

DOI: 10.19783/j.cnki.pspc.230297

# 基于混合 ISSA-LSTM 的锂离子电池剩余使用寿命预测

邹红波<sup>1,2</sup>, 柴延辉<sup>2</sup>, 杨钦贺<sup>2</sup>, 陈俊廷<sup>2</sup>

(1. 新能源微电网湖北省协同创新中心(三峡大学), 湖北 宜昌 443002;

2. 三峡大学电气与新能源学院, 湖北 宜昌 443002)

**摘要:** 准确预测锂离子电池剩余使用寿命(remaining useful life, RUL)对降低电池使用风险和维护设备稳定性方面具有重要意义。为了提高锂离子电池 RUL 预测的稳定性和结果的准确性, 提出一种基于混合改进麻雀搜索算法(improved sparrow search algorithm, ISSA)与长短期记忆(long short-term memory, LSTM)神经网络的锂电池 RUL 预测模型。首先, 用均值化方法对原始数据中的异常值进行处理。然后, 结合 Tent 混沌映射、自适应权重以及反向学习策略和柯西变异扰动策略优化麻雀搜索算法, 再利用改进麻雀搜索算法对 LSTM 模型的参数进行优化。最后, 采用改进的混合 ISSA-LSTM 模型并完成 RUL 预测。采用 NASA 公开数据集对本模型进行验证。结果表明, 该模型的平均绝对误差、均方根误差和平均相对百分比误差控制在 0.016 47、0.022 84 和 1.2048% 以内, 能够有效地提高锂离子电池 RUL 的预测精度。

**关键词:** 锂离子电池; 剩余使用寿命预测; 混合改进麻雀搜索算法; 长短期记忆神经网络; 均值化

## Remaining useful life prediction of lithium-ion batteries based on hybrid ISSA-LSTM

ZOU Hongbo<sup>1,2</sup>, CHAI Yanhui<sup>2</sup>, YANG Qinhe<sup>2</sup>, CHEN Junting<sup>2</sup>

(1. Hubei Provincial Collaborative Innovation Center for New Energy Microgrid (China Three Gorges University),

Yichang 443002, China; 2. College of Electric Engineering and Renewable Energy,

China Three Gorges University, Yichang 443002, China)

**Abstract:** Accurate prediction of the remaining useful life (RUL) of lithium-ion batteries is of great significance to reduce the risk of battery use and maintain the stability of equipment. To improve the stability and accuracy of RUL prediction of the lithium-ion battery, this paper proposes an RUL prediction model based on the hybrid improved sparrow search algorithm (ISSA) and long short-term memory (LSTM) neural network. First, the outliers in the original data are decomposed using averaging. Second, a Tent chaotic map, adaptive weight, an opposition-based learning strategy, and the Cauchy variation perturbation strategy are combined to optimize the sparrow search algorithm. The parameters of the LSTM model are optimized by the improved sparrow search algorithm. Finally, the improved hybrid ISSA-LSTM model is used to complete the RUL prediction. The NASA public data set is used to verify the model. The experimental results show that the mean absolute, root mean square, and average relative percentage errors of the model are controlled within 0.016 47, 0.022 84, and 1.2048%, which can effectively improve the prediction accuracy of the RUL of lithium-ion batteries.

This work is supported by the National Natural Science Foundation of China (No. 52107108).

**Key words:** lithium-ion battery; RUL prediction; hybrid improved sparrow search algorithm; long short-term memory neural network; averaging

## 0 引言

锂离子电池因具有使用寿命周期长、能量密度

高、环境污染小等优点<sup>[1-3]</sup>, 是目前最受欢迎的新能源之一, 广泛应用于电子设备、电动汽车、航空航天等电气系统的动能来源<sup>[4-6]</sup>。锂离子电池在连续的充电与放电循环使用中, 其内部会伴随发生一系列相关的物理化学反应<sup>[7]</sup>, 具体表现为电池放电电压

基金项目: 国家自然科学基金项目资助(52107108)

逐渐降低和内阻逐渐增大<sup>[8]</sup>,从而出现老化等故障,严重时甚至会危及人身安全、导致严重事故的发生<sup>[9]</sup>。因此,准确地预测和估计电池剩余使用寿命(remaining useful life, RUL)对于提高锂离子电池运行系统的可靠性和安全性非常重要<sup>[10]</sup>。

目前,对于锂离子电池 RUL 的预测主要有基于模型和数据驱动两种方法<sup>[11-12]</sup>。基于模型的预测往往需要通过分析电池内部相关的物理化学反应,搭建数学模型或物理模型,利用模型来描述锂离子电池的性能退化原理,如建立电路的等效模型和电化学模型来完成电池 RUL 预测。文献[13]通过构建电化学模型,用模型来分析锂离子电池内部参数来完成 RUL 预测,但因电化学反应是一个动态和非线性的过程,因此要获得一个精确的预测模型是十分困难的。文献[14]等效电路模型对实现锂离子电池的 RUL 预测取得了相对较好的效果。文献[15]基于扩展卡尔曼滤波算法解决了不确定噪声带来的影响,提高了电池模型的预测精度。文献[16]利用改进的双极化算法建立等效电路模型。尽管这几年基于模型的方法取得了很大的进展,但是此类模型结构复杂,易受外界环境等因素的动态影响,且需要大量的物理先验知识,同时电池 RUL 的预测精度依赖于模型参数的设置,建立精确的退化预测模型有较大的困难,因此存在一定的局限性。

针对模型本身存在的不足,当前大多研究使用数据驱动方法进行预测研究。该类方法摆脱了对电池内部结构的依赖,通过对电池充电与放电过程的实验数据进行研究,利用深度学习神经网络算法构建退化特征趋势的前后映射关系,实现电池 RUL 预测。文献[17]通过支持向量机算法建立锂离子电池 RUL 预测模型,克服了算法局部最优值问题,并增强了模型预测结果的准确性。文献[18]使用改进的极限学习机算法,增强了模型的有效性,提高了学习速度,更好地解决了传统模型收敛速度慢和易陷入局部最优解的问题,提高了模型的寻优性能。文献[19]通过锂离子电池容量退化数据作为输入,使用循环神经网络(recurrent neural network, RNN)算法建立预测模型,较好地实现了对锂离子电池退化数据的预测。但由于 RNN 本身具有梯度爆炸的特点,导致模型训练困难。文献[20]利用长短时记忆(long short-term memory, LSTM)神经网络较为准确地预测了锂离子电池寿命的衰减和退化问题,很好地解决了训练过程中梯度消失和梯度爆炸的问题。在锂离子电池 RUL 预测过程中, LSTM 神经网络不仅可以处理时序预测问题,还可以保证模型的预测精度。

麻雀搜索算法(sparrow search algorithm, SSA)是近几年提出的一种新的智能优化算法,其来源于动物界麻雀种群的觅食行为和反捕食行为。与传统的灰狼优化算法、引力搜索算法、粒子群算法等智能算法相比,SSA 具有更强的寻优能力、更快的收敛速度和更好的鲁棒性<sup>[21]</sup>。文献[22]通过实验证明 SSA 在收敛速度、精度和稳定性方面具有优越性,但是种群初始化问题和容易陷入局部最优解是大多数智能算法的共性<sup>[23]</sup>。为了解决种群初始化和容易陷入局部最优解情况的发生,需要对原始 SSA 进行改进以提高其性能。文献[24]利用 singer 混沌映射对麻雀种群个体初始位置进行优化,提高了全局的搜索能力。文献[25]将正余弦算法与反向学习算法交替执行增强算法的探索能力,提高了算法局部寻优和全局搜索的能力,使该算法的寻优能力得到提升。

针对上述模型方法本身存在的缺陷和不足,本文提出了一种混合 ISSA-LSTM 的锂离子电池 RUL 的预测模型。首先选择锂离子电池的容量作为反映退化趋势的输入特征,对原始数据的异常值采用均值化方式进行处理;然后,通过引入 Tent 混沌映射、自适应权重、反向学习策略和柯西变异扰动策略分别对种群初始化,对发现者位置更新,对麻雀种群的最优解进行改进并得到改进后的混合 ISSA 算法。最后,利用混合 ISSA 算法对 LSTM 的相关参数进行优化,完成模型搭建并实现锂离子电池 RUL 的预测。实验结果表明,在基于 NASA 锂离子电池数据集的剩余使用寿命预测中,与传统的方法相比,本文提出的混合 ISSA-LSTM 模型对锂离子电池 RUL 具有更好的预测效果,能够很好地应用于锂离子电池寿命研究领域。

## 1 麻雀搜索算法及其改进

### 1.1 麻雀搜索算法

麻雀搜索算法是通过将麻雀种群觅食行为和反捕食行为进行深入研究,将麻雀种群中不同的个体进行分类,以种群中个体位置的不断更新实现算法智能优化的目的。麻雀种群中第  $i$  只麻雀在空间中的位置表示为  $\mathbf{X}_i = (x_{i,1}, x_{i,2}, \dots, x_{i,D})$ , 其中  $i = 1, 2, \dots, N$ ;  $N$  为麻雀种群的个数;  $D$  为麻雀种群的维数,在数值上与 LSTM 神经网络的待优化参数一致。麻雀种群的适应度值矩阵  $\mathbf{F}_X$  表示为

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

式中:  $f(x_i)$  为麻雀种群中第  $i$  只麻雀的适应度值;  $f(x_{i,D})$  为维度为  $D$  时第  $i$  只麻雀的适应度值。

发现者的位置更新式为

$$x_{i,j}^{t+1} = \begin{cases} x_{i,j}^t \cdot \exp\left(-\frac{i}{\alpha \cdot T_{\max}}\right), & R_2 < R_{ST} \\ x_{i,j}^t + Q \times L, & R_2 \geq R_{ST} \end{cases} \quad (2)$$

式中:  $t$  和  $T_{\max}$  分别为当前迭代次数和设定的最大迭代次数;  $\alpha$  为一个随机变量,  $\alpha \in (0,1)$ ;  $Q$  为服从正态分布的随机数;  $R_2$  和  $R_{ST}$  分别为麻雀种群的警戒值和安全值;  $L$  为一个  $1 \times D$  维的矩阵;  $\exp$  为函数符号。

跟随者的位置更新式为

$$x_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_w^t - x_{i,j}^t}{i^2}\right), & i > \frac{N}{2} \\ x_e^{t+1} + |x_{i,j}^t - x_e^{t+1}| \cdot A^+ \cdot L, & i \leq \frac{N}{2} \end{cases} \quad (3)$$

式中:  $x_w^t$  为当前全局最差位置;  $x_e^{t+1}$  为麻雀种群中生产者在  $t+1$  代占据的最佳位置;  $A$  为每个元素随机为 1 或 -1 的  $1 \times D$  维的矩阵, 且  $A^+ = A^T(AA^T)^{-1}$ 。

警戒者的位置更新式为

$$x_{i,j}^{t+1} = \begin{cases} x_b^t + \beta \cdot |x_{i,j}^t - x_b^t|, & f_i > f_b \\ x_{i,j}^t + \zeta \left( \frac{|x_{i,j}^t - x_w^t|}{(f_i - f_w) + \varepsilon} \right), & f_i \leq f_b \end{cases} \quad (4)$$

式中:  $x_b^t$  为全局最优位置;  $\beta$  为步长控制参数;  $\zeta$  为麻雀种群个体飞行方向的步进调整系数, 且  $\zeta \in (-1,1)$ ;  $f_i$  为麻雀种群中第  $i$  只麻雀的适应度值;  $f_w$  和  $f_b$  分别为麻雀种群当前迭代次数下的全局最差值和全局最优适应度值;  $\varepsilon$  为常数, 其作用是用来避免分母为 0。

## 1.2 改进混合 ISSA 算法

SSA 与传统的智能算法相比, 虽具有较好的寻优性能, 但直接将 SSA 应用到电池 RUL 预测这样一个非线性且复杂的问题中, 同时又存在多个局部最优解。这些解对应的参数组合都能达到一个较好的预测效果, 在迭代过程中容易被其中一个最优解吸引, 从而忽略了其他可能的最优解, 很容易陷入局部最优的困境<sup>[26]</sup>, 导致算法无法在寻优过程中体现全局搜索的能力, 不能进一步提高锂离子电池 RUL 预测模型的预测精度。因此, 本文提出一种改进措施, 具体包括: 利用 Tent 混沌映射对麻雀种群进行初始化, 通过自适应权重、反向学习策略和柯西变异扰动策略, 优化发现者位置, 更新麻雀种群的最优解。

### 1.2.1 Tent 混沌映射

原始 SSA 的随机初始化过程限制了算法本身

的全局搜索能力。基于 Tent 混沌映射具有均匀性和遍历性的特点, 利用 Tent 混沌映射来生成麻雀种群个体初始的位置信息, 可以保证麻雀种群的多样性, Tent 映射表达式为

$$X_{i+1} = \begin{cases} X_i, & X_i \in (0, \gamma] \\ \gamma, & X_i \in (\gamma, 1] \\ \frac{1-X_i}{1-\gamma}, & X_i \in (\gamma, 1] \end{cases} \quad (5)$$

式中:  $X_i$  为第  $i$  次迭代时的映射函数值;  $\gamma$  为混沌系数。

### 1.2.2 自适应权重

从迭代循环开始时, 麻雀种群中的发现者就开始向全局最优解附近逐步靠近, 从而导致寻优空间有限, 容易陷入局部最优空间, 造成种群寻优精度下降。针对这一问题, 本文在麻雀种群的发现者公式中引入前一次迭代的全局最优解, 使得关于发现者的位置信息不仅受前一次循环种群发现者信息变化的影响, 而且也受前一次循环的全局最优解影响, 这样可以避免算法陷入局部最优<sup>[27]</sup>。另外, 受惯性权重的影响, 将动态权重因子引入到种群发现者的位置更新公式中。为了能够更好地进行全局搜索, 应在迭代初期使初始值相对较大, 在迭代后期逐渐减小, 以便更好地展开局部空间搜索, 提高种群的收敛速度。权重系数和改进后的种群发现者的位置更新公式为

$$\omega = \tanh\left(2\left(1 - \frac{t}{T_{\max}}\right)\right) \quad (6)$$

$$x_{i,j}^{t+1} = \begin{cases} (x_{i,j}^t + \omega(f_{j,g}^t - x_{i,j}^t))k, & R_2 < R_{ST} \\ x_{i,j}^t + Q, & R_2 \geq R_{ST} \end{cases} \quad (7)$$

式中:  $\omega$  为权重系数;  $f_{j,g}^t$  为上一代中种群第  $j$  维的全局最优解;  $\tanh$  为函数符号;  $k$  为  $[0,1]$  内的随机数。

### 1.2.3 反向学习策略和柯西变异扰动策略

反向学习基于当前解决方案, 使用反向学习规则找到相应的反向解决方案, 进行对比和评估以获得更好的解决方案并保存。为了使种群个体能够更迅速地找到最优解的解决方案, 反向学习被集成到麻雀算法中, 模型为

$$x_b'(t) = u_{ub} + r \oplus (u_{lb} - x_b(t)) \quad (8)$$

$$x_{i,j}^{t+1} = x_b'(t) + h \oplus (x_b(t) - x_b'(t)) \quad (9)$$

$$h = \left(T_{\max} - \frac{1}{T_{\max}}\right)^t \quad (10)$$

式中:  $x_b'(t)$  为第  $t$  代麻雀最优解的反向解决方案;  $u_{ub}$  和  $u_{lb}$  分别为最优解  $x_b(t)$  的上限和下限;  $r$  为

服从(0, 1)标准均匀分布的 $1 \times D$ 维随机变量矩阵;  
 $x_b(t)$ 为第 $t$ 代麻雀种群的最优解; $h$ 为信息控制交  
换变量。

柯西变异扰动策略是在最优解的位置运用柯西  
变异算子进行扰动变异得到最新解,改善了算法陷  
入局部区域的缺陷。在目标更新公式中引入柯西变  
异,通过柯西算子对目标位置扰动,使算法的全局  
搜索性能得到提高,数学模型为

$$x_{i,j}^{t+1} = x_b(t) + c(0,1) \oplus x_b(t) \quad (11)$$

式中, $c(0,1)$ 为标准柯西分布。

为了更好地提高算法的搜索性能,本文利用动  
态选择策略,在一定概率下动态选择反向学习策略  
和柯西变异扰动策略,然后再确定更新目标位置。  
至于采取何种策略更新目标位置,取决于选择概率  
 $P_y$ 。数学公式为

$$P_y = -\exp\left(1 - \frac{t}{T_{\max}}\right)^{20} + \eta \quad (12)$$

式中, $\eta$ 为可进行调整的定参,多数取0.05。

若 $k < P_y$ ,用反向学习策略更新目标位置,反  
之用柯西变异扰动策略更新目标位置。尽管反向学  
习策略和柯西变异扰动策略能够增强算法跳出局部  
极值的能力,但不能确定优化后获取的新值是否  
比原始位置的适应度值好。对此在扰动变异结束之  
后,需要引入贪婪模型,对新值和原始位置的适应  
度值进行比较,再确定是否进行目标位置更新。贪  
婪模型为

$$x_b = \begin{cases} x_{i,j}^{t+1}, & f(x_{i,j}^{t+1}) < f(x_b) \\ x_b, & f(x_{i,j}^{t+1}) \geq f(x_b) \end{cases} \quad (13)$$

式中, $f(x)$ 为 $x$ 位置的适应度值。

### 1.3 改进混合 ISSA 算法性能测试

为了充分验证算法的正确性和有效性,通过选  
择4个基准测试函数,比较混合ISSA与粒子群算  
法(particle swarm optimization, PSO)和SSA的性  
能。测试函数包括单峰和多峰函数,测试维度设置  
为30。4个基准测试函数取值范围和最优解信息  
如表1所示。

表1 4种基准测试函数

Table 1 Four benchmark functions

函数	类型	取值范围	最优解
$F_1$	Sphere	[-100,100]	0
$F_2$	Schwefel's 2.22	[-10,10]	0
$F_3$	rastrigin	[-5.12,5.12]	0
$F_4$	Grienwank	[-600,600]	0

3种优化算法种群数量设置为30,最大迭代次  
数 $T_{\max}$ 设置为100。对于PSO,学习因子 $C_1$ 和 $C_2$ 的

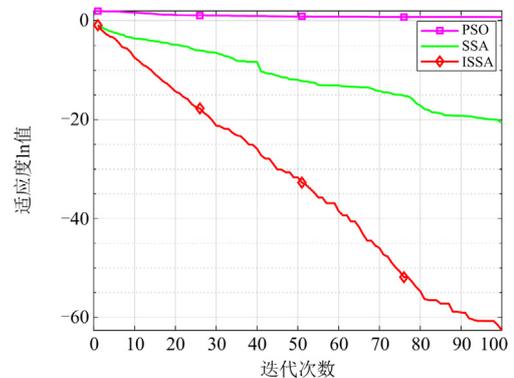
参数大小均设置为1.5。对于混合ISSA和SSA,种  
群发现者占比 $R_{pD}$ 和预警者占比 $R_{sD}$ 均设置为20%,  
警戒值 $R_2$ 设置为0.8,调整参数 $\eta$ 设置为0.05。

选取最差值、平均值和标准差作为评价指标,3  
种优化算法分别对基准测试函数 $F_1$ 、 $F_2$ 、 $F_3$ 、 $F_4$   
进行50次独立仿真实验,得到的测试结果如表2所  
示。从表2可以看出,对于4个基准测试函数,混合  
ISSA算法的评价指标均为最低。其中,最差值和平均  
值指标最低表示混合ISSA算法有较强寻优能力,  
标准差指标最低表示混合ISSA算法有更好的鲁棒  
性,因此可以得出混合ISSA算法搜索精度高且非  
常稳定。为了更直观地反映混合ISSA智能算法的  
收敛性能,3种优化算法的适应度值收敛曲线如图  
1所示。由图1可知,与PSO和SSA算法相比,混  
合ISSA算法的收敛曲线位于最下方且值最小,说  
明收敛速度最快。算法的适应度值在达到最优值  
后将不随迭代次数的增加而继续收敛变化。在图  
1(c)中ISSA在约15次迭代后收敛到最优值,而  
SSA在约36次迭代后收敛到最优值;同理在图  
1(d)中ISSA

表2 4种基准测试函数的测试结果

Table 2 Test results for the four benchmark functions

基准测 试函数	算法	最差值	平均值	标准差
$F_1$	PSO	6.582	2.914	1.151
	SSA	$1.087 \times 10^{-19}$	$2.174 \times 10^{-21}$	$1.537 \times 10^{-20}$
	ISSA	$1.2874 \times 10^{-61}$	$2.5749 \times 10^{-63}$	$1.821 \times 10^{-62}$
$F_2$	PSO	0.0329	0.0123	0.004 98
	SSA	$8.398 \times 10^{-19}$	$1.892 \times 10^{-20}$	$1.189 \times 10^{-19}$
	ISSA	$4.737 \times 10^{-64}$	$2.149 \times 10^{-65}$	$9.434 \times 10^{-65}$
$F_3$	PSO	466.354	307.799	56.530
	SSA	0	0	0
	ISSA	0	0	0
$F_4$	PSO	230.894	98.778	45.505
	SSA	0	0	0
	ISSA	0	0	0



(a) 测试函数 $F_1$

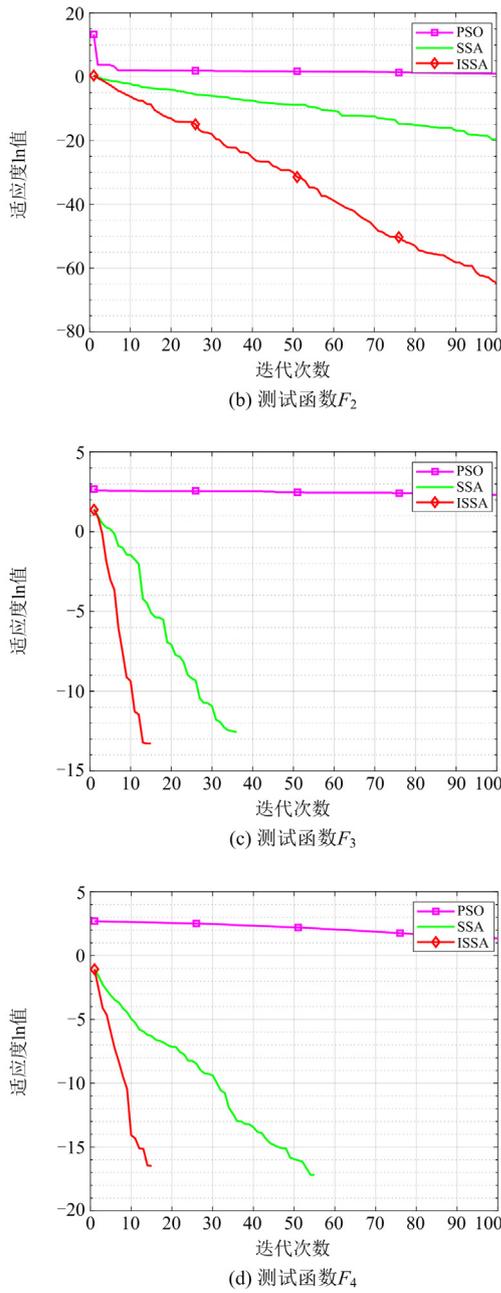


图 1 4 个基准测试函数适应度值的收敛曲线

Fig. 1 Convergence curves of fitness values of four benchmark functions

在约 14 次迭代后收敛到最优值, 而 SSA 在约 55 次迭代后收敛到最优值。

## 2 LSTM 神经网络模型

对于锂电池容量数据, 其前后数据之间是有一定关联的, 要挖掘内层看不见的关联。锂电池 RUL 预测过程实际是对电池历史上放电数据时间序列的分析, 时间序列越长, 分析的电池历史数据越多,

预测精度越准确。传统的 RNN 不能很好地处理长时间序列问题, LSTM 神经网络作为 RNN 的一种优化改进算法, 该算法不仅解决了 RNN 网络反向传播梯度消失的难点, 还保留了长短时间序列的依赖关系。

在 LSTM 中, 每个节点都包含一个记忆单元和 3 个门(输入门、遗忘门和输出门), 这些门控制着信号的流动。当输入信号进入 LSTM 时, 输入门会决定哪些信息需要被加入到记忆单元中, 遗忘门会决定哪些信息需要从记忆单元中删除, 输出门会决定什么时候把记忆单元中的信息输出。当出现容量突增点时, LSTM 的记忆单元可以存储更多的信息, 并且输入门可以选择性地将更多的信息加入到记忆单元中。因此, LSTM 可以更好地适应容量突增点的预测。此外, 本文对 LSTM 通过堆叠多个 LSTM 层来增加模型的容量, 从而提高模型的预测能力, 使得模型可以学习更复杂的时间序列模式。总之, LSTM 通过记忆单元和门的设计, 可以有效地处理容量突增点的预测问题。LSTM 单元结构如图 2 所示。

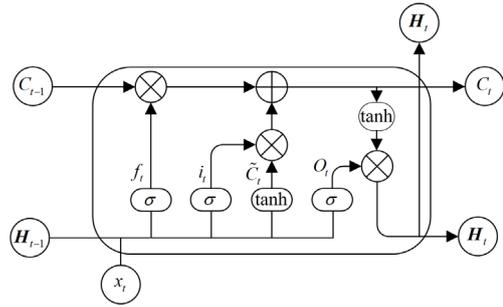


图 2 LSTM 单元结构

Fig. 2 LSTM cell structure

LSTM 单元结构通过对其遗忘门、输入门和输出门等门控结构来有效地保存和控制单元状态更新, 更新规则如式(14)所示。门控单元的实现如式(14)一式(19)所示。

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (14)$$

$$f_t = \sigma(W_f[H_{t-1}, x_t] + b_f) \quad (15)$$

$$i_t = \sigma(W_i[H_{t-1}, x_t] + b_i) \quad (16)$$

$$\tilde{C}_t = \tanh(W_c[H_{t-1}, x_t] + b_c) \quad (17)$$

$$O_t = \sigma(W_o[H_{t-1}, x_t] + b_o) \quad (18)$$

$$H_t = O_t \cdot \tanh(C_t) \quad (19)$$

式中:  $C_t$ 、 $C_{t-1}$  和  $\tilde{C}_t$  分别表示当前时刻的单元状态、上一时刻的单元状态和输出层的单元状态;  $f_t$ 、 $i_t$  和  $O_t$  分别表示门控结构中遗忘、输入和输出等结构的输出;  $\sigma$  为 Sigmoid 激活函数;  $W_f$ 、 $W_i$ 、 $W_c$  和  $W_o$

分别为该门对应的权重参数矩阵； $H_{i-1}$  为上一单元隐藏层输出； $x_i$  为当前单元的输入； $b_f$ 、 $b_i$ 、 $b_c$  和  $b_o$  分别为该门对应的偏置量参数矩阵； $[\ ]$  为向量连接。

### 3 基于混合 ISSA-LSTM 的锂离子电池 RUL 预测模型

#### 3.1 数据集

在实际应用中，由于测量误差、传感器噪声等因素影响，通过安时积分计算得到的容量数据可能也会存在一定的误差。如果这些误差被纳入到训练数据中，那么 LSTM 模型就会学习到这些误差，从而导致误差的迭代。这些误差并非人为因素同时又不可避免，只能尽可能地减小误差对预测结果的影响。为了减小容量数据误差的影响，本文通过使用阶梯电流充放电方法来减小锂电池容量数据误差，同时采用了容量校准方法来校准电池容量数据。

本文锂离子电池数据集来自于 NASA 锂电池充放电实验数据，选取 B0005、B0006、B0007、B0018 4 组电池作为锂离子电池的实验对象。该类型锂电池额定容量为 2 Ah，可以在常温环境下进行充电与放电。先用 1.5 A 的稳定电流充电，直至电压达到截止电压 4.2 V，紧接着用稳定电压充电，使电池充电电流下降到 20 mA，之后用 2 A 稳定电流继续放电，直至电池 B0005、B0006、B0007 和 B0018 的电压分别降到 2.7 V、2.5 V、2.2 V 和 2.5 V。一般来说，当锂离子电池的有效容量不足额定电池容量的 70% 时，作为电池容量的失效阈值。图 3 为 4 组锂离子电池容量衰减变化情况。图 3 中锂离子电池容量突变的原因是电池在不使用时发生的化学和物理反应，该反应过程会导致电池内部的锂离子片刻再生，从而引起锂离子电池容量发生突增，同时也会导致同种电池初始容量有差异的情况。

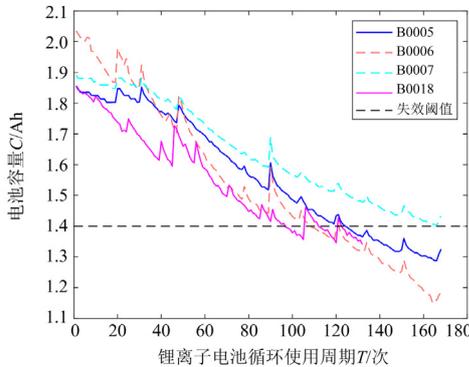


图 3 4 组锂离子电池容量衰减情况

Fig. 3 Capacity attenuation of four groups of lithium-ion batteries

#### 3.2 数据预处理

锂离子电池组原始数据中存在异常值。因为不能直接对数据进行挖掘分析，所以在预测模型建立之前，需要对原始的实验数据进行数据预处理，使模型的预测精度尽可能地避免被数据中的异常值影响。实验选择该异常值左右分别 10 个数据的和的平均值来代替。即

$$z_i = \frac{(z_{i-10} + \dots + z_{i-1}) + (z_{i+1} + \dots + z_{i+10})}{20} \quad (20)$$

式中： $z_i$  为异常值的代替值； $z_{i-1}$  为异常值的左一个实验值； $z_{i+1}$  为异常值的右一个实验值。

由于实验数据容易被外部环境和偶然性因素影响，不能将数据直接看作模型的输入条件，因此每个循环内的实验数据需要均值化，以此得到可以作为输入的数据。均值化处理后的实验数据既可作为模型的输入变量，也可减少外部不定变量的影响。计算公式为

$$\bar{z} = \frac{1}{n} \sum_{i=1}^n m_i \quad (21)$$

式中： $\bar{z}$  为每次循环内的均值； $n$  为每次循环内的样本个数； $m_i$  为实验样本数据。

本文在锂电池容量数据集的基础上，对各电池的完整放电过程构造放电容量测试样本集，同时在训练集中进一步划分训练和测试，选取 60% 的数据作为训练集，40% 的数据作为测试数据。

#### 3.3 混合 ISSA-LSTM 模型

LSTM 方法的预测精度取决于其参数的确定，为了实现参数的自动寻优，需要优化算法对 LSTM 网络进行优化。在 Matlab 2018a 的环境下，利用改进的麻雀搜索算法对 LSTM 神经网络的参数进行优化，构成混合 ISSA-LSTM 优化模型。图 4 为使用混合 ISSA-LSTM 模型对锂离子电池 RUL 进行预测的实验流程图。

模型预测的主要步骤如下。

步骤 1：数据预处理。对原始电池容量数据进行均值化处理，去除数据中的异常值。然后，将去除异常值后的数据分为实验训练数据和测试数据。

步骤 2：对麻雀种群的各项参数进行初始化，如种群个数  $N$ 、最大迭代次数  $T_{\max}$ 、种群发现者占比  $R_{PD}$  等，麻雀种群通过 Tent 映射进行初始化。

步骤 3：计算麻雀种群中麻雀个体适应度值，得到最优的麻雀适应度值和它们的位置。

步骤 4：从最优的麻雀适应度值中，随机选取一些麻雀个体当作发现者，同时用式(7)进行发现者的位置更新。

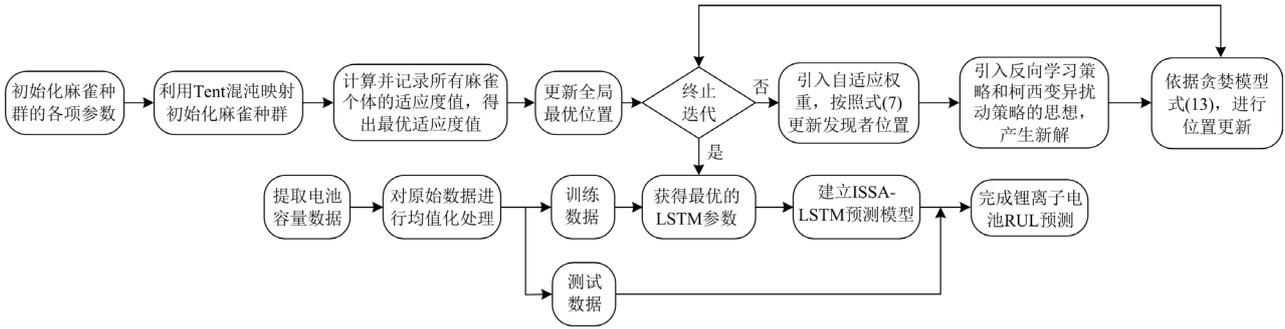


图 4 混合 ISSA-LSTM 模型对锂离子电池 RUL 进行预测的实验流程图

Fig. 4 Flowchart of the experiment of the hybrid ISSA-LSTM model to predict the RUL of lithium-ion batteries

步骤 5: 通过引入反向学习策略和柯西变异扰动这两种策略, 根据选择概率  $P_y$ , 判断对目前最优解的麻雀个体使用何种策略, 并得到新解。

步骤 6: 通过贪婪模型式(13), 判断是否继续进行麻雀种群位置更新。

步骤 7: 在满足混合 ISSA 算法设定达到的迭代误差或最大迭代次数的终止迭代条件后, 选取参数的最优值进行训练、预测以及优化 LSTM 神经网络模型。若不满足终止迭代条件, 则转到步骤 4 继续迭代。

步骤 8: 利用混合 ISSA 优化后的 LSTM 神经网络模型对锂离子电池 RUL 进行预测。

### 3.4 基于混合 ISSA 的参数优化

通过对锂电池数据集的划分, 得到验证集。利用验证集确定混合 ISSA-LSTM 模型的参数。混合 ISSA-LSTM 模型参数的搜索范围设置为: 隐藏层  $L_1$  的神经元数量  $L_1 \in [1, 100]$ , 隐藏层  $L_2$  的神经元数量  $L_2 \in [1, 100]$ , 训练次数  $K \in [1, 50]$ , 学习率  $l_r \in [0.001, 0.01]$ 。通过混合 ISSA 在验证集上找到模型的最优参数, 如表 3 所示。

表 3 参数最优值

Table 3 Optimal value of parameter

参数	$L_1$	$L_2$	$K$	$l_r$
数值	63	67	41	0.0055

## 4 实验结果分析

为了验证基于混合 ISSA-LSTM 预测模型的优越性, 实验利用 NASA 电池数据集中的 4 种锂离子电池 B0005、B0006、B0007 和 B0018 的容量数据, 并用 LSTM、PSO-LSTM 和 SSA-LSTM 这 3 种方法进行对比。为了更全面地展现基于混合 ISSA-LSTM 预测模型的有效性, 实验中分别以 50% 和 60% 的锂离子电池容量实验数据为训练数据, 其余的 50% 和 40% 的容量实验数据为测试数据, 即电池 B0005、

B0006 和 B0007 的训练样本的预测起点分别为 90 和 105, 电池 B0018 的训练样本的预测起点分别为 72 和 84, 预测过程中锂离子电池容量的失效阈值设置为电池额定容量的 70%, 即 1.4 Ah。

选取平均绝对误差  $E_{MAE}$ 、均方根误差  $E_{RMSE}$  和平均绝对百分比误差  $E_{MAPE}$  作为预测模型的评价指标, 如式(22)一式(24)所示。

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{s}(i) - s(i)| \quad (22)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{s}(i) - s(i))^2} \quad (23)$$

$$E_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{s}(i) - s(i)}{s(i)} \right| \quad (24)$$

式中:  $\hat{s}(i)$  为容量预测值;  $s(i)$  为容量真实值。  $E_{MAE}$  和  $E_{RMSE}$  表示真实值和预测值的拟合效果。其中,  $E_{MAE}$ 、 $E_{RMSE}$  和  $E_{MAPE}$  的值越小, 说明预测的结果越准确。

此外, 对于 NASA 锂离子电池数据集的 4 组电池, 与 LSTM、PSO-LSTM 和 SSA-LSTM 3 种普通预测模型进行对比, 基于混合 ISSA-LSTM 模型的预测容量曲线更接近真实容量退化曲线, 在不同预测条件下锂离子电池 RUL 的评价指标均最小, 这表明混合 ISSA-LSTM 模型的预测精度是最好的。其中, 选取前 50% 的数据作为训练数据集、后 50% 的数据作为测试数据集来验证实验结果, 实验预测结果如图 5 所示; 同样选取前 60% 的数据作为训练数据集、后 40% 的数据作为测试数据集来验证实验结果, 实验预测结果如图 6 所示。

由图 5 可知, LSTM 模型对于不同型号电池预测性能差异明显, 主要有以下几个原因。(1) 数据质量的不同: LSTM 神经网络受原始数据质量的影响, 而本文数据集只进行了异常值的处理, 并没有对数据中的噪声进行预处理, 使得 LSTM 模型的预测误

差可能会增加。(2) 数据分布的不同: 不同型号电池的数据集中数据分布存在一定的区别, 会使 LSTM 模型对数据的学习能力产生影响, 从而使预测结果有一定的偏差, 造成不同型号电池的预测性能差异明显。LSTM 模型作为本文混合 ISSA-LSTM 的对比模型, 其参数根据经验取值, 可能对不同型号电池数据集的适应性有所差别, 导致 LSTM 模型的泛化能力不够明显。从表 4 中的预测结果分析可知, LSTM 模型的预测结果虽然有一定的波动, 但仍在合理的变化区间内。从混合 ISSA-LSTM 模型可以

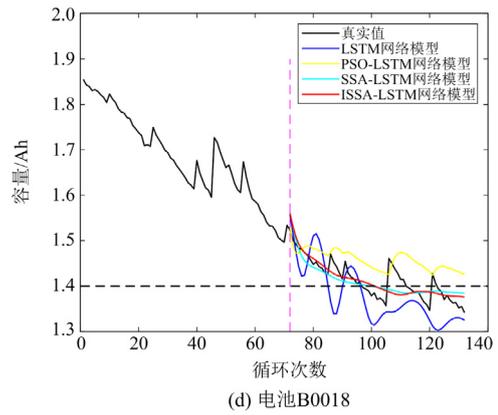
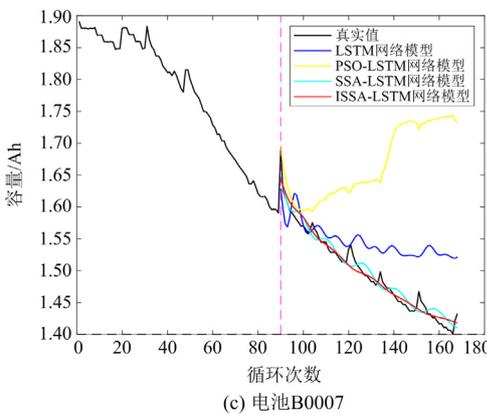
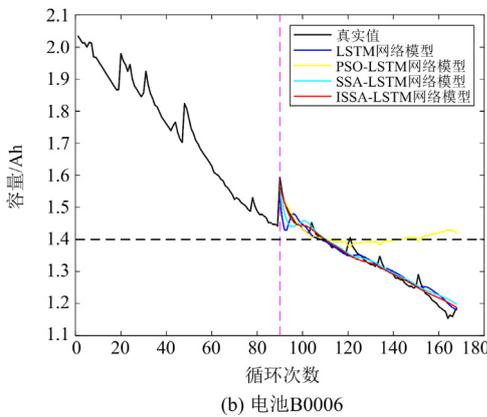
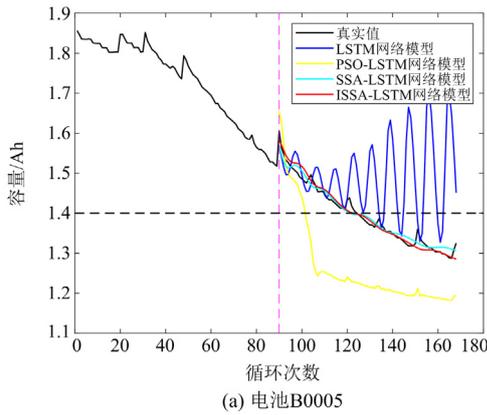
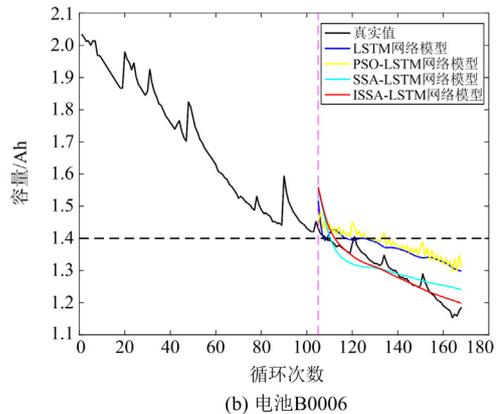
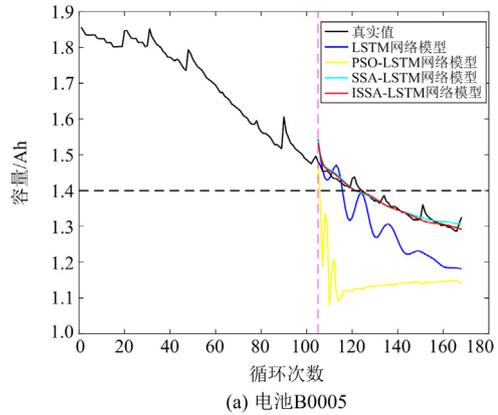


图 5 选取 50%的数据作为训练集的实验预测结果  
Fig. 5 Selecting 50% of the data as the training dataset prediction results of experiment

看出, 如果优化得到合理的参数, LSTM 模型仍然会具有很好的预测效果。

从图 5、图 6 和表 4 分析可知: 减少训练数据会降低模型的预测精度, 预测时预测起点越超前, 提供的有用信息越少, 模型预测结果的相对误差就越大。由表 5 可知, 预测起点越靠前, LSTM、PSO-LSTM 和 ISSA-LSTM 模型预测结果误差就越大。但



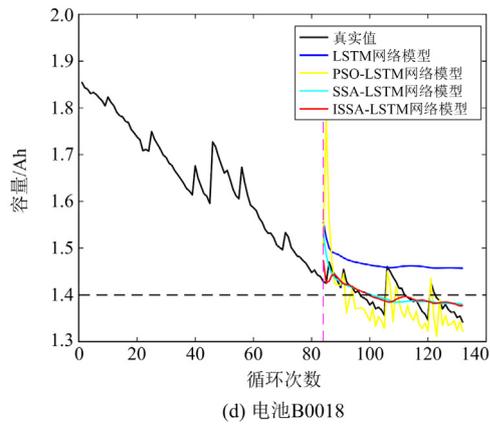
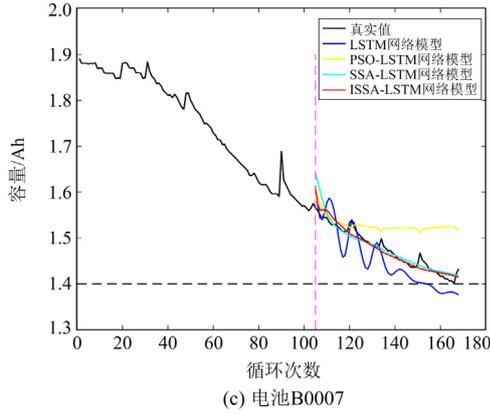


图 6 选取 60%的数据作为训练集的实验预测结果  
Fig. 6 Selecting 60% of the data as the training dataset prediction results of experiment

对于本文混合 ISSA-LSTM 模型来说, 训练数据的变动对模型的预测结果产生的影响较小。从表 5 中可以看出, 本模型在不同电池、不同预测起点下, 预测的  $E_{MAE}$ 、 $E_{RMSE}$  和  $E_{MAPE}$  的值是 4 种模型中最小的, 预测结果比较稳定, 表明本模型具有较好的泛化能力。其中, 数据集为 60% 的电池模型的  $E_{MAE}$ 、 $E_{RMSE}$  和  $E_{MAPE}$  的值分别控制在 0.016 47、0.022 84 和 1.2048% 以内, 最低可以达到 0.008 93、0.011 89 和 0.59247%。

表 4 与文献[28]模型的预测结果比较

Table 4 Compared with the prediction results of the model in reference [28]

模型	$E_{MAE}$	$E_{RMSE}$	$E_{MAPE} / \%$
GRU	0.036 52	0.043 01	—
LSTM	0.033 17	0.037 78	2.360 20
IPSO-GRU	0.009 60	0.013 24	—
ISSA-LSTM	0.008 93	0.011 89	0.592 47

为了进一步证明本文混合 ISSA-LSTM 模型在锂电池 RUL 预测的优势, 以 B0005 号电池为例, 选取相同的锂电池容量数据集, 将本文模型与文献 [28]模型的预测结果进行对比, 如表 4 所示。从表 4 可以看出, LSTM 的各性能指标略低于门控循环单元(gate recurrent unit, GRU)模型, 说明 LSTM 模型具有更好的预测性能。通过与 IPSO-GRU 模型相比, 本文的混合 ISSA-LSTM 模型具有较高的预测精度, 在锂电池 RUL 预测上也具有更大的优势。

表 5 在 NASA 锂离子电池数据集下 4 种模型方法的 RUL 预测结果比较

Table 5 Comparison of RUL prediction results of four model methods under the NASA lithium-ion battery dataset

电池型号	预测模型	50%的数据作为训练数据			60%的数据作为训练数据		
		$E_{MAE}$	$E_{RMSE}$	$E_{MAPE} / \%$	$E_{MAE}$	$E_{RMSE}$	$E_{MAPE} / \%$
B0005	LSTM	0.107 71	0.156 25	8.016 80	0.106 81	0.145 95	7.899 70
	PSO-LSTM	0.134 89	0.144 13	9.740 00	0.128 04	0.197 19	9.620 70
	SSA-LSTM	0.017 59	0.022 39	1.340 40	0.013 46	0.016 52	0.963 44
	<b>ISSA-LSTM</b>	<b>0.012 59</b>	<b>0.017 57</b>	<b>0.968 74</b>	<b>0.008 93</b>	<b>0.011 89</b>	<b>0.592 47</b>
B0006	LSTM	0.033 17	0.037 78	2.360 20	0.072 95	0.083 01	5.807 50
	PSO-LSTM	0.086 42	0.120 75	6.968 30	0.085 23	0.093 61	6.753 20
	SSA-LSTM	0.027 14	0.034 34	2.096 85	0.019 34	0.023 65	1.476 90
	<b>ISSA-LSTM</b>	<b>0.018 45</b>	<b>0.023 39</b>	<b>1.296 00</b>	<b>0.013 51</b>	<b>0.019 01</b>	<b>1.009 50</b>
B0007	LSTM	0.053 93	0.064 34	3.688 90	0.031 53	0.035 52	2.145 00
	PSO-LSTM	0.169 48	0.202 83	11.628 40	0.053 38	0.064 15	3.688 50
	SSA-LSTM	0.012 88	0.015 81	0.947 96	0.011 98	0.019 55	0.809 23
	<b>ISSA-LSTM</b>	<b>0.011 17</b>	<b>0.013 60</b>	<b>0.747 97</b>	<b>0.009 89</b>	<b>0.013 24</b>	<b>0.663 75</b>
B0018	LSTM	0.046 51	0.055 79	3.278 20	0.069 61	0.075 09	5.018 40
	PSO-LSTM	0.048 05	0.053 21	3.447 40	0.037 42	0.062 98	2.661 80
	SSA-LSTM	0.020 32	0.025 50	1.437 10	0.022 29	0.030 25	1.588 40
	<b>ISSA-LSTM</b>	<b>0.019 05</b>	<b>0.024 84</b>	<b>1.347 50</b>	<b>0.016 47</b>	<b>0.022 84</b>	<b>1.204 80</b>

结果表明,在不同的训练数据集和不同的预测起点下,本文提出的模型方法可以提供更为准确的预测结果。以 B0005 号电池为例,本文的混合 ISSA-LSTM 模型在不同训练数据集下预测曲线的  $E_{MAE}$ 、 $E_{RMSE}$  和  $E_{MAPE}$  的值分别是 0.012 59、0.008 93、0.017 57、0.011 89 和 0.96874%、0.59247%,均为同等条件下的最低值。预测误差越小,说明使用模型的预测精度越高。根据本文提出的混合 ISSA-LSTM 模型在锂电池 RUL 预测的结果上看,预测结果的各项性能指标均在合理的区间内变化,模型的训练结果比较理想,能够很好地拟合训练数据并在测试数据上表现良好。所以,本文提出的模型中 LSTM 神经网络并没有出现梯度爆炸和梯度消失的问题。通过实验预测结果分析可知,使用混合 ISSA-LSTM 模型具有更高的预测精度,也具备更好的电池剩余寿命预测能力。

## 5 结论

准确地预测锂离子电池的 RUL 对于提高储能系统的安全性和可靠性来说非常重要。本文介绍了一种可用于锂离子电池 RUL 预测的混合 ISSA-LSTM 模型。经验证和分析可以得出以下结论。

1) 利用均值化的方法对原始数据异常值进行处理,减小预测误差。通过引入 Tent 混沌映射、自适应权重、反向学习策略和柯西变异扰动策略分别对麻雀种群的初始化过程、发现者位置更新和种群最优解这 3 个关键步骤进行优化,提高麻雀种群的局部寻优和全局搜索能力。

2) 利用预处理后的锂离子电池数据来训练 LSTM 模型,通过混合 ISSA 算法寻优得到模型的最优参数,建立混合 ISSA-LSTM 模型,完成锂离子电池 RUL 的预测。在 NASA 锂离子电池数据集上的测试结果表明,与其他普通模型相比,本文所提的模型方法可以获得更高的锂离子电池 RUL 预测精度,预测结果  $E_{MAE}$ 、 $E_{RMSE}$  和  $E_{MAPE}$  的值控制在 0.016 47、0.022 84 和 1.2048% 以内,最优值可以达到 0.008 93、0.011 89 和 0.59247%。

## 参考文献

- [1] WANG S L, JIN S Y, BAI K Di, et al. A critical review of improved deep learning methods for the remaining useful life prediction of lithium-ion batteries[J]. Energy Reports, 2021, 7: 5562-5574.
- [2] 晋殿卫, 顾则宇, 张志宏. 锂电池健康度和剩余寿命预测算法研究[J]. 电力系统保护与控制, 2023, 51(1): 122-130.  
JIN Dianwei, GU Zeyu, ZHANG Zhihong. Lithium battery health degree and residual life prediction algorithm[J]. Power System Protection and Control, 2023, 51(1): 122-130.
- [3] LI Ning, ZHANG Yu, HE Fuxing, et al. Review of lithium-ion battery state of charge estimation[J]. Global Energy Interconnection, 2021, 4(6): 619-630.
- [4] 雷敏, 徐波, 华一飞, 等. 基于 SHEKF-GPM 融合的锂电池 SOC 估算[J]. 湖南工业大学学报, 2020, 34(6): 10-15.  
LEI Min, XU Bo, HUA Yifei, et al. State of charge estimation of lithium battery based on SHEKF-GPM fusion[J]. Journal of Hunan University of Technology, 2020, 34(6): 10-15.
- [5] GUO B Q, NIU M, LAI X K, et al. Application research on large-scale battery energy storage system under global energy interconnection framework[J]. Global Energy Interconnection, 2018, 1(1): 79-86.
- [6] 李建林, 屈树慷, 黄孟阳, 等. 锂离子电池建模现状研究综述[J]. 热力发电, 2021, 50(7): 1-7.  
LI Jianlin, QU Shukang, HUANG Mengyang, et al. A review of current research on lithium-ion battery modeling[J]. Thermal Power Generation, 2021, 50(7): 1-7.
- [7] 刘琼, 张豹. 基于 GBDT 算法的锂电池剩余使用寿命预测[J]. 电子测量与仪器学报, 2022, 36(10): 166-172.  
LIU Qiong, ZHANG Bao. Remaining useful lifetime prediction for lithium battery based on GBDT algorithm[J]. Journal of Electronic Measurement and Instrument, 2022, 36(10): 166-172.
- [8] 雷敏, 华一飞, 赵洪山, 等. 计及电池寿命的电动汽车参与电网调峰策略[J]. 现代电力, 2020, 37(5): 510-517.  
LEI Min, HUA Yifei, ZHAO Hongshan, et al. Strategy of electric vehicles participating peak load regulation of power grid considering battery life[J]. Modern Electric Power, 2020, 37(5): 510-517.
- [9] 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.
- [10] 蔡涛, 张钊诚, 袁奥特, 等. 锂离子电池储能安全管理中的机器学习方法综述[J]. 电力系统保护与控制, 2022, 50(24): 178-187.  
CAI Tao, ZHANG Zhaocheng, YUAN Aote, et al. Review of machine learning for safety management of li-ion battery energy storage[J]. Power system protection and control, 2022, 50(24): 178-187.
- [11] LIU C, WANG Y, CHEN Z H. Degradation model and cycle life prediction for lithium-ion battery used in hybrid energy storage system[J]. Energy, 2019, 166: 796-806.
- [12] 黎冲, 王成辉, 王高, 等. 基于数据驱动的锂离子电池健康状态估计技术[J]. 中国电力, 2022, 55(8): 73-86, 95.  
LI Chong, WANG Chenghui, WANG Gao, et al. Technology of lithium-ion battery state-of-health assessment based on

- data-driven[J]. *Electric Power*, 2022, 55(8): 73-86, 95.
- [13] KAVEH K S, JIN X, RIZZONI G. Prediction of remaining useful life for a composite electrode lithium-ion battery cell using an electrochemical model to estimate the state of health[J]. *Journal of Power Sources*, 2021, 481(1): 228861.
- [14] 宋胜, 李云伍, 赵颖, 等. 锂离子电池片段数据的荷电状态估计研究[J]. *电源技术*, 2022, 46(7): 734-738. SONG Sheng, LI Yunwu, ZHAO Ying, et al. Research on SOC estimation based on fragment data of lithium-ion battery[J]. *Chinese Journal of Power Sources*, 2022, 46(7): 734-738.
- [15] LI Junhui, GAO Fengjie, YAN Gangui, et al. Modeling and SOC estimation of lithium iron phosphate battery considering capacity loss[J]. *Protection and Control of Modern Power Systems*, 2018, 3(1): 61-69.
- [16] 寇发荣, 王甜甜, 王思俊, 等. 基于 ABC-RFEKF 算法的锂电池 SOC 估计[J]. *电力系统保护与控制*, 2022, 50(4): 163-171. KOU Farong, WANG Tiantian, WANG Sijun, et al. Lithium battery SOC estimation based on ABC-RFEKF algorithm[J]. *Power System Protection and Control*, 2022, 50(4): 163-171.
- [17] 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.
- [18] 何星, 丁有军, 宋丽君, 等. 基于加速鱼群算法的锂离子电池剩余使用寿命预测[J]. *兵器装备工程学报*, 2022, 43(2): 163-169. HE Xing, DING Youjun, SONG Lijun, et al. Residual life prediction for lithium-ion battery based on accelerating AFSA[J]. *Journal of Ordnance Equipment Engineering*, 2022, 43(2): 163-169.
- [19] 徐帅, 刘雨辰, 周飞. 基于 RNN 的锂离子电池 SOC 估算研究进展[J]. *电源技术*, 2021, 45(2): 263-269. XU Shuai, LIU Yuchen, ZHOU Fei. Research progress of SOC estimation of lithium ion batteries based on RNN[J]. *Chinese Journal of Power Sources*, 2021, 45(2): 263-269.
- [20] 刘伟霞, 田勋, 肖家勇, 等. 基于混合模型及 LSTM 的锂电池 SOH 与剩余寿命预测[J]. *储能科学与技术*, 2021, 10(2): 689-694. LIU Weixia, TIAN Xun, XIAO Jiayong, et al. Estimation of SOH and remaining life of lithium batteries based on a combination model and long short-term memory[J]. *Energy Storage Science and Technology*, 2021, 10(2): 689-694.
- [21] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [22] 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.
- [23] 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.
- [24] 李鹏, 丁倩文. 基于麻雀算法优化的 OSTU 分割算法[J]. *电子测量技术*, 2021, 44(19): 148-154. LI Peng, DING Qianwen. OSTU segmentation algorithm based on sparrow algorithm optimization[J]. *Electronic Measurement Technique*, 2021, 44(19): 148-154.
- [25] 郭文艳, 王远, 戴芳, 等. 基于精英混沌搜索策略的交替正弦余弦算法[J]. *控制与决策*, 2019, 34(8): 1654-1662. GUO Wenyan, WANG Yuan, DAI Fang, et al. Alternate sine and cosine algorithm based on elite chaotic search strategy[J]. *Control and Decision*, 2019, 34(8): 1654-1662.
- [26] 付华, 刘昊. 多策略融合的改进麻雀搜索算法及其应用[J]. *控制与决策*, 2022, 37(1): 87-96. FU Hua, LIU Hao. Improved sparrow search algorithm with multi-strategy integration and its application[J]. *Control and Decision*, 2022, 37(1): 87-96.
- [27] 毛清华, 张强. 融合柯西变异和反向学习的改进麻雀算法[J]. *计算机科学与探索*, 2019, 34(8): 1654-1662. MAO Qinghua, ZHANG Qiang. Improved sparrow algorithm combining Cauchy mutation and opposition-based learning[J]. *Journal of Frontiers of Computer Science and Technology*, 2019, 34(8): 1654-1662.
- [28] 王钊, 雷敏, 梁娇娇, 等. 基于 IPSO-GRU 的锂离子电池剩余使用寿命预测[J]. *湖南工业大学学报*, 2022, 36(4): 23-30. WANG Po, LEI Min, LIANG Jiaojiao, et al. An IPSO-GRU-based prediction of remaining useful life of lithium-ion batteries[J]. *Journal of Hunan University of Technology*, 2022, 36(4): 23-30.

收稿日期: 2023-03-21; 修回日期: 2023-06-09

作者简介:

邹红波(1978—), 男, 博士, 副教授, 硕士生导师, 研究方向为电力设备监测与故障诊断、电池寿命预测; E-mail: zhbhorace@163.com

柴延辉(1998—), 男, 通信作者, 硕士研究生, 研究方向为电池剩余寿命预测。E-mail: cyh132838575402021@163.com

(编辑 周金梅)