

基于在线顺序极限学习机模型的锂离子电池健康状况预测

郑启达¹, 赵谡², 汪彪¹, 赵孝磊², 王亚林², 尹毅²

(1. 上海电力大学电气工程学院, 上海 200090; 2. 上海交通大学电气工程系, 上海 200240)

摘要:针对锂电池健康状况预测精度不高以及模型不能实现在线更新的问题,文中提出基于在线顺序极限学习机(online sequential extreme learning machine, OSELM)模型的锂电池健康状况预测方法。首先,从锂离子电池历史充放电数据中获取与电池容量相关度高的健康因子,通过鹅算法优化 OSELM(记作 GOOSE-OSELM)提高模型的预测精度,同时引入柯西逆累积分布算子和正切飞行算子对鹅算法进行改进,提高模型全局优化能力和收敛速度,形成计算速度快且能在线更新的算法模型。然后,将改进鹅算法优化 OSELM(记作 IGOOSE-OSELM)的预测结果与 GOOSE-OSELM、OSELM、反向传播(back propagation, BP)神经网络、鲸鱼算法优化最小二乘支持向量机(whale optimization algorithm-least squares support vector machine, WOA-LSSVM)进行对比,结果显示,在 3 个电池数据集中 IGOOSE-OSELM 的拟合优度均值超 0.997,均方根误差都小于 0.004 5。最后,利用牛津电池数据集和 NASA 电池数据集对模型的泛化能力加以验证,结果表明 IGOOSE-OSELM 模型能够准确预测电池的健康状况,模型具有较高的鲁棒性和适应性。

关键词: 电池健康状态; 在线顺序极限学习机(OSELM); 鹅优化算法; 收敛速度; 泛化能力; 鲁棒性

中图分类号: TM912

文献标志码: A

文章编号: 2096-3203(2026)02-0051-09

0 引言

随着“双碳”目标的提出,以新能源为主体的新型电力系统建设逐步推进。新型电力系统需要具备高效、经济的能量存储技术,其中电化学储能技术发展速度最快、应用最广泛^[1-4]。锂离子电池自开发和商业化以来,凭借其循环寿命长、能量密度高、充电速度快等优点,在电化学储能领域迅速占据领先地位^[5-7]。然而,随着锂离子电池充放电次数增加及环境工况影响,电池会逐渐老化,导致内部化学反应不稳定,进而引起电池温度升高。在老化严重时,甚至可能引发热失控,造成严重危害。因此,及时了解锂离子电池的老化程度,预测其使用寿命,对于维护电力系统储能装备具有重要意义。

电池健康状态(state of health, SOH)是表征电池老化程度的重要指标,其定义为电池当前最大容量与额定容量的比值^[8-10],通过对 SOH 进行预测可预知电池的使用寿命。目前对于 SOH 的预测可分为模型法和数据驱动法^[11],模型法一般从电化学反应的角度描述电池的衰退过程,通过构建电化学模型、电化学阻抗模型或等效电路模型解释电池内部复杂的化学反应过程。文献[12]提出一种基于伪二模型和降解模型耦合的 SOH 和老化参数在线估计方法。文献[13]提出一种极简的电化学模型,用

于描述电池内部的锂含量,并将锂损失导致的容量衰减与 SOH 关联起来。模型法在电池建模准确的前提下可以准确估计电池的 SOH,但这类方法存在电池参数复杂度较高的问题,模型参数受外部环境的影响,鲁棒性较差。

数据驱动法通过测量电池使用中的电压、电流、温度等参数,提取与 SOH 变化相关度高的特征参量,利用高特征数据集实现对 SOH 的估计,相比于模型法,其不需要研究电池具体的反应机理,具有较高的适应性和鲁棒性。文献[14]利用差分进化灰狼优化器对长短期记忆(long short-term memory, LSTM)网络模型中的超参数进行优化,实现对电池 SOH 的预测。文献[15]采用灰色关联度对健康因子进行排序,确定 SOH 的主要健康特征,构建灰狼优化算法-最小二乘支持向量机(gray wolf optimization-least squares support vector machine, GWOLSSVM)对电池数据集进行预测。文献[16]提出一种基于粒子群优化多核高斯过程回归模型的锂离子电池 SOH 预测框架。文献[17]提出基于鲸鱼优化的双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络的电池 SOH 预测模型。以上算法虽均实现了对电池 SOH 的预测,但存在模型计算时间长、预测精度不高的问题。而电池的健康状况易受充电环境的影响,不经过实时快速更新难以保证电池 SOH 定位的精确度。基于以上问题,文中引入在线顺序极限学习机(online sequential

收稿日期: 2025-06-02; 修回日期: 2025-09-30

基金项目: 国家自然科学基金资助项目(52107019)

extreme learning machine, OSELM)算法对锂离子电池的 SOH 进行研究。

极限学习机(extreme learning machine, ELM)是一种批处理算法,其克服了传统神经网络和深度学习算法参数多、学习速度慢的缺点,具有学习速度快、泛化能力强等优点^[18-20]。OSELM 为 ELM 的变体,继承了 ELM 计算速度快、模型简单的优点,同时还解决了 ELM 不能实现模型在线更新的问题,但该方法仍存在模型初始化参数与神经元之间的权重对模型预测精度影响较大的问题^[21]。对此,文中提出基于 OSELM 模型预测电池 SOH 的方法。首先,从锂离子电池充放电数据集中提取健康因子,运用鹅算法优化 OSELM(记作 GOOSE-OSELM)以提高模型的预测精度;然后,引入柯西逆累积分布算子和正切飞行算子对算法进行改进,通过改进的鹅优化算法寻找 OSELM 的最佳参数;最后,利用改进鹅算法优化 OSELM(记作 IGOOSE-OSELM)对电池数据集进行在线预测,并将预测结果与 GOOSE-OSELM、OSELM、反向传播(back propagation, BP)神经网络、鲸鱼算法优化最小二乘支持向量机(whale optimization algorithm-least squares support vector machine, WOA-LSSVM)进行对比。结果显示,文中所提 IGOOSE-OSELM 模型预测的拟合优度均高于 0.997,在不同的电池数据集中均有较好的鲁棒性和适应性,可以为锂离子电池的健康预测提供参考。

1 健康因子筛选与特征选取

1.1 模型数据集选择

实验采用的电池数据均来源于 NASA 公开的电池数据集^[22],该数据集详细记录了电池充放电过程中的电压、电流、温度、容量等参数的变化情况。文中选取该数据集中的 B0005、B0006、B0007 号电池作为实验对象,锂电池容量均为 2 A·h,环境温度为 24 ℃。充放电过程如下:充电过程,恒流阶段电池以 1.5 A 电流充电,当电压达到 4.2 V 时进入恒压阶段,当充电电流小于 20 mA 时,充电停止;放电过程,电池以 2 A 电流放电,直到达到各自的截止电压 2.7、2.5、2.2 V 时,电池停止放电。电池充放电工况参数如表 1 所示。电池的容量衰减曲线如图 1 所示。

根据图 1 可知,电池容量呈非线性衰减,且在衰减过程中存在周期性的上升,这是因为电池存在容量自恢复的过程。在充放电过程中,锂离子会在正极和负极之间迁移,其中一些锂离子被固定在电

表 1 电池充放电工况参数

Table 1 Battery charging and discharging condition parameters

电池编号	温度/℃	放电截止电压/V	放电电流/A	充电电流/A
B0005	24	2.7	2	1.5
B0006	24	2.5	2	1.5
B0007	24	2.2	2	1.5

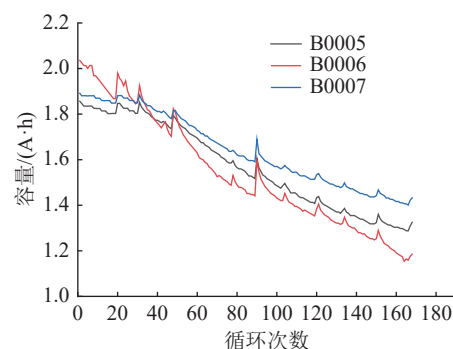


图 1 电池容量衰减曲线

Fig.1 Battery capacity decay curves

极表面或者穿过电解质膜而无法再次参与电池反应。当电池静置时,这些固定的锂离子有可能被重新释放出来,参与电池的充放电反应,从而导致下一个充放电周期的容量增加。

1.2 特征选取与相关性分析

电池容量和内阻是衡量其 SOH 的重要依据,但是在实际情况下难以直接获取。相比之下,在电池充放电过程中,很容易在线测量获取电流、电压、温度等参数,故可将电压、电流、温度的变化情况作为特征信号^[23]。

以 B0005 号电池数据为例,电池循环中电压、温度曲线变化如图 2 所示。随着电池循环次数的增加,恒流充电阶段电压上升时长增加,充放电阶段温度达到峰值时间以及放电阶段电压达到最低点时间均减小,因此将恒流阶段充电电压小于 4.2 V 的电压平均值记为 HI1;放电阶段温度达到峰值时间记为 HI2;电压从 4.2 V 降到截止电压时的放电电压平均值记为 HI3,该段时间记为 HI4^[24]。

斯皮尔曼相关系数(Spearman)可以反映两个随机变量的变化趋势方向和强度之间的关联,适用于变量不满足正态分布的条件。将上述特征与电池的容量用 Spearman 做快速相关性分析,相关系数如表 2 所示。从表 2 可知,不同数据集下,HI1、HI2、HI3、HI4 健康因子的相关系数绝对值均超 0.9,说明以上健康因子与锂离子电池容量有很强的相关性。这些相关性强的健康因子构成新的数据集。

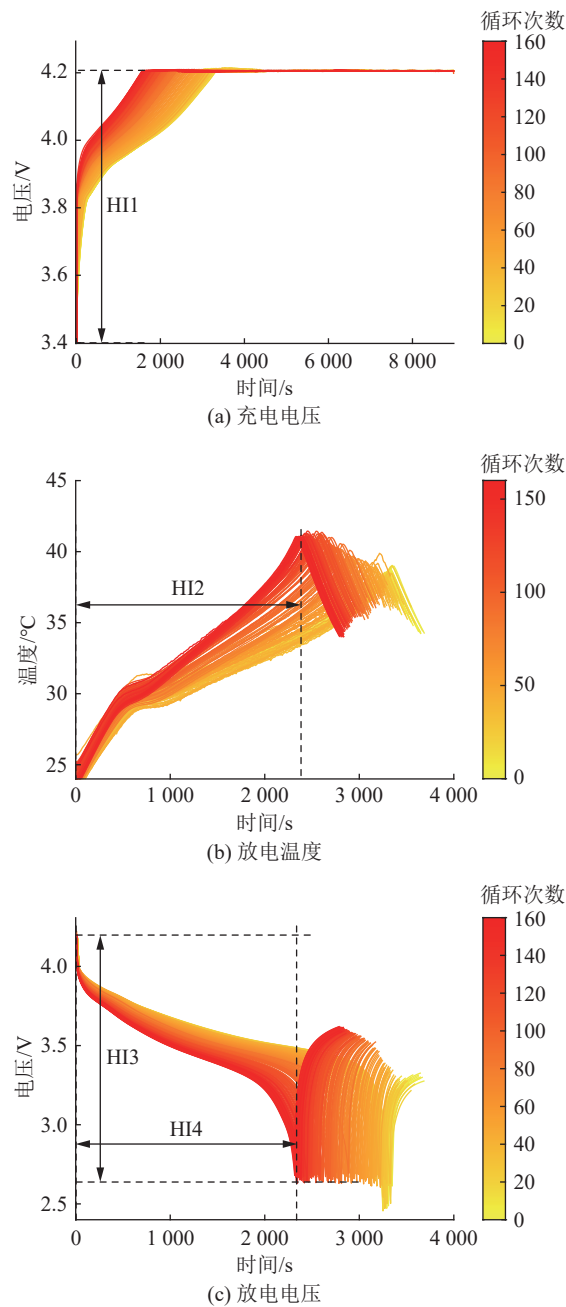


图2 循环中电压、温度的变化曲线

Fig.2 Variation curves of voltage and temperature during cycling

表2 各健康因子与电池容量的相关系数

Table 2 Correlation coefficients between each health factor and battery capacity

电池编号	Spearman			
	HI1	HI2	HI3	HI4
B0005	-0.971 5	0.999 5	0.982 2	0.999 7
B0006	-0.992 2	0.999 8	0.995 7	0.999 9
B0007	-0.987 5	0.998 6	0.976 9	0.999 0

2 模型建立

2.1 OSELM 模型

ELM 是南洋理工大学黄广斌提出的一种快速

学习算法^[25], 在确保学习精度的前提下比传统的学习算法速度更快, 泛化能力更强。但 ELM 是一种批处理算法, 其在训练阶段需要获得所有的训练数据, 经过训练后再测试, 而不是随着新数据的输入对模型进行在线更新。OSELM 为 ELM 的变体, 在 ELM 模型的基础上引入在线机制, 继承了 ELM 训练速度快、泛化能力强的优点, 且可以随新数据的输入不断更新模型, 无须重新训练模型。OSELM 的网络结构如图 3 所示。




图3 OSELM 的网络结构

Fig.3 Network structure of OSELM

图 3 中, y 为模型电池容量的输出, 其由隐含层输出和隐含层与输出层间的权重 β_m 决定, 隐含层的输出由激活函数 $G(a_s, b_s, x_c)$ 决定, a_s 为输入层到隐含层之间的输入权重, b_s 为第 s 个隐含层单元的阈值, x_c 为电池健康因子 HI1—HI4 数据集的输入。 a_s 、 b_s 由随机数生成, 因此需要求出权重 β_m 。

OSELM 模型的学习过程可分为两部分^[26-27]:

- (1) 初始阶段, 通过少量样本获得初始输出权重;
- (2) 在线学习阶段, 由样本组成的数据块被放入网络并更新输出权重 β_m 。

2.2 鹅优化算法

鹅优化算法是 Rebwar Khalid Hamad 和 Tarik A.Rashid 在 2024 年提出的一种新的元启发式算法^[28], 灵感来源于鹅在休息和觅食过程中的行为。该算法模拟鹅行为方式计算鹅在搜索空间中的最优位置, 具体可分为以下两阶段。

为平衡开发阶段和探索阶段, 根据迭代次数均匀分布相位, 使用随机变量 r , 当 $r \geq 0.5$ 进入开发阶段, 引入变量 $q (q \in (0, 1))$, 该变量的作用是判断哪个方程有效; 反之进入探索阶段。

(1) 开发阶段。如果第 i 个石头重量 $W_i \geq 12$ 且变量 $q > 0.2$, 要唤醒种群中的个体鹅, 需要找到一个最佳位置, 位置由石头下落速度 S 加上鹅的距离 G_i 乘以时间均值 A 的平方表示。

$$L_{i+1} = S + G_i A^2 \quad (1)$$

式中: L_{i+1} 为第 $i+1$ 个鹅位置。

如果石头重量 $W_i < 12$ 且变量 $q \leq 0.2$, 石头下落速度 S 可由物体落地时间 O_i 乘以石头重量 W_i 除以

重力加速度表示,如式(2)所示,声音传播距离和鹅的距离 G_i 不变。

$$S = O_i \frac{W_i}{9.81} \quad (2)$$

鹅的新位置如式(3)所示,具体由石头重量 W_i 和变量 q 决定。

$$L_{i+1} = SG_i A^2 q \quad (3)$$

(2) 探索阶段。如果种群中的鹅没有靠石头提醒而是随机醒来,其中一只鹅醒来就开始尖叫以保护种群中的所有个体。如果随机变量 $r < 0.5$,则进入探索阶段。此时检查最小时间 M 是否大于总时间,若是,则将最小时间赋值给总时间。

随机变量 $\alpha \in [0, 2]$ 会随着循环中的每次迭代而显著降低,用以改进搜索空间中的新位置。

$$\alpha = 2 - n / \frac{N_{\max}}{2} \quad (4)$$

式中: n 为迭代次数; N_{\max} 为最大可迭代次数。

为将搜索过程引导至最有可能产生最优解的方向,计算 M 和 α 至关重要。通过使用 $\text{rand}(N(1, d))$,确保鹅随机地探索搜索空间中的其他个体,鹅的新位置可以表示为:

$$L_{i+1} = \text{rand}(N(1, d)) \times (M\alpha) + C \quad (5)$$

式中: $\text{rand}(N(1, d))$ 为取值范围在 $1 \sim d$ 且服从标准正态分布的随机数, d 为维度数量; C 为搜索区域中的最佳位置。

2.3 鹅优化算法改进

鹅优化算法具备强大的全局搜索和局部搜索能力^[28],能够在复杂的环境中找到最优解,但在局部开发阶段容易陷入局部最优解,使得算法可能无法找到全局最优解。为平衡探索阶段和开发阶段,跳出局部搜索的困境,加快算法的收敛速度,增强其鲁棒性,文中从柯西逆累积分布算子和正切飞行算子两方面对其进行改进。

(1) 柯西逆累积分布算子。柯西分布也叫柯西—洛伦兹分布,其概率密度函数的形状类似于钟形曲线,但尾部延伸得非常远,在某些情况下的积分不收敛,所以柯西分布的数学期望、方差和高阶矩均不存在。当数据集中存在极端值或离群点时,柯西分布对于这类数据具有较好的拟合效果。其概率密度函数可以定义为:

$$f(x; a, b) = \frac{1}{\pi} \times \frac{b}{(x-a)^2 + b^2} \quad (6)$$

式中: a 为定义分布峰值位置的位置参数; b 为比例参数,用以定义最大值的一半宽度; x 为随机变量的取值。

柯西分布的累计分布函数为:

$$F(x; a, b) = \int_{-\infty}^x \frac{1}{\pi} \times \frac{b}{(x-a)^2 + b^2} = \frac{1}{2} + \frac{1}{\pi} \arctan\left(\frac{x-a}{b}\right) \quad (7)$$

柯西分布的累计分布函数的反函数可以定义为:

$$F^{-1}(p; a, b) = a + b \tan(\pi(p - 0.5)) \quad (8)$$

式中:概率值 $p = \text{rand}(1, d)$ 。 $a = 0$ 时反函数与标准柯西分布的中心位置一致; $b = 0.01$,这种赋值使得算法中的搜索过程不会过于激进,从而跳出新算法的设计领域。

(2) 正切飞行算子。步长对算法的优化极为重要。对于步长的取值,大的值有利于探索,小的值有利于开发,而切线函数有助于有效地探索搜索空间。正切飞行算子与柯西相似^[29],函数可以定义为:

$$\begin{cases} f = \tan\left(\gamma \frac{\pi}{2}\right) \\ \gamma = \text{rand}(1, d) \end{cases} \quad (9)$$

式中: γ 为 $1 \sim d$ 之间的随机值。

(3) 算法改进。改进策略主要对鹅优化算法的开发阶段进行更改。当随机数 $r \geq 0.5$ 时,算法进入开发阶段。柯西逆累积分布和正切飞行都属于切线函数,其步长较小,步数较多,通过柯西逆累积分布算子细化守卫鹅和种群中其他鹅的距离,减小整体步长,以更快达到最佳位置。式(1)可改进为式(10),数学模型描述如下:

$$L_{i+1} = S + G_i A^2 0.01 \tan(\pi(p - 0.5)) \quad (10)$$

正切飞行具有平衡开发和探索的能力。以正切飞行算子为比例因子控制鹅位置更新的步长,增强鹅优化算法的收敛能力,提高算法的精度和收敛速度,以避免陷入局部最优。式(3)可改进为式(11),具体数学模型描述如下:

$$L_{i+1} = SG_i A^2 q \tan\left(\gamma \frac{\pi}{2}\right) \quad (11)$$

IGOOSE-OSELM 模型的具体步骤如下。

(1) 根据锂电池充放数据,提取健康因子,并进行相关性分析。选取相关性强的健康因子,构成新的数据集。将数据分成训练集和测试集,对两个数据集进行归一化。

(2) 初始化鹅优化算法的相关参数,指定随机变量,寻找最佳适合度和最佳位置。

(3) 运用柯西逆累积分布算子和正切飞行算子策略更新鹅在搜索空间中的位置,记录最佳位置和最佳适合度。

(4) 判断迭代次数是否达到最大迭代次数,如果成立,输出最佳位置和最佳适合度,否则继续

迭代。

(5) 将优化算法的结果代入 OSELM 模型, 得到预测模型, 用测试集对模型进行验证, 完成锂电池的寿命预测。

3 预测结果与分析

3.1 评价指标

为定量分析预测模型的精确度, 文中采用 4 个评价指标: 拟合优度 R^2 、平均绝对百分比误差 P 、均方根误差 S 、平均绝对偏差 A 。计算如下:

$$R^2 = 1 - \frac{\sum_{j=1}^J (y_j - \hat{y}_j)^2}{\sum_{j=1}^J (y_j - \bar{y})^2} \quad (12)$$

$$P = \frac{1}{J} \sum_{j=1}^J \frac{|y_j - \hat{y}_j|}{y_j} \quad (13)$$


$$S = \sqrt{\frac{\sum_{j=1}^J (y_j - \hat{y}_j)^2}{J}} \quad (14)$$

$$A = \frac{\sum_{j=1}^J |y_j - \hat{y}_j|}{J} \quad (15)$$

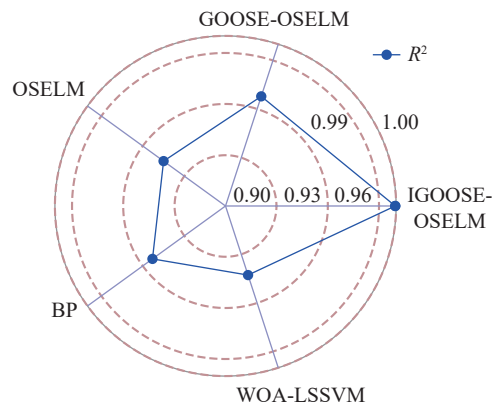
式中: y_j 为第 j 个电池的实际容量; \hat{y}_j 为第 j 个电池的预测容量; \bar{y} 为第 j 个电池实际容量的平均数; J 为样本个数。通常来说, R^2 越接近于 1, 模型对数据的拟合程度越好^[30]; P 、 S 、 A 值越小, 说明实际值与预测值之差越接近 0, 也就意味着模型的预测精度越高。

3.2 模型对比

为验证文中所提 IGOOSE-OSELM 模型的稳定性和准确性, 对处理后的 B0005、B0006、B0007 进行锂电池的寿命预测, 并与 GOOSE-OSELM、OSELM、BP 神经网络以及 WOA-LSSVM 进行对比。上述模型均采用同一种健康因子的选取办法, 取数据集前 50% 的数据用于训练模型, 后 50% 的数据用于预测验证。B0005、B0006、B0007 的 SOH 预测结果分别如图 4、图 5、图 6 所示。结果表明, IGOOSE-OSELM 模型的拟合效果比其他模型的拟合效果要好, 预测值更加接近实际值, 拟合优度 R^2 均高于 0.997。以 B0005 号数据集为例, IGOOSE-OSELM 模型的拟合优度 R^2 较 GOOSE-OSELM 模型提高了 3.3%, 较 OSELM 模型提高了 5.78%, 说明在预测性能方面, IGOOSE-OSELM > GOOSE-OSELM > OSELM。同时, IGOOSE-OSELM 模型也优于常用的 BP 神经网络模型和 WOA-LSSVM 模型。




(a) B0005号电池预测结果




(b) 拟合优度对比

图 4 B0005 号电池 SOH 预测结果

Fig.4 SOH prediction results of B0005 battery



(a) B0006号电池预测结果

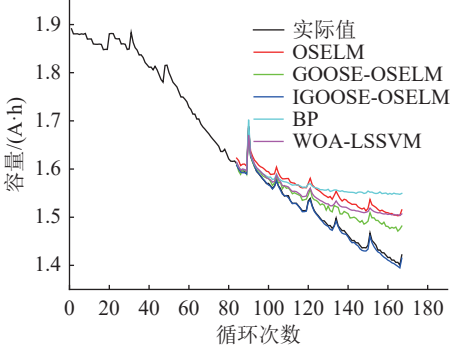


(b) 拟合优度对比

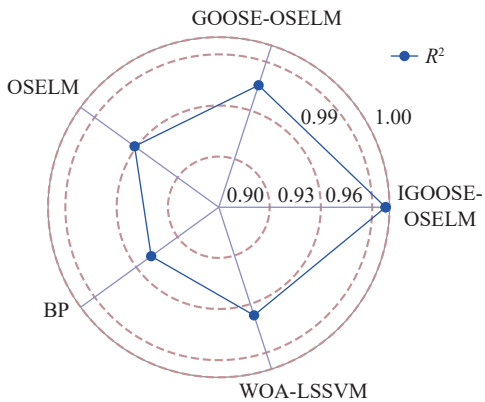
图 5 B0006 号电池 SOH 预测结果

Fig.5 SOH prediction results of B0006 battery

算法的适应度值越小意味着该算法在解决问



(a) B0007号电池预测结果



(b) 拟合优度对比

图6 B0007 号电池 SOH 预测结果

Fig.6 SOH prediction results of B0007 battery

题时的性能越好。在优化算法中, 适应度值通常表示算法得到的解与最优解之间的差距, 因此其值越小表示算法得到的解越接近最优解。图 7 为 3 种算法收敛速度的比较, 可以看出改进鹅优化算法较其他算法能最快收敛到一个最优解, 说明柯西逆累积飞行算子和正切飞行算子能增强鹅优化算法的

收敛能力, 提高其精度。




图 7 算法收敛速度比较

Fig.7 Comparison of algorithm convergence rate

表 3 为 3 种锂电池 SOH 的评价指标, 各个评价指标的值越小, 预测结果越精确。由表 3 可知, IGOOSE-OSELN 模型的预测误差明显优于其他算法, 均方根误差均低于 0.004 5。以 B0006 号电池数据集为例, IGOOSE-OSELN 模型的平均绝对百分比误差比 GOOSE-OSELN 模型减少 85.86%, 均方根误差仅为 GOOSE-OSELN 的 14.17%。总体上来看, IGOOSE-OSELN模型的预测精度最优, 而 BP 模型表现较差。从时间上看, IGOOSE-OSELN模型用时少于 GOOSE-OSELN, 说明改进策略对算法寻优的精确度和速度均有提升的作用; 而 OSELN 和 WOA-LSSVM 模型虽然预测用时少, 但预测精度不高。总体上看, 各种算法的用时差别不大。

3.3 模型泛化能力验证

为验证模型的泛化能力, 分别选取 NASA 的 B0053 号电池数据集和牛津电池老化数据集集中的

表 3 各算法的评价指标对比

Table 3 Evaluation indexes comparison of each algorithm

算法	电池编号	平均绝对百分比误差	均方根误差	平均绝对偏差	时间/s
IGOOSE-OSELN	B0005	0.040 7	0.000 735	0.000 570	1.385 4
	B0006	0.179 8	0.003 094	0.002 351	1.030 7
	B0007	0.241 2	0.004 404	0.003 532	1.529 7
GOOSE-OSELN	B0005	2.628 6	0.045 662	0.036 938	2.113 0
	B0006	1.271 6	0.021 836	0.016 660	1.140 1
	B0007	2.022 0	0.037 294	0.030 471	1.741 8
OSELN	B0005	4.615 1	0.078 088	0.066 883	0.453 0
	B0006	3.289 3	0.058 887	0.044 092	0.367 8
	B0007	3.408 7	0.059 203	0.052 443	0.479 6
BP	B0005	3.671 2	0.066 694	0.052 451	2.243 3
	B0006	4.932 1	0.087 496	0.067 893	2.253 6
	B0007	4.022 3	0.077 424	0.062 555	2.212 6
WOA-LSSVM	B0005	4.605 1	0.081 159	0.066 755	0.257 3
	B0006	3.251 1	0.055 318	0.043 441	0.255 6
	B0007	2.678 4	0.050 324	0.040 784	0.294 3

Cell1 进行验证。对两数据集进行健康因子提取, 其中在 NASA 的 B0053 号电池数据集中, 只有放电阶段温度达到峰值的时间、放电电压从 4.2 V 降到截止电压 2.0 V 的时间这两个健康因子的相关性符合要求, 模型对 B0053 号电池数据集的预测结果以及预测值与实际值的误差曲线如图 8 所示。而牛津电池老化数据集 Cell1 中充电温度的时间间隔、平均充电电压、充电电压的时间间隔和放电电压差这 4 个健康因子的相关性绝对值在 0.8~1.0, 模型对牛津数据集 Cell1 的预测结果以及预测值与实际值的误差曲线如图 9 所示。模型均选取数据集的前 50% 作为训练集, 后 50% 作为预测数据的验证集。




图 8 B0053 号电池预测结果和误差曲线
Fig.8 Prediction results and error curves of B0053 battery




图 9 牛津 Cell1 预测结果和误差曲线
Fig.9 Prediction results and error curves of Oxford Cell1

从模型对两种不同数据集的预测表现来看, B0053 号电池数据集的拟合优度 R^2 为 0.999 43, 牛津电池老化数据集 Cell1 的拟合优度 R^2 为 0.999 02, 模型的鲁棒性较强, 预测精度也较高, 说明模型具有一定的适用性。若能从足够多的电池样本数据中提取出与健康状况相关性超过 0.9 的健康因子, 则对于不同类型的电池, 仅需少量数据即可为其健康状况的评估提供参考依据。

4 结论

文中提出一种锂离子电池健康因子提取办法以及 IGOOSE-OSELM 的锂离子电池 SOH 模型, 相关结论如下。

(1) 锂离子电池的充放电过程中电压的平均值、放电过程中的最高温度、充放电时间与电池容量具有很强的相关性, 这些具有强相关的健康因子构成数据集可以用来预测 SOH 的样本数据, 减小

数据库的数据量。

(2) 通过引入柯西逆累积分布算子和正切飞行算子对鹅优化算法进行改进, 提高算法的精度和收敛速度, 相比于未优化的鹅优化算法, 改进算法适应度值最小, 最接近最优解, 同时可避免算法陷入局部最优。

(3) IGOOSE-OSELM 模型的预测精度优于常见的 BP、LSSVM 等锂离子 SOH 预测模型, 3 个数据集的 R^2 均高于 0.997, 均方根误差均低于 0.004 5。通过不同的数据集进行验证, 结果表明该模型的鲁棒性和适应性较高。

参考文献:

- [1] 王蓓蓓, 胡维涵, 牟玉亭, 等. 储能对高比例新能源电力系统的容量价值贡献及机制思考[J]. 电网技术, 2024, 48(6): 2520-2531.
WANG Beibei, HU Weihang, MOU Yuting, et al. Contribution and mechanism consideration of energy storage to capacity value in high proportion renewable energy power systems[J]. Power System Technology, 2024, 48(6): 2520-2531.
- [2] 张智刚, 康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报, 2022, 42(8): 2806-2819.
ZHANG Zhigang, KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2819.
- [3] 于娜, 吴钰豪, 黄大为, 等. 计及功能性衰减的独立运营模式下电化学储能容量配置研究[J]. 电力系统保护与控制, 2024, 52(17): 62-72.
YU Na, WU Yuhao, HUANG Dawei, et al. Electrochemical energy storage capacity configuration in an independent operational mode considering functional decay[J]. Power System Protection and Control, 2024, 52(17): 62-72.
- [4] 贾一凡, 安海舰, 周敏刚, 等. 电化学储能电站研究现状综述[J]. 电力电容器与无功补偿, 2025, 46(3): 99-105.
JIA Yifan, AN Haijian, ZHOU Mingang, et al. Review of current research status for electrochemical energy storage power station[J]. Power Capacitor & Reactive Power Compensation, 2025, 46(3): 99-105.
- [5] 屈克庆, 董浩, 毛玲, 等. 基于融合健康因子和集成极限学习机的锂离子电池 SOH 在线估计[J]. 上海交通大学学报, 2024, 58(3): 263-272.
QU Keqing, DONG Hao, MAO Ling, et al. SOH online estimation of lithium-ion batteries based on fusion health factor and integrated extreme learning machine[J]. Journal of Shanghai Jiao Tong University, 2024, 58(3): 263-272.
- [6] 朱卫平, 陈国旺, 卫志农, 等. 基于 VFFRLS 算法的锂电池参数辨识[J]. 电力工程技术, 2023, 42(1): 226-233.
ZHU Weiping, CHEN Guowang, WEI Zhinong, et al. Parameter identification of lithium-ion battery based on least squares algorithm with variable forgetting factor[J]. Electric Power Engineering Technology, 2023, 42(1): 226-233.

- [7] 邹国发, 高祥, 王春. 考虑锂电池多时间尺度效应的参数辨识与 SOC 估计方法[J]. 电力系统保护与控制, 2024, 52(21): 71-80.
- ZOU Guofa, GAO Xiang, WANG Chun. Parameter identification and SOC estimation methods considering multi-timescale effect lithium batteries[J]. Power System Protection and Control, 2024, 52(21): 71-80.
- [8] 王萍, 弓清瑞, 张吉昂, 等. 一种基于数据驱动与经验模型组合的锂电池在线健康状态预测方法[J]. 电工技术学报, 2021, 36(24): 5201-5212.
- WANG Ping, GONG Qingrui, ZHANG Ji'ang, et al. An online state of health prediction method for lithium batteries based on combination of data-driven and empirical model[J]. Transactions of China Electrotechnical Society, 2021, 36(24): 5201-5212.
- [9] 吴青峰, 杨艺涛, 刘立群, 等. 基于 GA-SA-BP 神经网络的锂电池健康状态估算方法[J]. 电力系统保护与控制, 2024, 52(19): 74-84.
- WU Qingfeng, YANG Yitao, LIU Liqun, et al. Lithium battery state of health estimation method based on a GA-SA-BP neural network[J]. Power System Protection and Control, 2024, 52(19): 74-84.
- [10] 侯林涛, 张彩萍, 蔡雪, 等. 基于阻抗谱重构技术的电池健康状态快速估计方法[J]. 全球能源互联网, 2024(2): 145-154.
- HOU Lintao, ZHANG Caiping, CAI Xue, et al. A fast estimation method of battery state of health based on impedance spectroscopy reconstruction technique[J]. Journal of Global Energy Interconnection, 2024(2): 145-154.
- [11] 武明虎, 岳程鹏, 张凡, 等. 多尺度分解下 GRU-MLR 组合的锂电池剩余使用寿命预测方法[J]. 储能科学与技术, 2023, 12(7): 2220-2228.
- WU Minghu, YUE Chengpeng, ZHANG Fan, et al. Combined GRU-MLR method for predicting the remaining useful life of lithium batteries via multiscale decomposition[J]. Energy Storage Science and Technology, 2023, 12(7): 2220-2228.
- [12] BI Y L, YIN Y L, CHOE S Y. Online state of health and aging parameter estimation using a physics-based life model with a particle filter[J]. Journal of Power Sources, 2020, 476: 228655.
- [13] XU Z C, WANG J, LUND P D, et al. Co-estimating the state of charge and health of lithium batteries through combining a minimalist electrochemical model and an equivalent circuit model[J]. Energy, 2022, 240: 122815.
- [14] MA Y, SHAN C, GAO J W, et al. A novel method for state of health estimation of lithium-ion batteries based on improved LSTM and health indicators extraction[J]. Energy, 2022, 251: 123973.
- [15] 郑青根, 杨祥国, 刘冬, 等. 改进灰狼优化最小二乘支持向量机的锂电池剩余寿命预测[J]. 重庆大学学报, 2023, 46(11): 78-89.
- ZHENG Qinggen, YANG Xiangguo, LIU Dong, et al. Lithium battery remaining life prediction method based on improved grey wolf optimization least squares support vector machine [J]. Journal of Chongqing University, 2023, 46(11): 78-89.
- [16] LIN D, ZHANG X S, WANG L L, et al. State of health estimation of lithium-ion batteries based on a novel indirect health indicator[J]. Energy Reports, 2022, 8: 606-613.
- [17] 方斯顿, 刘龙真, 孔赖强, 等. 基于双向长短期记忆网络含间接健康指标的锂电池 SOH 估计[J]. 电力系统自动化, 2024, 48(4): 160-168.
- FANG Sidun, LIU Longzhen, KONG Laiqiang, et al. State-of-health estimation for lithium-ion batteries incorporating indirect health indicators based on bi-directional long short-term memory networks[J]. Automation of Electric Power Systems, 2024, 48(4): 160-168.
- [18] 寇发荣, 杨天祥, 罗希, 等. 基于 ISSA-ELM 算法的锂电池 SOC 估计[J/OL]. 电源学报, 2024: 1-8. (2024-03-01) [2025-04-27]. <https://kns.cnki.net/kcms/detail/12.1420.TM.20240229.1408.005.html>.
- KOU Farong, YANG Tianxiang, LUO Xi, et al. Lithium battery SOC estimation based on ISSA-ELM algorithm subtitle[J/OL]. Journal of Power Supply, 2024: 1-8. (2024-03-01)[2025-04-27]. <https://kns.cnki.net/kcms/detail/12.1420.TM.20240229.1408.005.html>.
- [19] 王真, 刘子全, 路永玲, 等. 基于 RFID 传感器和深度学习的开关柜故障诊断研究[J]. 电力科学与技术学报, 2025, 40(2): 179-185.
- WANG Zhen, LIU Ziquan, LU Yongling, et al. Fault detection in switchgear based on RFID sensors and deep learning[J]. Journal of Electric Power Science and Technology, 2025, 40(2): 179-185.
- [20] 夏焰坤, 朱赵晴, 唐文张, 等. 基于改进秃鹰算法优化极限学习机的谐波发射水平估计[J]. 电力系统保护与控制, 2024, 52(1): 156-165.
- XIA Yankun, ZHU Zhaoqing, TANG Wenzhang, et al. Optimization of harmonic emission level estimation of extreme learning machine based on improved vulture algorithm[J]. Power System Protection and Control, 2024, 52(1): 156-165.
- [21] 李炳金, 韩晓霞, 张文杰, 等. 锂离子电池剩余使用寿命预测方法综述[J]. 储能科学与技术, 2024, 13(4): 1266-1276.
- LI Bingjin, HAN Xiaoxia, ZHANG Wenjie, et al. Review of the remaining useful life prediction methods for lithium-ion batteries[J]. Energy Storage Science and Technology, 2024, 13(4): 1266-1276.
- [22] SAHA B, GOEBEL K. Battery data set, NASA ames prognostics data repository[J]. NASA Ames Research Center, 2007.
- [23] 李英顺, 阚宏达, 郭占男, 等. 基于数据预处理和 VMD-LSTM-GPR 的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(10): 3244-3258.
- LI Yingshun, KAN Hongda, GUO Zhannan, et al. Prediction of remaining useful life of lithium-ion battery based on data preprocessing and VMD-LSTM-GPR[J]. Transactions of China Electrotechnical Society, 2024, 39(10): 3244-3258.
- [24] 杨立新, 张孝远. 基于多健康特征融合的锂离子电池剩余使用寿命预测[J]. 武汉科技大学学报, 2024, 47(2): 137-143.
- YANG Lixin, ZHANG Xiaoyuan. Prediction of remaining

- useful life of lithium-ion batteries based on multi-health feature fusion[J]. *Journal of Wuhan University of Science and Technology*, 2024, 47(2): 137-143.
- [25] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2006, 70(1/2/3): 489-501.
- [26] ZHU Y D, YAN F W, KANG J Q, et al. State of health estimation based on OS-ELM for lithium-ion batteries[J]. *International Journal of Electrochemical Science*, 2017, 12(7): 6895-6907.
- [27] YAN L Y, WANG H J, WANG H, et al. An improved OS-ELM based real-time prognostic method towards singularity perturbation phenomenon[J]. *Measurement*, 2021, 182: 109673.
- [28] HAMAD R K, RASHID T A. GOOSE algorithm: a powerful optimization tool for real-world engineering challenges and beyond[J]. *Evolving Systems*, 2024, 15(4): 1249-1274.
- [29] WANG M, WANG J S, LI X D, et al. Harris hawk optimization algorithm based on cauchy distribution inverse cumulative function and tangent flight operator[J]. *Applied Intelligence*, 2022, 52(10): 10999-11026.
- [30] 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.

作者简介:



郑启达

郑启达(1996), 男, 硕士在读, 研究方向为高电压绝缘技术(E-mail: 2388560554@qq.com);
赵漫(1991), 男, 博士, 助理研究员, 研究方向为工程绝缘电介质及储能电池检测;
汪彪(1999), 男, 硕士在读, 研究方向为高电压绝缘技术。

Lithium-ion battery health prediction based on online sequential extreme learning machine model

ZHENG Qida¹, ZHAO Su², WANG Biao¹, ZHAO Xiaolei², WANG Yalin², YIN Yi²

(1. College of Electrical Power Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Department of Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: Aiming at the problems that the prediction accuracy of lithium battery health status is not high and the model cannot be updated online, a lithium-ion battery health prediction method based on the online sequential extreme learning machine (OSELM) model is proposed. The health factors with high correlation with battery capacity are obtained from the historical charge and discharge data of lithiumion batteries, and the OSELM model is optimized by goose algorithm (GOOSE-OSELM) to improve the prediction accuracy of the model. At the same time, the Cauchy inverse cumulative distribution operator and tangent flight operator are introduced to improve the goose algorithm to improve the global optimization ability and convergence speed of the model, and form an algorithm model with fast calculation speed and online update. The prediction results of the improved goose algorithm-optimized OSELM model (IGOOSE-OSELM) are compared with those of GOOSE-OSELM, OSELM, back propagation (BP) neural networks, and whale optimization algorithm-least squares support vector machine (WOA-LSSVM). The results show that the goodness of fit values of IGOOSE-OSELM in the three battery datasets are above 0.997, and the root mean square error is less than 0.004 5. Finally, the generalization ability of the model is verified by using the Oxford battery dataset and the NASA battery dataset. The results show that the IGOOSE-OSELM model can accurately predict the health status of the battery, and the model has high robustness and adaptability.

Keywords: battery state of health; online sequential extreme learning machine (OSELM); goose optimization algorithm; convergence rate; generalization capability; robustness

(编辑 陆海霞)