选择容量作为预测特征。采用 VMD 和 AC 对已知容量序列进行分解、筛选、重构来完成降噪处理, 最终选取降噪后的数据完成 RUL 预测模型的构建。

1.1 变分模态分解原理

VMD 作为 1 种自适应信号处理方法, 其分解过程可视为约束变分问题的迭代求解过程^[21]。通过 VMD 对原始信号进行分解, 可以得到有限个本征模态分量 IMF(intrinsic mode function)和残余分量, 由此产生的约束变分问题为

$$\begin{cases} \min_{\{u_k\}, \{w_k\}} \left\{ \sum_{k=1}^K \left\| \delta_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-jw_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (1)$$

式中: u_k 为分解后的分量; w_k 为中心频率; K 为模态分量个数; δ_t 为对 t 的导数; “*” 代表卷积过程; $f(t)$ 为原始信号。

引入二阶惩罚因子 α 和拉格朗日乘法算子

$\lambda(x)$ 将约束变分问题转化为非约束问题。增广拉格朗日函数可以表示为

$$L(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \delta_t [(\delta(t) + j/\pi t) * u_k(t)] \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (2)$$

式中, λ 为拉格朗日乘法算子。

利用交替方向法更新 u_k^{n+1} 、 w_k^{n+1} 和 λ^{n+1} , 搜索增广拉格朗日表达式的鞍点, 将问题转至傅里叶域内进行简化, 对 \hat{u}_k^1 、 w_k^1 和 $\hat{\lambda}^1$ 进行初始化后, VMD 分解过程如下。

步骤 1 模式函数的更新: $u_k^{n+1}(w) \leftarrow [f(w) - \sum_{i < k} \hat{u}_i^{n+1}(w) - \sum_{i > k} \hat{u}_i^n(w) + \frac{1}{2} \hat{\lambda}^n(w)] / [1 + 2\alpha(w - w_k^n)^2]$ 。其中, \hat{u}_i 为 u_i 的傅里叶变换形。

步骤 2 中心角频率更新: $w_k^{n+1} \leftarrow \left(\int_0^\infty w |\hat{u}_k^{n+1}(w)|^2 dw \right) / \left(\int_0^\infty |\hat{u}_k^{n+1}(w)|^2 dw \right)$ 。

步骤 3 拉格朗日乘法运算符的更新: $\hat{\lambda}^{n+1}(w) \leftarrow \hat{\lambda}^n(w) + \tau \left[\hat{f}(w) - \sum_k |\hat{u}_k^{n+1}(w)| \right]$ 。

步骤 4 重复步骤 1~步骤 3, 满足终止条件 $\sum_k \left(\left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|^2 / \left\| \hat{u}_k^n \right\|^2 \right) < \varepsilon$ 后结束迭代过程。其中, \hat{u}_k 、 $\hat{\lambda}$ 分别为 u_k 、 λ 的傅里叶变换形。

1.2 锂离子电池退化数据集

本文电池数据集来自 NASA 预测中心 PCoE (prognostics center of excellence), 选取标号为 B5、B6、B7、B18 的电池作为研究对象^[7]。电池额定容量为 2.00 A·h, 在室温下进行充、放电过程: 首先以 1.5 A 恒定电流进行充电, 直到达到 4.2 V 截止电压, 然后以恒压模式充电, 直到充电电流降至 20 mA; 接下来以 2.0 A 恒定电流进行放电, 直到 B5、B6、B7、B18 电池电压分别降至 2.7、2.5、2.2、2.5 V。一般来说, 电池容量的失效阈值定义为额定容量的 70%(即 1.40 A·h), 考虑到 B7 号电池容量并未降至 1.40 A·h, 因此将其失效阈值设为 1.45 A·h。

1.3 通过 VMD 对容量序列进行降噪重构

受复杂的物理-化学反应和环境因素影响, 电池退化曲线中存在容量回升现象和噪声。为有效消除波动和噪声, 采用 VMD 对容量序列进行分解。以 B5 号电池为例, 基于 B5 号电池的分解结果如图 1 所示, 可见: 原序列分解为残差和 5 个 IMF 分量, 其中残差代表了原始容量的主要趋势, IMF 分量反映了退化过程的局部状态。采用 AC 计算模态分量与原始容量间的相关系数, 如表 1 所示。




图 1 B5 号电池 VMD 分解结果

Fig. 1 VMD decomposition result of B5 battery

表 1 B5 号电池中 IMF 分量与容量间的相关系数


Tab. 1 Correlation coefficients between IMF components and capacity for B5 battery

模态分量	相关系数
IMF1	0.111 0
IMF2	0.045 7
IMF3	0.033 0
IMF4	0.026 2
IMF5	0.021 4


设定关联阈值来判别 IMF 分量与容量间的相关性, 当分量的相关系数大于关联阈值时, 判定该分量为强相关性, 将其与残差进行组合来完成容量序列的重构。根据文献[22]中阈值设定公式 $CT = \max(IMFi)/n$ 计算的结果为 0.022 2, 表明 IMF1~IMF4 均满足要求。但由图 2 分析可知, IMF2~IMF4 的波动频率较高, 会对建模产生严重干扰。

为提高判定精度, 将阈值设定公式改进为 $CT = \left(\sum_{i=1}^n IMFi \right) / n$, 计算 $CT=0.047 46$, 该关联阈

值较之前有明显提升, 有效提高了筛选精度。参考该阈值对 B5 号电池的模态分量进行自适应筛选, 经过多次组合测试, 判定 IMF1 为强相关性, 与残差进行结合并舍弃其他分量, 完成降噪过程。对所有电池的容量序列进行重构, 电池原始容量退化曲线和重构后的降噪曲线如图 2 所示, 可见: 重构后的序列具有平滑的递减趋势, 且在去除噪声分量的基础上保留了原始数据的真实特性。



(a) NASA 电池容量退化曲线



(b) 原始容量曲线重构后结果

图 2 容量曲线重构前、后效果对比

Fig. 2 Comparison of effect before and after capacity curve reconstruction

2 基于 ISSA-ELM 的 RUL 预测模型

2.1 极限学习机原理

ELM 是 1 种典型的单隐层前馈神经网络, 设训练数据集为 (X, Y) , 其中 $X_i = [x_{i1} \ x_{i2} \ \dots \ x_{im}]^T \in R^n$, $Y_i = [y_{i1} \ y_{i2} \ \dots \ y_{im}]^T \in R^m$ 。

设 L 为隐层节点数, $h(x)$ 为激活函数, ELM 模型可表示为

$$\sum_{i=1}^L \beta_i h(w_i \cdot x_i + b_i) = o_k \quad k=1, 2, \dots, N \quad (3)$$

式中: β_i 为连接第 i 个隐层节点和输出层节点的权重; w_i 为连接输入层节点和第 i 个隐层节点的权

重; b_i 为隐层第 i 个节点的阈值; o_k 为网络的输出。

w_i 、 β_i 和 o_k 可分别表示为

$$\begin{cases} \mathbf{w}_i = [w_{i1} & w_{i2} & \cdots & w_{in}]^T \\ \boldsymbol{\beta}_i = [\beta_{i1} & \beta_{i2} & \cdots & \beta_{im}]^T \\ \mathbf{o}_k = [o_{k1} & o_{k2} & \cdots & o_{kn}]^T \end{cases} \quad (4)$$

设 ELM 输出矩阵为 \mathbf{H} , 模型结果经过一定训练时间后可接近实际输出 $\sum_{k=1}^N \|o_k - y_k\| = 0$, ELM 模型可等效为 $\mathbf{H}\boldsymbol{\beta} = \mathbf{Y}$, \mathbf{H} 可展开为

$$\mathbf{H} = \begin{bmatrix} h(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & \cdots & h(\mathbf{w}_L \cdot \mathbf{x}_1 + b_L) \\ \vdots & & \vdots \\ h(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) & \cdots & h(\mathbf{w}_L \cdot \mathbf{x}_N + b_L) \end{bmatrix}_{N \times L} \quad (5)$$

最终输出权重可计算为 $\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{Y}$, 其中 \mathbf{H}^+ 为 \mathbf{H} 的逆矩阵。

本文使用平滑降噪后的容量数据进行模型的训练和测试, 通过起点 T 将电池的整体容量序列划分为训练集(历史数据)和测试集。通过对历史数据的充分学习完成模型训练过程, 建立预测模型为

$$\hat{C}_{i+1} = \text{ELM}(C_{i-l+1}, C_{i-l+2}, \cdots, C_{i-1}, C_i) \quad (6)$$

式中: \hat{C}_{i+1} 为下一循环的容量预测值; l 为输入数据长度。将测试数据集代入式(6)进行迭代预测, 进而得出起点后每一循环的容量预测值, 从而可以计算出电池的 RUL。

为了确保 ELM 模型具有较高的预测精度和泛化能力, 必须选择合适的输入权值和隐含层阈值, 因此本文采用改进后的 SSA 优化 ELM 的相关参数。

2.2 麻雀搜索算法原理

麻雀搜索算法灵感源于麻雀的觅食和警戒行为, 第 i 只麻雀在空间中的位置可表示为 $\mathbf{X}_i = [x_{i,1}, x_{i,2}, \cdots, x_{i,d}]$ 。其中, $i = 1, 2, \cdots, N$; d 为空间维度; N 为麻雀总数。适应度矩阵为

$$\begin{cases} \mathbf{F}_X = [f(x_1) & f(x_2) & \cdots & f(x_N)]^T \\ \mathbf{f}(x_i) = [f(x_{i,1}) & f(x_{i,2}) & \cdots & f(x_{i,d})] \end{cases} \quad (7)$$

式中, $f(x_i)$ 为第 i 只麻雀的适应度值。生产者、

跟随者、警戒者位置更新公式可分别表示为

$$\begin{cases} \mathbf{x}_{i,j}^{t+1} = \begin{cases} \mathbf{x}_{i,j}^t \exp\left(\frac{-i}{\alpha \cdot \text{iter}_{\max}}\right) & R_2 < \text{ST} \\ \mathbf{x}_{i,j}^t + Q \cdot \mathbf{L} & R_2 \geq \text{ST} \end{cases} \\ \mathbf{x}_{i,j}^{t+1} = \begin{cases} Q \exp\left(\frac{x_{\text{worst}}^t - x_{i,j}^t}{i^2}\right) & i > \frac{N}{2} \\ x_e^{t+1} + |x_{i,j}^t - x_e^{t+1}| \cdot \mathbf{A}^+ \cdot \mathbf{L} & i \leq \frac{N}{2} \end{cases} \\ \mathbf{x}_{i,j}^{t+1} = \begin{cases} x_{\text{best}}^t + \beta |x_{i,j}^t - x_{\text{best}}^t| & f_i > f_b \\ x_{i,j}^t + k \left[\frac{|x_{i,j}^t - x_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right] & f_i = f_b \end{cases} \end{cases} \quad (8)$$

式中: $j = 1, 2, \cdots, d$; t 为当前迭代次数; iter_{\max} 为最大迭代次数; $\alpha \in (0, 1]$; R_2 和 ST 分别为警告值和安全值, 其中 $R_2 \in [0, 1]$, $\text{ST} \in [0.5, 1]$; Q 为遵循正态分布的随机数; \mathbf{L} 为元素值全部为 1 的 $1 \times d$ 阶矩阵; x_{worst}^t 为全局最差位置; x_e^{t+1} 为生产者在 $t+1$ 代占据的最佳位置; \mathbf{A} 为 $1 \times d$ 阶矩阵, 每个元素随机分配值 1 或 -1, 且 $\mathbf{A}^+ = \mathbf{A}^T (\mathbf{A} \mathbf{A}^T)^{-1}$; x_{best}^t 为全局最佳位置; β 为步长控制参数, 服从方差为 1、均值为 0 的正态分布; k 为步进控制参数, $k \in [-1, 1]$; f_b 和 f_w 分别为全局最佳和最差适应度值; f_i 为第 i 只麻雀的适应度值。

2.3 对 SSA 算法的改进

虽然 SSA 具有较强的优化性能, 但在处理复杂问题时搜索能力退化, 易陷入局部最优解。因此本文提出 1 种改进的 SSA 算法, 具体措施包括: 基于 Tent 混沌映射 TCM(Tent chaotic mapping)的种群初始化、通过正余弦算法 SCA(sine cosine algorithm)和 Levy 飞行 LF(levy flight)策略优化生产者 and 跟随者的位置更新公式。

2.3.1 Tent 混沌映射

SSA 的随机初始化过程对算法自身的全局搜索能力产生了限制。Tent 混沌映射具有遍历性和规律性, 采用 Tent 混沌映射来生成初始种群可以保证种群的多样性。映射表达式为

$$X_{i+1} = \begin{cases} \kappa X_i & 0 \leq X_i \leq 0.5 \\ \kappa(1 - X_i) & 0.5 < X_i \leq 1 \end{cases} \quad (9)$$

式中: X_i 为第 i 次迭代时变量的值; κ 为映射函数的参数。

2.3.2 正余弦优化算法

在有限的迭代次数下, 生产者的移动范围会逐渐缩小, 使算法全局搜索能力下降。针对此问题, 本文引入正余弦算法对生产者的位置公式进行动态调整, 以平衡全局拓展和局部优化这 2 个过程, 使 SSA 在早期具有更强的全局开发能力, 在后期具有更强的小范围搜索能力。改进后生产者位置更新公式为

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + r_1 \sin(r_2) |r_3 x_{best}^t - X_{i,j}^t| & R_2 < ST \\ X_{i,j}^t + r_1 \cos(r_2) |r_3 x_{best}^t - X_{i,j}^t| & R_2 \geq ST \end{cases} \quad (10)$$

式中: $r_1 = \chi - t\chi / \text{iter}_{\max}$, $\chi = 2$; $r_2 \in (0, 2\pi)$; $r_3 \in [0, 2]$ 。

2.3.3 Levy 飞行策略

在觅食过程中, 跟随者在生产者的引导下向目标方向移动。如果生产者受困于局部范围, 将导致所有跟随者均被吸引至该区域, 使算法过早收敛。为克服此困难, 本文引入 Levy 飞行策略对跟随者位置公式进行优化, 该策略的特点是多次小范围移动伴随偶然的长距离迁越。Levy 飞行步长 s 和改进后的跟随者位置 $x_{i,j}^{t+1}$ 可分别表示为

$$\begin{cases} s = \mu / |\beta|^{1/\beta} & 0 < \beta \leq 2 \\ \mu \sim N(0, \sigma_\mu^2), v \sim N(0, 1) \\ \sigma_\mu = \left\{ \frac{\Gamma(1+\beta) \cdot \sin(\pi\beta/2)}{\Gamma[(1+\beta)/2] \cdot \beta \cdot 2^{(\beta-1)/2}} \right\}^{1/\beta} \\ \Gamma(1+\beta) = \int_0^\infty t^\beta e^{-t} dt \\ x_{i,j}^{t+1} = \begin{cases} Q \exp\left(\frac{x_{worst}^t - x_{i,j}^t}{i^2}\right) & i > \frac{N}{2} \\ x_e^{t+1} + s |x_{i,j}^t - x_e^{t+1}| \cdot A^+ \cdot L & i \leq \frac{N}{2} \end{cases} \end{cases} \quad (11)$$

2.4 改进 SSA 算法性能测试

为验证本文算法的正确性和有效性, 选择 3 个基准函数来测试 ISSA 的性能, 并与 PSO 和 SSA 进行比较, 测试维度设置为 30。其中函数 F_1 极值

数为 1, 适用于测试算法的全局搜索能力; 而函数 F_2 、 F_3 具有多个极值, 用来检验算法的局部寻优能力, 3 个基准函数 F_1 、 F_2 、 F_3 可分别表示为

$$\begin{cases} F_1(x) = \max_i \{|x_i|, 1 \leq i \leq n\} \\ F_2(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10] \\ F_3(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \end{cases} \quad (12)$$

3 种优化算法的种群数量 N 均设置为 30, 最大迭代数 $M=100$ 。对于 SSA 和 ISSA, 生产者占比 PD 和警戒者占比 SD 统一为 20%, 安全阈值 $R_2=0.8$ 。对于 PSO, 设定参数 $C_1=C_2=1.5$, $w=0.729$ 。

选取最优值、最差值、平均值和标准差作为评价指标, 通过 3 种优化算法分别对基准函数 F_1 、 F_2 、 F_3 进行 30 次独立仿真实验, 所得测试结果见表 2。由表 2 可以看出, 对于 3 个基准函数, ISSA 的 4 个评价指标均最低, 其中最优值、最差值和均值这 3 个指标最低反映出 ISSA 的寻优能力较强, 而标准差指标最低反映出 ISSA 鲁棒性更好。由此可得, ISSA 搜索精度高且非常稳定。

为更直观体现 ISSA 算法的收敛性能, 绘制 3 种优化算法的适应度曲线, 如图 3 所示。可见, 与 PSO、SSA 相比, ISSA 曲线恒处于最下方, 表示其寻优能力最好、收敛速度最快。

表 2 测试结果

Tab. 2 Test results

测试函数	算法	最优值	最差值	平均值	标准差
F_1	PSO	0	1.15×10^{-19}	3.98×10^{-21}	2.09×10^{-20}
	SSA	0	5.26×10^{-34}	1.75×10^{-35}	9.61×10^{-35}
	ISSA	0	6.04×10^{-60}	6.22×10^{-61}	1.42×10^{-60}
F_2	PSO	3.39×10^{-5}	1.73×10^{-3}	5.77×10^{-4}	3.16×10^{-4}
	SSA	0	1.11×10^{-11}	3.72×10^{-13}	2.03×10^{-12}
	ISSA	0	0	0	0
F_3	PSO	0.74	1.33	1.01	0.14
	SSA	0	8.89×10^{-16}	2.96×10^{-17}	1.62×10^{-16}
	ISSA	0	0	0	0




图 3 3 个基准函数的收敛曲线

Fig. 3 Convergence curves for three benchmark functions

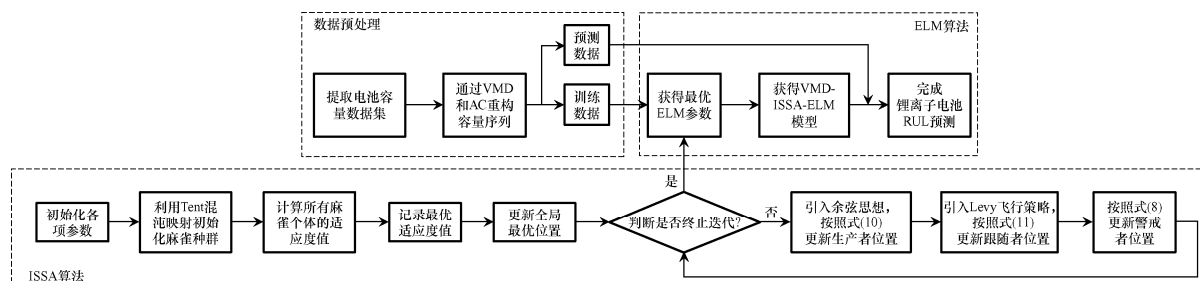


图 4 基于 VMD-ISSA-ELM 方法的锂离子电池 RUL 预测流程

Fig. 4 Flow chart of lithium-ion battery RUL prediction based on VMD-ISSA-ELM method

3 种方法基于 NASA 数据集的 RUL 预测曲线如图 5 所示, 可见: 与 PSO-ELM 和 SSA-ELM 这 2 种方法相比, VMD-ISSA-ELM 方法的容量预测曲线最接近真实退化趋势, 在不同预测条件下 RUL 计算结果误差均最小, 这说明基于 VMD-ISSA-ELM 方法的预测精度最高。

3 种方法在 NASA 数据集下的 RUL 预测效果

3 实验结果分析

为验证基于 VMD-ISSA-ELM 预测方法的优越性和鲁棒性, 将其与 PSO-ELM 和 SSA-ELM 这 2 种方法进行对比, 采用 NASA 电池数据集进行实验。为更全面地展现 VMD-ISSA-ELM 预测方法的适应性, 设定 2 个不同的预测起点 T 进行 RUL 预测, 其中 B5、B6、B7 号电池起点 1 和 2 分别为 80、100, 而 B18 号电池起点 1 和 2 分别为 65、75。采用 VMD-ISSA-ELM 方法对锂离子电池 RUL 进行预测的流程如图 4 所示。

选取绝对误差 AE (absolute error)、平均绝对误差 MAE (mean absolute error) 和均方根误差 RMSE (root mean square error) 作为预测模型的评价准则, 即

$$\begin{cases} AE = |RUL - \widehat{RUL}| \\ MAE = \frac{1}{n} \sum_{i=1}^n |x(i) - \hat{x}(i)| \\ RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [x(i) - \hat{x}(i)]^2} \end{cases} \quad (13)$$

式中: \widehat{RUL} 为 RUL 预测值; $x(i)$ 为容量真实值; $\hat{x}(i)$ 为容量预测值。MAE 和 RMSE 代表预测值与实际值的契合效果。AE、MAE 和 RMSE 的值越小, 表明预测效果越好。

其中 MAE 和 RMSE 值分别控制在 1.58%和 2.14% 以内, 最低可达 0.62%和 0.85%。

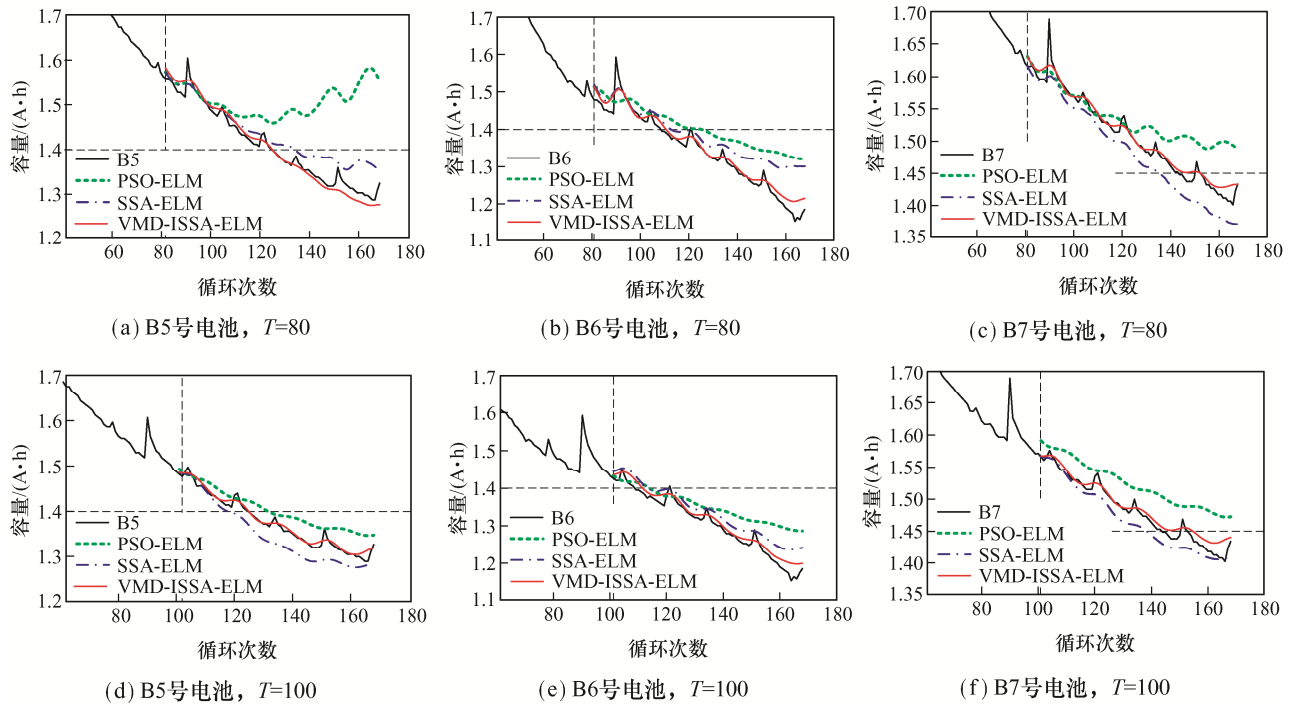


图 5 基于 NASA 数据集的电池 RUL 预测结果

Fig. 5 Prediction results of battery RUL based on NASA data sets

表 3 3 种方法在 NASA 数据集下的 RUL 预测效果对比

Tab. 3 Comparison of RUL prediction effect among three methods based on NASA data sets

电池	预测方法	起点 1 预测结果					起点 2 预测结果				
		真实 RUL/次	预测 RUL/次	AE/%	MAE/%	RMSE/%	真实 RUL/次	预测 RUL/次	AE/%	MAE/%	RMSE/%
B5	PSO-ELM	—	—	—	10.19	13.55	—	31	6	2.97	3.33
	SSA-ELM	45	54	9	2.88	3.65	25	17	8	2.70	3.07
	VMD-ISSA-ELM	—	45	0	1.34	1.71	25	0	0.62	0.85	
B6	PSO-ELM	—	36	7	6.45	7.69	—	14	5	4.78	5.99
	SSA-ELM	29	33	4	4.42	5.68	9	13	4	3.14	3.55
	VMD-ISSA-ELM	—	31	2	1.50	2.11	11	2	1.40	1.68	
B7	PSO-ELM	—	—	—	3.16	4.17	—	—	—	4.07	4.35
	SSA-ELM	63	55	8	2.59	2.95	43	38	5	1.53	1.78
	VMD-ISSA-ELM	—	67	4	0.78	1.21	47	4	0.83	1.07	
B18	PSO-ELM	—	20	12	8.07	9.65	—	14	8	5.27	6.24
	SSA-ELM	32	27	5	3.01	4.01	22	37	15	2.01	2.43
	VMD-ISSA-ELM	—	32	0	1.34	1.98	23	1	1.58	2.14	

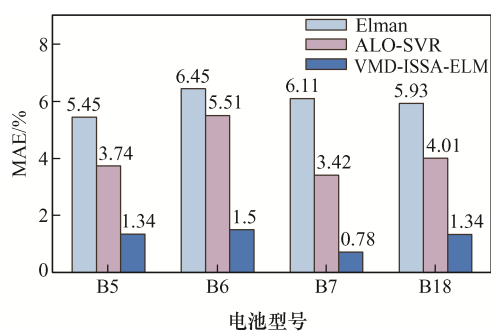
注: “—” 代指未出现预测结果。

总体结果表明, 在不同电池和不同训练数据集下, 本文所提方法可以提供较为准确的 RUL 预测。

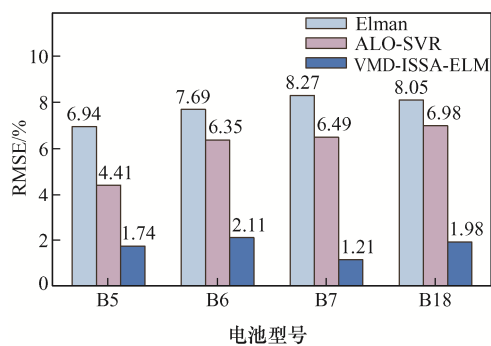
以 B5 号电池为例, VMD-ISSA-ELM 方法的 RUL 预测误差为 0, 不同起点下预测曲线的 MAE 和 RMSE

值分别为 1.34%、0.62%和 1.71%、0.85%，均为同条件下最低值。由预测结果可以判断，VMD-ISSA-ELM 方法鲁棒性良好，具有更好的电池寿命预测能力。

为进一步验证本文方法的有效性，将文献[23]和文献[4]中提到的基于 Elman 神经网络方法和 ALO-SVR 方法与本文方法进行对比。选取电池 B5、B6、B7、B18 作为实验对象，起点设置为 80 (B5、B6、B7)和 65(B18)，以预测结果的 MAE 和 RMSE 作为评判标准。3 种方法对电池 B5、B6、B7、B18 的 RUL 预测结果 MAE、RMSE 对比如图 6 所示。可见：与 Elman 方法和 ALO-SVR 方法相比，VMD-ISSA-ELM 在 RUL 预测精度和稳定性方面具有较大优势。



(a) MAE对比



(b) RMSE对比

图 6 3 种方法预测结果对比

Fig. 6 Comparison of prediction result among three methods

4 结论

本文提出 1 种基于 VMD-ISSA-ELM 方法来预

测锂离子电池的剩余使用寿命，通过创新性研究和探索得出结论如下。

(1)利用 VMD 和 AC 重构电池的容量序列，完成对原始数据的预处理，可有效降低容量回升现象的影响，避免噪声分量干扰，有效减少预测误差。

(2)通过引入 Tent 混沌映射、正余弦思想及 Levy 飞行策略，分别对 SSA 中的种群初始化过程、生产者位置更新和跟随者位置更新这 3 个关键步骤进行优化，可提高 SSA 的全局搜索能力和局部寻优能力。

(3)通过重构后的降噪数据训练 ELM 模型，结合 ISSA 寻优得到的模型最佳参数建立 VMD-ISSA-ELM 方法，并完成对电池的 RUL 预测。基于 NASA 数据集的测试实验结果表明，与其他方法相比，本文所提方法可以获得精确的 RUL 预测值，预测结果的 MAE 和 RMSE 分别在 1.58%和 2.14%内，最优值分别为 0.62%和 0.85%。

参考文献：

- [1] 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 Fang, Zhang Nan, Huang Kai. Review of state estimation and life prediction for lithiumion batteries [J]. Journal of Power Supply, 2020, 18(3): 175-183 (in Chinese).
- [2] Zhang Kai, Zhao Peng, Sun Canfei, et al. Remaining useful life prediction of aircraft lithium-ion batteries based on F-distribution particle filter and kernel smoothing algorithm [J]. Chinese Journal of Aeronautics, 2020, 33(5): 1517-1531.
- [3] 张若可, 郭永芳, 余湘媛, 等. 基于数据驱动的锂离子电池 RUL 预测综述[J]. 电源学报, 2023, 21(5): 182-190.
Zhang Ruoke, Guo Yongfang, Yu Xiangyuan, et al. Review of data-driven RUL prediction for Lithium-ion batteries [J]. Journal of Power Supply, 2023, 21(5): 182-190 (in Chinese).
- [4] 王瀛洲, 倪裕隆, 郑宇清, 等. 基于 ALO-SVR 的锂离子电池剩余使用寿命预测[J]. 中国电机工程学报, 2021, 41(4): 1445-1457.
Wang Yingzhou, Ni Yulong, Zheng Yuqing, et al. Remain-

- ing useful life prediction of lithium-ion batteries based on support vector regression optimized and ant lion optimizations [J]. Proceedings of the CSEE, 2021, 41(4): 1445-1457 (in Chinese).
- [5] 徐波, 雷敏, 王钊. 基于 TRNN 和 FA-PF 融合的锂离子电池 RUL 预测[J]. 电源学报, 2023, 21(2): 138-145.
Xu Bo, Lei Min, Wang Po. RUL prediction of lithium-ion battery based on fusion of TRNN and FA-PF [J]. Journal of Power Supply, 2023, 21(2): 138-145 (in Chinese).
- [6] Qiu Xianghui, Wu Weixiong, Wang Shuangfeng. Remaining useful life prediction of lithium-ion battery based on improved cuckoo search particle filter and a novel state of charge estimation method [J]. Journal of Power Sources, 2020, 450: 227700.
- [7] 杨战社, 王云浩, 孔晨再. 基于 GWO-SVR 的锂电池剩余使用寿命预测[J]. 电源学报, 2023, 21(2): 154-162.
Yang Zhanshe, Wang Yunhao, Kong Chenzai. Prediction of remaining useful life of lithium-ion batteries based on GWO-SVR method [J]. Journal of Power Supply, 2023, 21(2): 154-162 (in Chinese).
- [8] 刘月峰, 赵光权, 彭喜元. 多核相关向量机优化模型的锂电池剩余寿命预测方法[J]. 电子学报, 2019, 47(6): 1285-1292.
Liu Yuefeng, Zhao Guangquan, Peng Xiyuan. A lithium-ion battery remaining using life prediction method based on multi-kernel relevance vector machine optimized model [J]. Acta Electronica Sinica, 2019, 47(6): 1285-1292 (in Chinese).
- [9] Li Xiaoyu, Zhang Lei, Wang Zhenpo, 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.
- [10] Yang Hao, Wang Penglei, An Yabin, et al. Remaining useful life prediction based on denoising technique and deep neural network for lithium-ion capacitors [J]. eTransportation, 2020, 5: 100078.
- [11] Xu Xiaodong, Tang Shengjin, Yu Chuanqiang, et al. Remaining useful life prediction of lithium-ion batteries based on Wiener process under time-varying temperature condition [J]. Reliability Engineering & System Safety, 2021, 214: 107675.
- [12] Li Xiaoyu, Yuan Changgui, Wang Zhenpo. Multi-time-scale framework for prognostic health condition of lithium battery using modified Gaussian process regression and nonlinear regression [J]. Journal of Power Sources, 2020, 467: 228358.
- [13] 张婷婷, 于明, 李宾, 等. 基于 Wavelet 降噪和支持向量机的锂离子电池容量预测研究[J]. 电工技术学报, 2020, 35(14): 3126-3136.
Zhang Tingting, Yu Ming, Li Bin, et al. Capacity prediction of lithium-ion batteries based on Wavelet noise reduction and support vector machine [J]. Transactions of China Electrotechnical Society, 2020, 35(14): 3126-3136 (in Chinese).
- [14] Ma Yanying, Wu Lifeng, Guan Yong, et al. The capacity estimation and cycle life prediction of lithium-ion batteries using a new broad extreme learning machine approach [J]. Journal of Power Sources, 2020, 476: 228581.
- [15] 陈则王, 李福胜, 林娅, 等. 基于 GA-ELM 的锂离子电池 RUL 间接预测方法[J]. 计量学报, 2020, 41(6): 735-742.
Chen Zewang, Li Fusheng, Lin Ya, et al. Indirect prediction method of RUL for lithium-ion battery based on GA-ELM [J]. Acta Metrologica Sinica, 2020, 41(6): 735-742 (in Chinese).
- [16] Xue Jiankai, Shen Bo. A novel swarm intelligence optimization approach: Sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [17] 李雅丽, 王淑琴, 陈倩茹, 等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用, 2020, 56(22): 1-12.
Li Yali, Wang Shuqin, Chen Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms [J]. Computer Engineering and Applications, 2020, 56(22): 1-12 (in Chinese).
- [18] Zhu Yanlong, Yousefi N. Optimal parameter identification of PEMFC stacks using adaptive sparrow search algorithm [J]. International Journal of Hydrogen Energy, 2021, 46(14): 9541-9552.
- [19] Liu Bo, Rodriguez D. Renewable energy systems optimization by a new multi-objective optimization technique: A residential building [J]. Journal of Building Engineering, 2021, 35: 102094.

- [20] Zhou Shenghang, Xie Hao, Zhang Chuncheng, et al. Wavefront-shaping focusing based on a modified sparrow search algorithm [J]. *Optik*, 2021, 244: 167516.
- [21] Xu Bo, Zhou Fengxing, Li Huipeng, et al. Early fault feature extraction of bearings based on Teager energy operator and optimal VMD [J]. *ISA Transactions*, 2019, 86: 249-265.
- [22] 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 Tianzhong, Yu Jianbo. 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 (in Chinese).
- [23] Li Wenhua, Jiao Zhipeng, Du Le, et al. An indirect RUL prognosis for lithium-ion battery under vibration stress

using Elman neural network [J]. *International Journal of Hydrogen Energy*, 2019, 44(23): 12270-12276.



丁恒

作者简介:

丁恒(1997—), 男, 硕士研究生。研究方向: 电器可靠性理论及检测技术、储能电池组建模及寿命预测等。E-mail: 1377752790@qq.com。

黄凯(1980—), 男, 中国电源学会会员, 通信作者, 博士, 副教授。研究方向: 电器可靠性理论及检测技术、储能电池组健康状态预测与可靠性评估。E-mail: huangkai@hebut.edu.cn。

田海建(1995—), 男, 硕士研究生。研究方向: 电器可靠性理论及检测技术、储能电池组建模及寿命预测。E-mail: 1843718316@qq.com。

