

DOI:10.19651/j.cnki.emt.2417083

# 基于 AO-AVOA-BP 神经网络模型的锂电池 SOH 预测<sup>\*</sup>

李军毅<sup>1</sup> 汪兴兴<sup>1</sup> 陈祥<sup>1</sup> 陈林飞<sup>1</sup> 邓业林<sup>2</sup>

(1. 南通大学机械工程学院 南通 226019; 2. 苏州大学轨道交通学院 苏州 215131)

**摘要:** 为提供准确可靠的锂电池健康状态预测,提出了一种基于非洲秃鹫优化算法融合天鹰优化算法优化BP神经网络的预测模型。通过对电池充电过程中的电压、电流和温度数据的分析,基于灰色关联分析验证健康因子与电池SOH的相关性,确定4个健康因子作为模型的输入,结合基于AO-AVOA优化的BP神经网络模型,实现更精确的SOH预测。将提出的模型与其他优化模型对锂电池SOH进行预测,对各项指标进行对比分析,结果表明,所提出的预测模型平均绝对误差小于0.0089,均方根误差小于0.0112,平均绝对百分比误差小于1.4512%,具有精度高、泛化性强等特点,可有效用于锂电池的SOH预测。

**关键词:** 锂电池; 健康状态; BP神经网络; 非洲秃鹫优化算法; 天鹰优化算法

中图分类号: TM912; TN86 文献标识码: A 国家标准学科分类代码: 530.4130

## SOH prediction of lithium battery based on AO-AVOA-BP neural network modeling

Li Junyi<sup>1</sup> Wang Xingxing<sup>1</sup> Chen Xiang<sup>1</sup> Chen Linfei<sup>1</sup> Deng Yelin<sup>2</sup>

(1. School of Mechanical Engineering, Nantong University, Nantong 226019, China;

2. School of Rail Transportation, Soochow University, Suzhou 215131, China)

**Abstract:** To provide accurate and reliable prediction of the state of health of lithium batteries, a prediction model based on the African Vulture Optimization Algorithm fused with the Aquila Optimizer to optimize the BP neural network is proposed. Through the analysis of voltage, current and temperature data during the battery charging process, the correlation between the health factors and the SOH of the battery is verified based on grey correlation analysis, and four health factors are identified as inputs to the model, which are combined with the BP neural network model based on AO-AVOA optimization to achieve a more accurate SOH prediction. The proposed model is compared with other optimization models for SOH prediction of lithium batteries, and the results show that the average absolute error of less than 0.0089, the root mean square error below 0.0112, and the average absolute percentage error under 1.4512%. This model is characterized by high accuracy and robust generalization capabilities, making it highly effective for SOH prediction in lithium batteries.

**Keywords:** lithium-ion battery; state of health; BP neural network; african vultures optimization algorithm; aquila optimizer

## 0 引言

锂离子电池因其能量密度高、使用寿命长、稳定性高、价格适中等优点而受到人们的青睐,在电动汽车、航空航天和智能电网等领域被广泛应用<sup>[1-2]</sup>。然而,随着电池充放电循环次数的积累,锂离子电池不可避免地会出现老化现象,

导致可用电池容量下降和安全问题<sup>[3]</sup>。电池的健康状态(state of health, SOH)是电池管理系统的重要参考依据<sup>[4]</sup>,因此,准确有效的SOH预测对电动汽车的高效运行具有重要意义,是预防电池故障、保障安全的关键技术<sup>[5]</sup>。

当前,针对电池的SOH预测主要有两种方法:基于模型的方法和数据驱动的方法<sup>[6-7]</sup>。基于模型的方法通过精

收稿日期:2024-10-11

\*基金项目:国家自然科学基金面上项目(52477218)、江苏省重点研发计划项目(BE2021065)资助

构建模型来解析电池容量与充放电循环次数之间的内在联系<sup>[8]</sup>,包含电化学模型和等效电路模型等。Bian 等<sup>[9]</sup>提出了一种融合开路电压模型与增量容量分析的基于融合的 SOH 预测方法,在温度显著变化的条件下,该方法具有较高的估计精度。Hosseiniinasab 等<sup>[10]</sup>提出了一种新的基于分数阶电池模型的协估计方案,用于同时估计内阻和容量衰减作为 SOH 指标。赵月荷等<sup>[11]</sup>基于二阶 RC 等效电路模型,采用无迹卡尔曼滤波算法对电池的荷电状态和欧姆内阻进行实时估计,进而实现了对 SOH 的实时估计。

对于基于模型的方法,难以解决电池内部原理的复杂性和外部运行条件的高不确定性,数据驱动的方法可以有效地克服这些困难<sup>[12]</sup>。数据驱动的方法无需考虑电池内部复杂的原理,依赖于获取的电池老化数据<sup>[13]</sup>,目前有大量学者使用机器学习方法应用于电池 SOH 预测,例如神经网络、高斯滤波器、支持向量机等。陈新岗等<sup>[14]</sup>设计了一种混合神经网络模型 SOH 预测模型,由改进麻雀优化算法、卷积神经网络、双向门控递归单元和注意力机制组成。潘大为等<sup>[15]</sup>提出了一种基于粒子滤波算法优化贝叶斯神经网络的概率性 SOH 估计方法,所提方法对不同工况下的卫星锂电池 SOH 估计具有良好的适用性。丁同等<sup>[16]</sup>提出了一种改进粒子群优化算法和极限学习机的 SOH 预测模型。实验结果表明,所提模型误差在 2% 以内。Gong 等<sup>[17]</sup>构建了一个基于深度学习的编码器-解码器模型,该模型采用混合神经网络作为编码器,以 BP 神经网络作为解码器。钱伟等<sup>[18]</sup>提出了出一种基于 BP 神经网络和 H<sub>∞</sub>滤波的 SOH-SOC 联合估计方法,该方法表现出优异的预测准确度和强鲁棒性。Ma 等<sup>[19]</sup>采用了优化的粒子群优化算法对 BP 神经网络进行了优化,显著提升了 SOH 预测的精度。

BP 神经网络结构简单,易于计算,具有误差反向传播的特性,可以通过误差调整参数,使估计结果更加准确,并且有许多学者对其进行了改进并使其成熟。此外,BP 神经网络具有较强的泛化能力,适用于求解锂离子电池的 SOH 预测等非线性问题,但它也存在参数初始化的问题。为了解决这个问题,本文采用非洲秃鹫优化算法 (African vultures optimization algorithm, AVOA) 对 BP 神经网络的权值和阈值进行优化,AVOA 是一种受秃鹫生活习性启发而设计的元启发式群体智能优化算法,相比于其他优化算法,其拥有强大的开发机制,但其勘探能力和收敛速度并不令人满意。因此,有很多学者已经实施了许多改进和混合尝试来提高 AVOA 的性能。Liu 等<sup>[20]</sup>将 AVOA 与准对立学习和差分进化相结合来解决 AVOA 的局限性,所提模型优于 AVOA 和其他 7 种群体智能算法,表现出更快的收敛速度和更高的解精度。Alizadeh 等<sup>[21]</sup>将樽海鞘群优化算法和 AVOA 进行了融合,通过混合元启发式算法并同时使用不同的机制,与全局优化问题相比,所提算法能够在 23 个标准基准中的 21 个函数中获得最佳结果。Mostafa

等<sup>[22]</sup>将阿基米德优化算法与 AVOA 集成在一起,将阿基米德优化算法整合到 AVOA 框架中,加强了勘探阶段并促进了勘探和开采之间的动态过渡。

这些研究表明,通过混合不同的元启发式算法,可以有效提升单一算法的性能,特别是在解决全局优化问题时。因此,考虑到 AVOA 算法勘探机制不足,容易陷入局部最优解,本文引入天鹰优化算法 (quila optimizer, AO),尝试将 AO 和 AVOA 这两种基于种群的元启发式算法混合,充分发挥两者的优势,实现更好的整体优化性能,进而提出了一种改进的非洲秃鹫融合天鹰优化算法 (AO-AVOA),将 AO 的探索阶段与 AVOA 的开发阶段进行融合,提取并继承了两种算法的探索和开发能力。

综上所述,本文提出一种基于 AO-AVOA 优化的 BP 神经网络模型进行锂电池 SOH 预测。首先,通过电池充电过程中数据的分析,同时采用灰色关联分析法选取与电池 SOH 相关性高的健康因子,构建锂电池 SOH 预测的输入特征集;其次,提出了一种改进的 AO-AVOA 算法,运用改进的 AO-AVOA 算法对 BP 神经网络模型的权值和阈值进行优化,构建了 AO-AVOA-BP 神经网络的电池 SOH 预测模型;最后,利用 NASA 电池数据集对提出的模型进行实验验证,结果表明,所提出的模型预测效果更好,可有效用于锂电池的 SOH 预测。

## 1 电池老化数据及健康因子提取

### 1.1 数据集介绍

本文使用的电池数据来自美国国家航空航天局 (National Aeronautics and Space Administration, NASA) 卓越预测中心数据集的电池数据集,电池为 18650 锂离子动力电池,本文选择 B0005、B0006、B0007、B0018 作为数据支持。其额定电流均为 2.2 Ah,额定电压为 3.7 V。在 24℃ 的室温下,对所有电池进行恒流-恒压充电模式、恒流放电模式和电化学阻抗谱测试模式 3 种模式的测试。在恒流 (constant current, CC) 充电阶段,采用 1.5 A 的恒定电流为电池充电,直至电压攀升至 4.2 V。随后进入恒压 (constant voltage, CV) 充电阶段,维持此电压继续充电,直至充电电流逐渐减小到 20 mA。放电阶段,以 2 A 恒流放电,直至 B0005、B0006、B0007、B0018 电池的电压分别降至 2.7、2.5、2.2、2.5 V。当电池额定容量减少 30% 时寿命终止,停止实验。

4 种电池的 SOH 变化曲线如图 1 所示,从图 1 可以看出,随着循环周期的增加,电池的 SOH 呈现衰退趋势。本文的电池 SOH 通过容量角度进行定义,如式(1)所示。

$$SOH = \frac{C_{now}}{C_{rated}} \times 100\% \quad (1)$$

式中:  $C_{now}$  表示完全充满时电池的当前最大容量,  $C_{rated}$  表示电池出厂时的额定容量。

### 1.2 健康因子提取

鉴于锂离子电池在实际运行时放电条件通常高度不稳

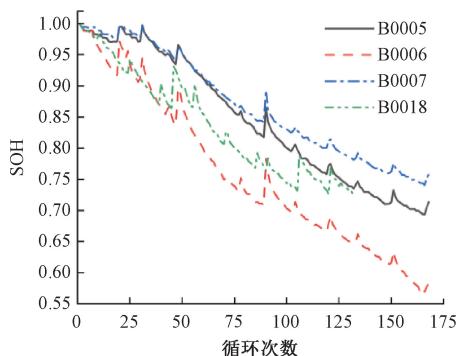


图1 锂电池SOH变化曲线

Fig. 1 SOH variation curve of lithium-ion battery

定且难以精确调控,在充电状态下锂离子电池所处环境比较平稳。所以本工作选取从CC充电阶段和CV充电阶段的相关数据中提取健康因子来预测电池的SOH。以B0005电池为例,得到了10、40、70、100、130和160循环状态下CC充电阶段和CV充电阶段的充电时间变化,如图2(a)和(b)所示。可以看出,随着循环次数的增加,CC充电阶段电池的充电时间从3 221 s逐渐减少到1 579 s,而CV充电阶段电池的充电时间随着循环次数的增加从6 900 s逐渐增加到8 700 s。

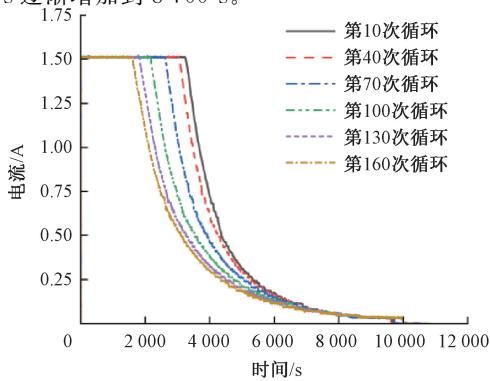
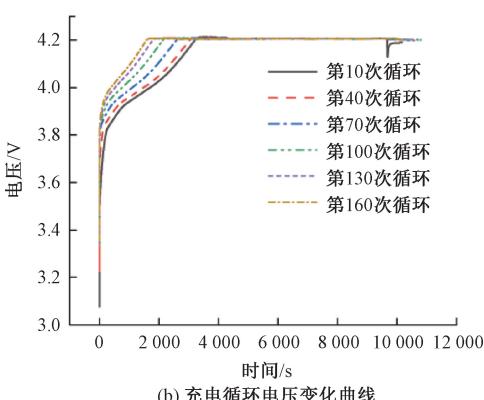
(a) 充电循环电流变化曲线  
(a) Charging cycle current variation curve

图2 不同循环次数的充电曲线

Fig. 2 Charging curves with different cycle number

图3为不同充电阶段容量和时间变化曲线。从图3(a)可以看出,在CC充电阶段,随着循环次数的增加,充电所需时间和充电容量均呈现出逐渐降低的趋势。相反,从图3(b)可以看出,在CV充电阶段,充电所需时间和充电容量则随着循环次数的增加而上升。因此,可以用数学方法对锂离子动力电池的电压、电流等原有参数进行处理,构建新的特征作为锂离子电池的健康因子,即CC充电时间、CC充电容量、CV充电时间和CV充电容量。从电池充电完整性的角度出发,整个充电过程可以被认为是锂离子电池健康的一个重要因素。因此,可以选取CC充电时间与CV充电时间之比、CC充电容量与CV充电容量之比作为电池的健康因子。

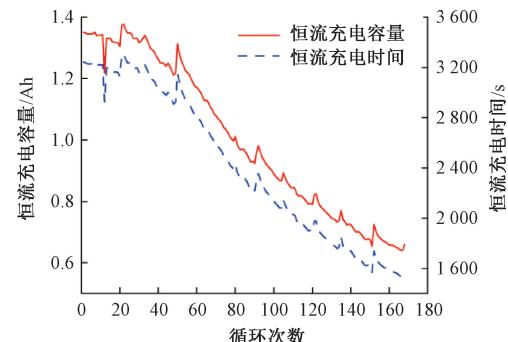
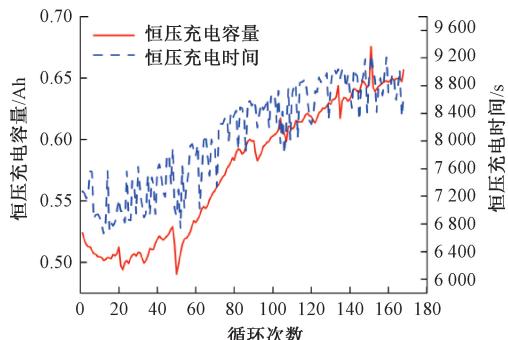
(a) 充电循环电流变化曲线  
(a) Charging cycle current variation curve(b) CV充电阶段容量和时间变化曲线  
(b) Variation of the CV charging capacity and time

图3 不同充电阶段容量和时间变化曲线

Fig. 3 Curves of changing capacity and time at different charging stages

此外,第10、40、70、100、130、160循环状态下的温度变化曲线如图4所示。由图4可以看出,对于每一个循环次数,锂离子电池的温度先下降,然后上升,最后下降到一个稳定的状态。从电池全生命周期的不同循环来看,随着循环次数的逐渐增多,电池的温度变化也呈现出特定的趋势,这种趋势在CC充电阶段的温升变化以及CV充电阶段的平均温度变化上尤为显著。图5显示了两者随电池循环次数的变化。虽然电池的温度变化与容量没有直接的相关关系,但在电池的充电和放电过程中,会发生一系列复杂的化

学反应,这些反应会不可避免地导致热量的产生和温度的波动,因此可以选取电池的温度变化作为电池 SOH 估计的健康因子。

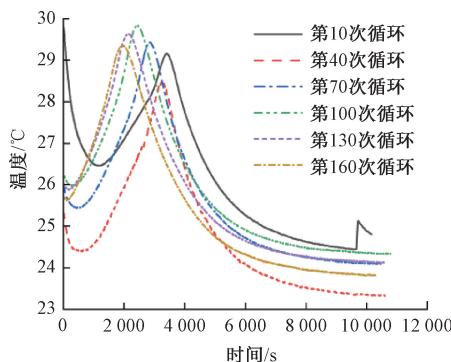


图 4 不同充电循环温度变化曲线

Fig. 4 Temperature change curves under different cycles

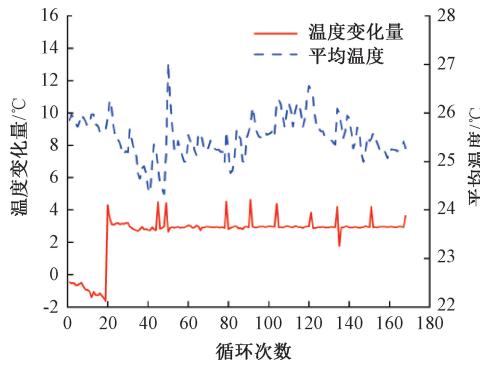


图 5 电池温升和平均温度变化曲线

Fig. 5 Change curves of temperature rise and mean temperature of the battery

综上所述,总共选取 8 个健康因子作为输入来估计锂离子电池的 SOH,分别为:CC 充电时间  $H_1$ 、CC 充电容量  $H_2$ 、CC 充电温升变化  $H_3$ 、CV 充电时间  $H_4$ 、CV 充电容量  $H_5$ 、CV 充电平均温度  $H_6$ 、CC 充电时间与 CV 充电时间之比  $H_7$ 、CC 充电容量与 CV 充电容量之比  $H_8$ 。

### 1.3 相关性分析

为了测试所选健康因子与电池 SOH 之间的相关性,采用灰色关联分析(grey relation analysis, GRA)来度量这些特征点的质量。首先,确定标签向量和特征向量。标签向量为 SOH,特征向量由提出的 8 个健康因子组成。然后,用初值法对原始数据进行无量纲化处理。如式(2)所示。

$$x_i^*(k) = \frac{x_i(k)}{x_i(1)} \quad (2)$$

式中:  $x_i^*(k)$  为无量纲化后的可比性特征向量,  $x_i(1)$  是原始数据序列中的第  $i$  个序列的第一个数据,  $k$  是向量的维数。然后通过计算可比性特征向量与标签向量之间的灰色关联系数  $\xi$  来明确可比性特征数据与标签数据之间的关系,如式(3)所示。

$$\begin{aligned} \xi_i(k) = & \\ \min_{i} \min_k |y_i(k) - x_i^*(k)| + \rho \max_{i} \max_k |y_i(k) - x_i^*(k)| & \\ |y_i(k) - x_i^*(k)| + \rho \max_{i} \max_k |y_i(k) - x_i^*(k)| & \end{aligned} \quad (3)$$

式中: $\rho$  为分辨系数,通常取 0.5。最后对上述灰色关联系数进行加权平均,得到第  $i$  个特征向量与标签向量之间的灰色关联系数  $r_i$ ,如式(4)所示。

$$r_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k) \quad (4)$$

计算灰色关联系数的目的是量化评估特征向量与标签向量之间的关联性强度。如果特征向量与标签向量的相关性越强,则灰色关联系数越接近 1,反之则越接近 0。4 种电池的灰色关联系数如表 1 所示。以 B0005 电池为例,由表 1 可以看出这些参数对电池 SOH 的影响依次为:  $H_1 > H_2 > H_6 > H_8 > H_7 > H_5 > H_4 > H_3$ 。对于健康因子的确定,选择灰色关联系数最高的 4 个健康因子作为输入特征集,即 CC 充电时间、CC 充电容量、CV 充电平均温度和 CC 充电容量与 CV 充电容量之比。

表 1 不同健康因子与 SOH 之间的灰色关联系数

Table 1 Grey correlation coefficient between different health factors and SOH

健康因子	电池编号			
	B0005	B0006	B0007	B0018
$H_1$	0.980 8	0.867 1	0.961 4	0.944 4
$H_2$	0.980 5	0.866 7	0.961 1	0.944 2
$H_3$	0.473 4	0.479 7	0.468 1	0.498 0
$H_4$	0.953 3	0.728 1	0.889 0	0.872 3
$H_5$	0.955 6	0.719 4	0.912 6	0.866 2
$H_6$	0.975 0	0.834 6	0.939 8	0.922 1
$H_7$	0.969 0	0.819 7	0.928 2	0.923 4
$H_8$	0.970 4	0.819 8	0.941 6	0.920 3

## 2 基于 AO-AVOA-BP 的预测模型构建

### 2.1 AO-AVOA 优化算法

#### 1) AO 优化算法

AO 优化算法由 Abualigah 等<sup>[23]</sup>于 2021 年提出的基于种群的元启发式优化方法,通过模拟天鹰的狩猎行为来优化问题。AO 算法的优化流程被划分为 4 个独立的离散阶段,第 1 阶段,广泛探索搜索空间,搜索猎物。这种行为的数学模型为:

$$\begin{aligned} \mathbf{X}_1(t+1) = & \mathbf{X}_{best}(t) \times \left(1 - \frac{t}{T}\right) + \\ (\mathbf{X}_m(t) - \mathbf{X}_{best}(t)) \times rand & \end{aligned} \quad (5)$$

$$\mathbf{X}_m(t) = \frac{1}{N} \sum_{k=1}^N \mathbf{X}_i(t) \quad (6)$$

式中:  $\mathbf{X}_m(t)$  表示当前种群中所有个体的平均位置,  $\mathbf{X}_{best}(t)$  表示迄今为止实现的最佳位置,  $N$  为总体大小,  $rand$  为 0 到 1 之间的随机数,  $t$  和  $T$  分别为当前迭代和最大迭代次数。

第 2 阶段, 缩小探索, 短滑翔攻击猎物。天鹰位置更新公式为:

$$\begin{aligned} \mathbf{X}_2(t+1) &= \mathbf{X}_{best}(t) \times LF(D) + \\ \mathbf{X}_R(t) + (y-x) \times rand & \end{aligned} \quad (7)$$

式中:  $D$  为维度空间,  $\mathbf{X}_R(t)$  表示天鹰的随机位置,  $LF(D)$  表示 Levy 飞行函数,  $x, y$  分别表示算法在搜索空间中的螺旋形状。

第 3 阶段, 扩大开发, 垂直降落初步攻击猎物。该阶段用数学公式表示为:

$$\mathbf{X}_3(t+1) = (\mathbf{X}_{best}(t) - \mathbf{X}_m(t)) \times \alpha - rand + ((UB - LB) \times rand + LB) \times \delta \quad (8)$$

式中:  $UB$  和  $LB$  分别为期望问题的上界和下界,  $\alpha$  和  $\delta$  为等于 0.1 的开发调整参数。

第 4 阶段, 缩小开发, 移动和捕捉猎物。这种行为的数学模型如下:

$$\mathbf{X}_4(t+1) = QF \times \mathbf{X}_{best}(t) - (G_1 \times \mathbf{X}(t) \times rand) - G_2 \times LF(D) + rand \times G_1 \quad (9)$$

式中:  $QF$  表示用于平衡搜索策略的质量函数,  $G_1$  表示在跟踪猎物时的运动参数,  $G_2$  表示追逐猎物时的飞行坡度。

## 2) AVOA 优化算法

AVOA 是 Abdollahzadeh 等<sup>[24]</sup>于 2021 年提出出来的一种新的元启发式群体智能优化算法, 通过模拟非洲秃鹫食物猎寻与飞行轨迹行为来解决优化问题。与 AO 一样, AVOA 也分为 4 个单独的阶段。第 1 阶段, 确定最佳秃鹫个体, 其数学表达式为:

$$\mathbf{R}(i) = \begin{cases} \mathbf{BestVulture}_1, & p_i = L_1 \\ \mathbf{BestVulture}_2, & p_i = L_2 \end{cases} \quad (10)$$

式中:  $\mathbf{R}(i)$  表示最优秀鹫的位置,  $BestVulture_{1,2}$  是最优秀鹫和次优秀鹫,  $L_1$  和  $L_2$  是在进行搜索操作前必须初始化的值在 0~1 的参数, 两个参数之和等于 1。 $P_i$  为最优秀鹫被选出的概率。

第 2 阶段, 秃鹫的饥饿指数计算, 其数学表达式为:

$$\begin{cases} F = (2 \times rand_1 + 1) \times z \times \left(1 - \frac{t}{T}\right) + a \\ a = h \times \left(\sin^{\omega} \left(\frac{\pi}{2} \times \frac{t}{T}\right) + \cos \left(\frac{\pi}{2} \times \frac{t}{T}\right) - 1\right) \end{cases} \quad (11)$$

式中:  $F$  为秃鹫的饥饿指数,  $t$  表示当前迭代次数,  $T$  为迭代总次数,  $rand_1, z$  和  $h$  均为随机数, 且  $rand_1 \in (0, 1), z \in (-1, 1), h \in (-2, 2), \omega$  是优化操作前设置的常数参数, 取值为 2.5。

第 3 阶段, 勘探阶段, 当  $|F| \geq 1$  时, 秃鹫在不同区域寻找食物, 算法进入勘探阶段。其数学表达式为:

$$\begin{cases} \mathbf{P}(i+1) = \\ \mathbf{R}(i) - |X \times \mathbf{R}(i) - \mathbf{P}(i)| \times F & P_1 \geq rand_{P_1} \\ \mathbf{R}(i) - F + rand_2((ub - lb)rand_3 + lb) & P_1 < rand_{P_1} \end{cases} \quad (12)$$

式中:  $\mathbf{P}(i)$  为当前秃鹫的位置,  $\mathbf{P}(i+1)$  表示下一次迭代时秃鹫的位置,  $X = 2 \times rand$  是增加秃鹫随机运动的系数,  $rand_2, rand_3 \in (0, 1)$  之间的随机值,  $ub$  和  $lb$  分别为期望问题的上下界。

第 4 阶段, 开发阶段。当  $|F| < 1$  时, AVOA 进入开发阶段。当  $|F| \in (0.5, 1)$  时进入开发阶段的第一阶段,  $P_2 > rand_{P_2}$  时, 实施缓慢围攻策略, 其数学表达式为:

$$\begin{cases} \mathbf{P}(i+1) = |X \times \mathbf{R}(i) - \mathbf{P}(i)| \times (F + rand_4) - \mathbf{d}(t) \\ \mathbf{d}(t) = \mathbf{R}(i) - \mathbf{P}(i) \end{cases} \quad (13)$$

$P_2 < rand_{P_2}$  时, 执行旋转飞行策略, 其数学表达式为:

$$\begin{cases} \mathbf{P}(i+1) = \mathbf{R}(i) - (\mathbf{S}_1 + \mathbf{S}_2) \\ \mathbf{S}_1 = \mathbf{R}(i) \times \left(\frac{rand_5 \times \mathbf{P}(i)}{2\pi}\right) \times \cos(\mathbf{P}(i)) \\ \mathbf{S}_2 = \mathbf{R}(i) \times \left(\frac{rand_5 \times \mathbf{P}(i)}{2\pi}\right) \times \sin(\mathbf{P}(i)) \end{cases} \quad (14)$$

当  $|F| \in (0, 0.5)$  时进入开发阶段的第 2 阶段, 如果  $P_3 \geq rand_{P_3}$ , 多种秃鹫会聚集在食物源上, 这一行为的位置数学表达式为:

$$\begin{cases} \mathbf{P}(i+1) = \frac{\mathbf{A}_1 + \mathbf{A}_2}{2} \\ \mathbf{A}_{1,2} = \mathbf{BestVulture}_{1,2}(i) - \frac{\mathbf{BestVulture}_{1,2}(i) - \mathbf{P}(i)}{\mathbf{BestVulture}_{1,2}(i) - \mathbf{P}(i)^2} \times F \end{cases} \quad (15)$$

如果  $P_3 < rand_{P_3}$ , 则实施围攻策略, 这一行为的位置数学表达式为:

$$\mathbf{P}(i+1) = \mathbf{R}(i) - |\mathbf{d}(t)| \times F \times LF(D) \quad (16)$$

## 3) 改进的 AO-AVOA 算法

AO 算法展现出了强大的全局搜索能力, 然而其开发能力还需进一步提升。相反, AVOA 算法表现出较好的开发能力, 但其探索能力不够稳定。鉴于这两种算法各自的优势和局限, 本文提出了一种改进的 AO-AVOA 算法, 旨在为全局优化问题提供更优质的可行解。

在 AVOA 的勘探阶段用式(5)和(7)替换原有的位置更新规则, 如下:

$$\mathbf{X}_i(t+1) =$$

$$\begin{cases} \mathbf{X}_{best}(t) \times \left(1 - \frac{t}{T}\right) + (\mathbf{X}_m(t) - \mathbf{X}_{best}(t)) \times rand, & rand \leq P_1 \\ \mathbf{X}_{best}(t) \times LF(D) + \mathbf{X}_R(t) + (y - x) \times rand, & rand > P_1 \end{cases} \quad (17)$$

将 AO 的探索阶段与 AVOA 的开发阶段进行融合, 不仅保留了两者在全局和局部搜索方面的高效能力, 还提高了收敛速度。

## 2.2 AO-AVOA-BP 神经网络模型

BP 神经网络是一种多层前馈网络, 具有信号前向传输和误差反向传播的特点<sup>[25]</sup>。BP 神经网络泛化能力强, 通过训练过程学习数据的映射关系, 能够较好地反映电池容量在全生命周期中的非线性衰减过程。但 BP 神经网络也有其局限性, 特别是参数初始化的问题, 为了解决这一问题, 本文以建好的理论模型为基础, 利用 AO-AVOA 算法去优化 BP 神经网络模型的权值和阈值, 建立 AO-AVOA-BP 神经网络电池 SOH 预测模型, 流程如图 6 所示。

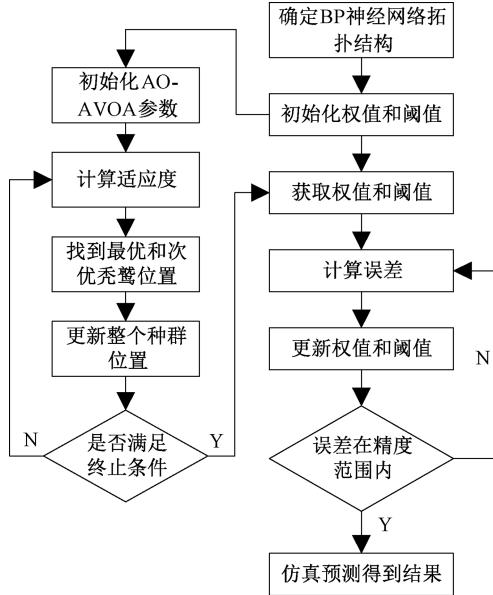


图 6 AO-AVOA-BP 模型流程图

Fig. 6 Flowchart of the AO-AVOA-BP model

## 2.3 SOH 预测流程

基于 AO-AVOA-BP 神经网络模型的锂电池 SOH 预测模型的总体流程如图 7 所示。首先, 数据预处理, 输入 NASA 原始数据集, 从原始数据中提取充电数据进行分析, 将数据集划分为训练集和测试集, 计算电池电压、电流和温度等数据; 其次, 健康因子提取, 从电池充电过程中电压、电流和温度等数据中提取健康因子, 通过灰色关联分析法将提取的健康因子进行相关性分析, 构建输入特征集; 然后, 建立预测模型, 将 BP 神经网络的权值和阈值作为优化对象, 利用改进 AO-AVOA 算法对 BP 神经网络进行优化, 构建 AO-AVOA-BP 预测模型; 最后, SOH 预测, 将构建好输入特征集作为输入, 实现 SOH 预测, 利用评价指标函数验证所提模型的准确性。

## 3 实验验证与评估

### 3.1 实验设置

以 MATLAB 为平台, 搭建 BP 神经网络算法、PSO-BP 神经网络算法、AO-BP 神经网络算法、AVOA-BP 神经网络算法和 AO-AVOA-BP 神经网络算法的模型, 以前文

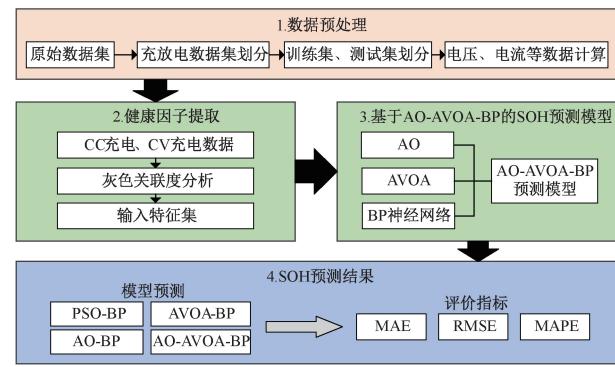


图 7 总体流程图

Fig. 7 Overall flow chart

筛选的 4 个健康因子作为输入, 电池 SOH 作为输出, 选取电池前 70% 的循环数据作为训练集, 剩余数据作为测试集, 进行电池 SOH 的预测。为衡量模型的预测性能, 选取平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 和平均绝对百分比误差 (mean absolute percent error, MAPE) 作为评价函数, 计算公式为:

$$MAE = \frac{1}{N} \sum_{i=1}^{i=1} |(y_i - \hat{y}_i)| \quad (18)$$

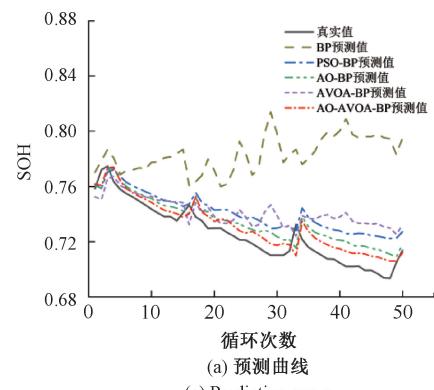
$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (19)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^{i=1} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (20)$$

式中:  $N$  为电池循环的总次数;  $y_i$  为电池 SOH 的真实值,  $\hat{y}_i$  为预测值。

### 3.2 模型预测结果分析

为了验证本文所提模型的预测能力, 将其与 BP 神经网络、PSO-BP 神经网络、AO-BP 神经网络、AVOA-BP 神经网络模型进行对比分析。以 B0005 电池为例, 电池的 SOH 预测结果及误差如图 8(a) 和 (b) 所示。将 B0006、B0007、B0018 电池分别输入到模型进行预测, 评价指标对比结果如表 2 所示。



(a) 预测曲线

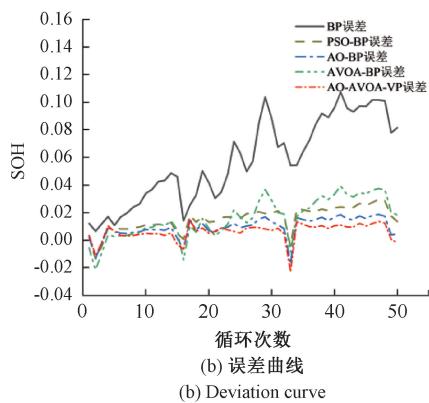


图 8 B0005 电池不同模型 SOH 预测结果及误差

Fig. 8 SOH prediction results and errors of different models for B0005 battery

表 2 不同模型的评价指标对比

Table 2 Comparison of evaluation indexes of different models

电池编号	模型	MAE	RMSE	MAPE/%
B0005	BP	0.057 6	0.065 3	8.080 2
	PSO-BP	0.016 2	0.017 7	2.260 7
	AO-BP	0.010 8	0.011 9	1.508 8
	AVOA-BP	0.018 2	0.021 4	2.550 7
	AO-AVOA-BP	0.007 9	0.008 9	1.094 3
B0006	BP	0.050 1	0.054 2	8.184 9
	PSO-BP	0.014 5	0.017 2	2.396 4
	AO-BP	0.012 4	0.015 9	2.052 3
	AVOA-BP	0.017 3	0.023 3	2.891 1
	AO-AVOA-BP	0.008 9	0.011 2	1.451 2
B0007	BP	0.063 4	0.063 9	8.229 2
	PSO-BP	0.016 3	0.019 7	2.147 4
	AO-BP	0.013 3	0.015 4	1.752 2
	AVOA-BP	0.020 9	0.024 2	2.743 3
	AO-AVOA-BP	0.007 8	0.008 5	1.023 5
B0018	BP	0.058 5	0.060 4	7.830 1
	PSO-BP	0.014 7	0.017 8	1.981 1
	AO-BP	0.011 3	0.016 2	1.511 8
	AVOA-BP	0.018 4	0.025 4	2.458 9
	AO-AVOA-BP	0.008 6	0.010 9	1.151 5

通过图 8 和表 2 可以发现,相比于其他 4 种模型,本文提出的 AO-AVOA-BP 神经网络模型的预测效果更好,在所有样本集上的 MAE、RMSE 和 MAPE 指标都表现得更优。所提模型对应的 MAE 误差值为 0.007 9,相比于 PSO-BP 的 MAE 值 0.016 2,降低了 51.34% 的误差值,相比于 AO-BP 的 MAE 值 0.010 8,降低了 27.24% 的误差值,相比于 AVOA-BP 的 MAE 值 0.018 2,降低了 56.71% 的误差值;RMSE 误差值为 0.008 9,相比于 PSO-BP 的

RMSE 值 0.017 7,降低了 49.81% 的误差值,相比于 AO-BP 的 RMSE 值 0.011 9,降低了 25.47% 的误差值,相比于 AVOA-BP 的 RMSE 值 0.021 4,降低了 58.60% 的误差值;MAPE 误差值为 1.094 3%,相比于 PSO-BP 的 MAPE 值 2.260 7%,降低了 51.59% 的误差值,相比于 AO-BP 的 MAPE 值 1.508 8%,降低了 27.47% 的误差值,相比于 AVOA-BP 的 MAPE 值 2.550 7%,降低了 57.10% 的误差值。综上所述,所提 AO-AVOA-BP 模型进行锂离子电池 SOH 的估计,相比于传统简单融合模型,具有更高的准确性。

为了进一步证明本文所提出的 AO-AVOA-BP 神经网络模型的优异性能,以 B0005 电池为例,将本工作所提模型与近期相关文献所提模型的预测结果进行了对比,对比结果如表 3 所示。

表 3 与其他文献模型对比结果

Table 3 Comparison with other literature models

模型	MAE	RMSE	MAPE/%
TCA-PSA <sup>[26]</sup>	0.019 8	0.022 1	2.21
BO-LSTM <sup>[27]</sup>	0.012 7	0.009 2	1.35
MFPA-TCN <sup>[28]</sup>	0.009 3	0.009 7	—
AO-AVOA-BP	0.007 9	0.008 9	1.094 3

从表 3 可以看出,李红磊等<sup>[26]</sup>提出了一种基于时空卷积网络和金字塔分割注意力融合 Transformer 的 SOH 预测模型,以恒流充电的时间、温度、电压积分和整个充电阶段的内阻作为输入特征,预测误差 MAE、RMSE 和 MAPE 仅为 0.019 8、0.022 1 和 2.21%;MENG 等<sup>[27]</sup>提出了一种基于贝叶斯优化的长短期记忆网络,以提取的部分增量容量曲线作为 SOH 预测的特征,预测误差 MAE、RMSE 和 MAPE 分别为 0.012 7、0.009 2 和 1.35%;Zhang 等<sup>[28]</sup>将时间卷积网络与改进的花朵授粉算法相结合,将外部传感器原始数据和等效电路模型中识别的欧姆电阻轨迹输入到模型中来预测 SOH,预测误差 MAE 和 RMSE 分别为 0.009 3 和 0.009 7。综上所述,本文所提出的 AO-AVOA-BP 神经网络模型在预测性能上仍展现出相对更优的表现,从而验证了所提出方法的有效性和优越性。

## 4 结 论

针对锂电池的 SOH 预测,本文提出了一种基于 AO-AVOA-BP 神经网络组合模型的 SOH 预测模型。选取 CC 充电时间、CC 充电容量、CV 充电平均温度和 CC 充电容量与 CV 充电容量之比这 4 个健康因子作为输入特征集。在此基础上,利用 AO-AVOA 算法去优化 BP 神经网络,将 AO 的探索阶段与 AVOA 的开发阶段进行融合,不仅保留了两者在全局和局部搜索方面的高效能力,还提高了收敛速度,建立了 AO-AVOA-BP 神经网络的 SOH 预测模型。

采用 B0005、B0006、B0007、B00018 电池验证所设计模型的准确性和泛化性,结果表明,该方法预测电池 SOH 的 MAE 小于 0.008 9, RMSE 小于 0.011 2, MAPE 小于 1.451 2%,在多个电池样本上的 SOH 预测精度明显优于其他对比模型。因此,本文所提出的 SOH 预测模型具有精度高、鲁棒性强、泛化性强等特点,可有效用于锂电池的 SOH 预测。

本文使用的数据集针对特定型号的锂电池,对于其他类型或新型电池的适用性有待验证,后续应考虑在电池数量更庞大的数据集上进行预测实验,此外,本文使用的数据集主要集中在特定环境条件下的测试,温度等环境因素可能会影响预测精度,如何克服外部因素以确保较高的预测精度和电池的泛化性是本研究进一步工作的另一个目标。

## 参考文献

- [1] ZHANG D, ZHAO W H, WANG L, et al. Evaluation of the state of health of lithium-ion battery based on the temporal convolution network [J]. Frontiers in Energy Research, 2022, 10: 929235.
- [2] 张朝龙,罗来劲,刘惠汉,等.基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计[J].电子测量与仪器学报,2023,37(1): 167-176.  
ZHANG CH L, LUO L J, LIU H H, et al. State of health estimation of lithium-ion batteries based on incremental energy analysis and BiGRU-Dropout [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 167-176.
- [3] ZHANG F, XING Z X, WU M H. State of health estimation for Li-ion battery using characteristic voltage intervals and genetic algorithm optimized back propagation neural network [J]. Journal of Energy Storage, 2023, 57: 106277.
- [4] 贺宁,杨紫琦,钱成.基于非参数模型与粒子滤波的锂电池 SOH 估计[J].电子测量与仪器学报,2024,38(2): 148-159.  
HE N, YANG Z Q, QIAN CH. SOH estimation of lithium-ion battery based on non-parametric model and particle filter[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(2): 148-159.
- [5] ZUO H Y, LIANG J W, ZHANG B, et al. Intelligent estimation on state of health of lithium-ion power batteries based on failure feature extraction [J]. Energy, 2023, 282: 128794.
- [6] DEMIRCI O, TASKIN S, SCHALTZ E, et al. Review of battery state estimation methods for electric vehicles-Part II: SOH estimation [J]. Journal of Energy Storage, 2024, 96: 112703.
- [7] ROMAN D, SAXENA S, ROBU V, et al. Machine learning pipeline for battery state-of-health estimation[J]. Nature Machine Intelligence, 2021, 3(5): 447-456.
- [8] NUROLDAYEVA G, SERIK Y, ADAIR D, et al. State of health estimation methods for lithium-ion batteries [J]. International Journal of Energy Research, 2023, 2023(1): 4297545.
- [9] BIAN X L, WEI ZH B, LI W H, et al. State-of-health estimation of lithium-ion batteries by fusing an open circuit voltage model and incremental capacity analysis[J]. IEEE Trans Power Electron, 2022, 37: 2226-2236.
- [10] HOSSEININASAB S, LIN CH W, PISCHINGER S, et al. State-of-health estimation of lithium-ion batteries for electrified vehicles using a reduced-order electrochemical model[J]. Journal of Energy Storage, 2022, 52: 104684.
- [11] 赵月荷,庞宗强.基于无迹卡尔曼滤波的动力电池健康状态估计[J].国外电子测量技术,2022,41(10): 136-141.  
ZHAO Y H, PANG Z Q. State of health estimation of power batteries based on unscented Kalman filter[J]. Foreign Electronic Measurement Technology, 2022, 41(10): 136-141.
- [12] QIANG H, ZHANG W J, DING K CH. A prediction framework for state of health of lithium-ion batteries based on improved support vector regression [J]. Journal of the Electrochemical Society, 2023, 170(11): 110517.
- [13] 金帅,董静.基于数据驱动的锂离子电池健康状态估计研究进展综述[J].仪器仪表学报,2024,45(3): 45-59.  
JIN SH, DONG J. Review on progress of data-driven based health state estimation for lithium-ion batteries[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 45-59.
- [14] 陈新岗,赵龙,马志鹏,等.基于 ISSA-CNN-BiGRU-Attention 的锂电池健康状态评估[J].电子测量技术,2024,47(8): 45-52.  
CHEN X G, ZHAO L, MA ZH P, et al. State of health assessment of lithium batteries based on ISSA-CNN-BiGRU-Attention [J]. Electronic Measurement Technology, 2024, 47(8): 45-52.
- [15] 潘大为,师杰,杜宇航,等.基于 BNN-PF 的卫星锂离子电池多工况 SOH 估计[J].电子测量与仪器学报,2024,38(9): 104-115.  
PAN D W, SHI J, DU Y H, et al. BNN-PF-based SOH estimation of satellite lithium-ion batteries under different operating conditions[J]. Journal of Electronic

- Measurement and Instrumentation, 2024, 38(9): 104-115.
- [16] 丁同,傅晓锦.基于改进粒子群优化算法和极限学习机的锂离子电池健康状态预测[J].国外电子测量技术,2023,42(5): 163-173.
- DING T, FU X J. Improved particle swarm optimization and an extreme learning machine are used to predict the health state of lithium-ion batteries[J]. Foreign Electronic Measurement Technology, 2023, 42(5): 163-173.
- [17] GONG Q R, WANG P, CHENG Z. An encoder-decoder model based on deep learning for state of health estimation of lithium-ion battery[J]. Journal of Energy Storage, 2022, 46: 103804.
- [18] 钱伟,王亚丰,王晨,等.基于BP神经网络与 $H_{\infty}$ 滤波的锂电池SoH-SoC联合估计研究[J].仪器仪表学报,2024,45(6): 307-319.
- QIAN W, WANG Y F, WANG CH, et al. Joint estimation of SoH-SoC for lithium battery based on BP neural network and  $H_{\infty}$  infinity filter [J]. Chinese Journal of Scientific Instrument, 2024, 45 ( 6 ): 307-319.
- [19] MA Y, YAO M H, LIU H CH, et al. State of health estimation and remaining useful life prediction for lithium-ion batteries by improved particle swarm optimization-back propagation neural network [J]. Journal of Energy Storage, 2022, 52: 104750.
- [20] LIU R J, WANG T L, ZHOU J, et al. Improved african vulture optimization algorithm based on quasi-oppositional differential evolution operator[J]. IEEE Access, 2022, 10: 95197-95218.
- [21] ALIZADEH A, GHAREHCHOPOGH F S, MASDARI M, et al. An improved hybrid salp swarm optimization and African vulture optimization algorithm for global optimization problems and its applications in stock market prediction [J]. Soft Computing, 2024, 28(6): 5225-5261.
- [22] MOSTAFA R R, HASHIM F A, EL-ATTAR N E, et al. Empowering african vultures optimizer using archimedes optimization algorithm for maximum efficiency for global optimization and feature selection[J]. Evolving Systems, 2024,15(5):1701-1731.
- [23] ABUALIGAH L, YOUSRI D, ABD E M, et al. Aquila optimizer: A novel meta-heuristic optimization algorithm[J]. Computers & Industrial Engineering, 2021, 157: 107250.
- [24] ABDOLLAHZADEH B, GHAREHCHOPOGH F S, MIRJALILI S. African vultures optimization algorithm: A new nature-inspired metaheuristic algorithm for global optimization problems [ J ]. Computers & Industrial Engineering, 2021, 158: 107408.
- [25] ZHANG M, YANG D F, DU J X, et al. A review of SOH prediction of Li-ion batteries based on data-driven algorithms[J]. Energies, 2023, 16(7): 3167.
- [26] 李红磊,刘勋川,高强,等.基于TCT-PSA模型的锂离子电池健康状态评估[J].电子测量技术,2024,47(12):122-131.
- LI H L, LIU X CH, GAO Q, et al. Lithium-ion battery state of health estimation based on TCT-PSA modeling [J]. Electronic Measurement Technology, 2024, 47(12):122-131.
- [27] MENG H X, GENG M Y, HAN T. Long short-term memory network with Bayesian optimization for health prognostics of lithium-ion batteries based on partial incremental capacity analysis [ J ]. Reliability Engineering & System Safety, 2023, 236: 109288.
- [28] ZHANG H, GAO J Y, KANG L, et al. State of health estimation of lithium-ion batteries based on modified flower pollination algorithm-temporal convolutional network[J]. Energy, 2023, 283: 128742.

### 作者简介

**李军毅**,硕士研究生,主要研究方向为动力电池及其应用。

E-mail:2210310030@stmail.ntu.edu.cn

**汪兴兴**(通信作者),正高级实验师,主要研究方向为新能源新材料及装备技术。

E-mail:wangxx@ntu.edu.cn

**陈祥**,博士,主要研究方向为动力电池及可再生能源系统。

E-mail:xiang33.chen@ntu.edu.cn

**陈林飞**,实验师,主要研究方向为新能源新材料及装备技术。

E-mail:chenlinfei@ntu.edu.cn

**邓业林**,教授,主要研究方向为动力电池及可再生能源系统。

E-mail:yelin.deng@suda.edu.cn