

DOI: 10.13382/j.jemi.B2508274

基于 WOA-RF 模型的航空镍镉电池 SOC 预测

雷晓霖 胡新华 王浩

(空军工程大学航空工程学院 西安 710038)

摘要:航空镍镉电池的荷电状态(SOC)预测是保障航空器安全运行的关键技术之一,针对传统预测模型精度不足、环境适应性差的问题,提出一种融合鲸鱼优化算法(WOA)与随机森林(RF)的 WOA-RF 混合预测模型。首先,基于随机森林回归算法构建初始预测模型,利用其多决策树集成优势处理非线性特征;其次,引入鲸鱼优化算法对随机森林的核心超参数(进行全局寻优,解决人工调参效率低下的问题)从而提升模型预测精度与泛化能力。为验证模型性能,在不同温度(20℃、0℃、-10℃、-20℃)环境下分别进行放电循环实验,对比分析 WOA-RF 与传统 RF、反向传播神经网络(BPNN)、支持向量回归(SVR)以及粒子群优化 RF(PSO-RF)、遗传算法优化 RF(GA-RF)等模型的预测效果。实验结果表明,在标准温度下,WOA-RF 模型的平均绝对误差(MAE)为 1.22%、决定系数(R^2)达到 0.986、均方根误差(RMSE)为 1.56%,优于对比模型;在低温环境下,WOA-RF 的 MAE 仍保持在 1.5%以内, RMSE 为 1.8%以内, R^2 高于 0.975,表现出更强的环境鲁棒性。结果表明,WOA-RF 模型有效提高了 SOC 预测的准确性和稳定性,尤其适用于航空极端工况下的镍镉电池状态监测,为电池管理系统提供了可靠的技术支持。

关键词:航空镍镉电池;SOC 预测;鲸鱼优化算法;随机森林

中图分类号: TM912.2; TN06

文献标识码: A

国家标准学科分类代码: 510.4

Research on storage life prediction of aeronautical electromagnetic relay based on WOA-RF model

Lei Xiaoben Hu Xinhua Wang Hao

(Aviation Engineering School, Air Force Engineering University, Xi'an 710038, China)

Abstract: The state of charge (SOC) prediction of aviation nickel-cadmium batteries is a critical technology for ensuring the safe operation of aircraft. To address the issues of insufficient accuracy and poor environmental adaptability in traditional prediction models, this study proposes a hybrid WOA-RF prediction model that combines the whale optimization algorithm (WOA) with random forest (RF). Firstly, an initial prediction model is constructed based on the random forest regression algorithm, leveraging its multi-decision tree ensemble advantage to handle nonlinear features. Secondly, the whale optimization algorithm is introduced to globally optimize the core hyperparameters of the random forest, resolving the inefficiency of manual parameter tuning and thereby enhancing the model's prediction accuracy and generalization capability. To validate the model's performance, discharge cycle experiments were conducted under different temperature conditions (20℃, 0℃, -10℃, -20℃), and the prediction results of the WOA-RF model were compared with those of traditional RF, backpropagation neural network (BPNN), support vector regression (SVR), as well as particle swarm optimization RF (PSO-RF) and genetic algorithm-optimized RF (GA-RF) models. The experimental results show that under standard temperature conditions, the WOA-RF model achieves a mean absolute error (MAE) of 1.22%, a coefficient of determination (R^2) of 0.986, and a root mean square error (RMSE) of 1.56%, outperforming the comparison models. In low-temperature environments, the WOA-RF model maintains an MAE below 1.5%, an RMSE below 1.8%, and an R^2 above 0.975, demonstrating stronger environmental robustness. The conclusion indicates that the WOA-RF model effectively improves the accuracy and stability of SOC prediction, making it particularly suitable for monitoring the state of nickel-cadmium batteries under extreme aviation operating conditions. This provides reliable technical support for battery management systems.

Keywords: aviation nickel-cadmium batteries; SOC prediction; whale optimization algorithm; random forest

0 引言

镍镉电池电化学性质稳定、瞬时放电性能优异同时具备较大的能量密度^[1],因此广泛应用于航空领域,常被选择作为机载应急电源^[2]。当飞机主电源系统失效故障时,由机载应急电源为保证飞机安全飞行的关键设备供电。荷电状态的估算对电池管理至关重要^[3],因此对航空镍镉电池的工作状态进行监测和管理对提高飞行可靠性具有切实意义。

目前工程实际应用的荷电状态(state of charge, SOC)估计方法大致可分为传统预测、卡尔曼滤波和基于数据驱动等 3 种方法^[4],传统预测法包括安时法和开路电压法等。安时法通过实时测量电池的充放电电流对时间积分,累计计算流入或流出的电量,从而推算 SOC 的变化量^[5],但精度依赖初始 SOC,若初始 SOC 不准确,后续估算全部偏差,同时由于自放电效应和电池老化,安时法的误差会随时间累积。开路电压法指电池在长时间静置后,开路电压(open circuit voltage, OCV)趋于稳定,而 OCV 与 SOC 存在确定的映射关系,根据此关系对 OCV 检测来估算 SOC^[6],但需要获得精确的 OCV-SOC 曲线,并且极化效应导致需要足够的静置时间只能用于离线估计,同样电池老化会影响 OCV-SOC 曲线,误差会随时间累积^[6]。并且考虑到镍镉电池具有 OCV-SOC 滞回效应^[7],因此难以应用于对 SOC 估计。卡尔曼滤波是一种基于状态空间模型的最优估计算法,适用于动态系统中存在噪声的状态估计。其核心思想是结合系统模型(如等效电路模型)和实时测量数据(电压、电流等),通过递推计算得到最优 SOC 估计值,并动态修正误差^[8],但估算严重依赖高精度的等效模型建立、准确的参数识别和噪声协方差矩阵的标定。基于数据驱动的 SOC 估计方法不依赖精确的电池物理模型,而是利用历史数据和机器学习/深度学习算法,直接从输入数据(电压、电流、温度等)中学习 SOC 的映射关系。这类方法适用于复杂电池系统(如老化、温度变化大的场景),近年来随着大数据和人工智能技术的发展得到广泛应用。其适应性强,可处理非线性、时变系统,同时无需复杂的等效电路模型参数辨识,结合大数据可提升泛化能力。

现阶段对基于数据驱动的 SOC 估计的研究方法不断创新,主要有神经网络(artificial neural network, ANN)、支持向量机(support vector regression, SVM)模型、高斯过程回归(Gaussian process regression, GPR)等多种算法进行混合对其改进的方法^[9]。反向传播神经网络(back propagation neural network, BPNN)可处理非线性、时变系统(如老化电池),但网络结构复杂时,容易出现过拟合现象权重和隐含层输出难以物理解释,无法直

观分析 SOC 与输入特征(如电压、电流)的因果关系。Guo 等^[10]提出了一种基于模糊加权算法的 SOC 估计模型,该模型通过将遗传算法(genetic algorithm, GA)对 BPNN 与安培积分方法相结合进行了改进。SVM 在对小样本和非线性预测问题的求解中表现出很强的泛化能力,但性能高度依赖超参数选择。姜洁等^[11]以 OCV、放电电流、电池温度的变化为输入,采用粒子群算法(particle swarm optimization, PSO)对 SVM 采的参数进行优化性能优于网格搜索。GPR 是基于统计学理论的一种机器学习回归方法,它是一种有概率的机器学习,在参数寻优时可以避免局部最优,可以很好地解决高维数、非线性等复杂问题。孙爱芬等^[12]利用共轭梯度法,获得最优核函数的超参数值,对 GPR 进行改进。近年也出现使用深度学习的方法来进行 SOC 预测, Yu 等^[13]利用简化的电化学模型获得与机理相关的物理变量,以扩展深度学习模型的输入,使用长短期记忆网络(long short-term memory, LSTM)与贝叶斯优化结合使用,并识别出相关性高的变量;通过将所有选定的高度相关变量一起添加到输入中进行训练对 SOC 的预测。

随机森林(random forest, RF)具有计算速度快、精确度高、泛化性能强、回归性能好等特点^[14]。白浩等^[15]提出一种基于小波去噪与随机森林的高阻接地故障半监督识别方法,预测结果较好。但是随机森林算法需要对超参数进行寻优,从而提高预测精度。鲸鱼优化算法(whale optimization algorithm, WOA)是模仿座头鲸感知猎物区域,搜索空间猎物而衍生的仿生算法^[16]。WOA 自动搜索超参数的最优解,提高 RF 的预测准确率、泛化能力或降低过拟合风险^[17]。

本文采用改进的鲸鱼优化算法对随机森林超参数寻优,建立了 WOA-RF 航空镍镉电池 SOC 预测模型。

1 随机森林预测模型

RF 是一种引导聚集算法(bootstrap aggregating, Bagging)类型的有监督集成算法,算法原理是按照一定组合规则组合性能较弱的多个分类回归树,从而得到一片森林,分类或者回归结果由决策树投票或者均值给出^[18]。

1.1 分类回归树(CART)算法及 Bagging 抽样技术

CART 算法是一种二分递归分类方法,采用基尼指数(Gini index, Gini)指标最小原则作为分裂规则。算法按照分裂属性取值将当前样本训练集 S 分割为两个子集 S_1 和 S_2 ,采用二元递归的方式生成两个分枝树,对每个属性二元划分,最终选取最小的 Gini 指数的子集作为分裂子集,由此不断分裂得到决策树。

样本 S 的 Gini 指数计算公式为:

$$G_s = 1 - \sum_{i=1}^m P_i^2 \quad (1)$$

式中: P_i 表示数据集 S 所包含的 m 个类别中第 i 个类别出现的概率。

节点分裂时样本 S 按照属性 A 划分的 Gini 指数为:

$$G_{S,A} = \frac{|S_1|}{S} G_{S_1}(S_1) + \frac{|S_2|}{S} G_{S_2}(S_2) \quad (2)$$

式中: $G_{S,A}$ 表示属性 A 的 Gini 指数, $G_{S,A}$ 越小, 分类效果越好。

Bagging 抽样技术即可重复无权重随机可放回抽样方法, 通过为从原始训练集 S 中生成 N 个约占原始训练子集 S 的 $2/3$ 大小的训练子集, 解决森林中决策树的局部最优解问题, 同时提高算法的学习精度和泛化性能。

1.2 随机森林算法原理

设随机森林由一系列决策 $h_1(x), h_2(x), h_3(x), \dots, h_n(x)$ 组成, 输入向量 \mathbf{X} 和正确分类别向量 \mathbf{Y} , 采用投票或平均值得到最终预测值。

定义 1 边缘函数为:

$$L(\mathbf{X}, \mathbf{Y}) = av_k(I(h_k(\mathbf{X}) = \mathbf{Y})) - \max_{j \neq Y} av_k(I(h_k(\mathbf{X}) = j)) \quad (3)$$

式中: $av_k(\cdot)$ 为平均值函数; j 为错误分类向量; $I(\cdot)$ 为指示函数; h_k 为第 k 棵决策树, $k = 1, 2, 3, \dots, n$ 。

边缘函数 $L(\mathbf{X}, \mathbf{Y})$ 表示正确分类得票数超过错误分类得票数的最大得票数, 分析可知, 边缘函数值越大, 决策的置信度越高。

定义 2 泛化误差为:

$$PE^* = P_{X,Y}(L(\mathbf{X}, \mathbf{Y}) < 0) \quad (4)$$

式中: $P_{X,Y}(L(\mathbf{X}, \mathbf{Y}))$ 表示相对输入向量 \mathbf{X} 的错误分类概率。

根据式(1)、(2)大数定律和决策树, 可得到泛化误差收敛于:

$$\lim_{n \rightarrow \infty} PE^* = \lim_{n \rightarrow \infty} P_{X,Y}(L(\mathbf{X}, \mathbf{Y})) = P_{X,Y} P_{\Phi}(h(\mathbf{X}, \Phi) = Y) - \max_{j \neq Y} P_{\Phi}(h(\mathbf{X}, \Phi) = j) < 0) \quad (5)$$

式中: P_{Φ} 表示相对任一给定序列 $\Phi(k)$ 的错误分类概率。

由式(5)可知泛化误差收敛且有界, 从而可得到泛化误差上界为:

$$PE^* \leq \frac{\bar{\rho}(1 - s^2)}{s^2} \quad (6)$$

式中: $\bar{\rho}$ 表示决策树平均相关系数; s 表示决策树平均强度。降低决策树的相关性和提高决策树强度可以减小泛化误差上界, 从而提高算法预测精度。

1.3 RF 算法流程

$S = \{(x_i, y_i), x_i \in X, y_i \in Y, n = 1, 2, 3, \dots, n\}$ 为训

练集, 共有 ξ 个特征。

步骤 1) 数据预处理;

步骤 2) 对原始训练集 S 进行 Bagging 抽样, 生成训练集 S_i ;

步骤 3) 在训练集 S_i 中随机选取 m 个特征, 满足 $m \leq \xi$, 根据式(1)和(2)计算每个分裂节点的 Gini 指数;

步骤 4) 根据特征进行节点分裂直到 Gini 指数最大;

步骤 5) 重复步骤 2)~4), 完成模型的训练;

步骤 6) 输入待测样本 x_d , 待测随机森林 $H = \{h(i), i = 1, 2, \dots, n\}$, 便可输出如式(7)预测值。

$$F(x_d) = \frac{1}{n} \sum_{i=1}^n h_i(x_d) \quad (7)$$

2 鲸鱼优化算法

2.1 WOA 数学模型

WOA 是模仿座头鲸感知猎物区域, 搜索空间猎物而衍生的仿生算法, 包括感知包围、螺旋气泡收缩包围、随机寻找猎物^[19]。

1) 感知包围猎物, 从未知位置出发, 选择当前最优搜索路径, 改变自身位置, 实现最优搜索代理。数学模型如下:

$$\mathbf{D} = |\mathbf{C}\mathbf{X}^*(t) - \mathbf{C}\mathbf{X}_j(t)| \quad (8)$$

$$\mathbf{X}_j(t+1) = \mathbf{X}^*(t) - \mathbf{A} \cdot \mathbf{D} \quad (9)$$

式中: \mathbf{D} 表示当前最佳搜索代理到猎物的距离; \mathbf{A} 、 \mathbf{C} 为系数; \mathbf{X}_j 表示第 j 条鲸鱼在群体的位置; \mathbf{X}^* 表示最佳搜索代理位置(当前最优解); t 为迭代次数。

系数 \mathbf{A} 和 \mathbf{C} 的数学公式为:

$$\mathbf{A} = 2ar - a \quad (10)$$

$$\mathbf{C} = 2r \quad (11)$$

式中: 随机数 $r \in [0, 1]$, a 为收敛因子, 可用式(12)的线性函数表示, 与最大迭代次数相关, 在整个迭代过程中数值从 2 线性变化直到 0。

$$a = 2 - 2t/t_{\max} \quad (12)$$

式中: t_{\max} 为最大迭代次数。

2) 螺旋气泡收缩包围, 收缩包围机制主要通过式(10)中 a 值从 2 到 1 的线性变化, \mathbf{A} 可以取到 $[-a, a]$ 的任意值, 从而搜索代理的新位置可以更新到代理的原始位置和当前最佳代理之间的任一位置。螺旋位置更新是建立鲸鱼和猎物之间螺旋形运动方程, 以描述鲸鱼的位置更新:

$$\mathbf{X}_j(t+1) = De^{bl} \cos 2\pi l + \mathbf{X}^*(t) \quad (13)$$

$$\mathbf{D} = |\mathbf{X}^*(t) - \mathbf{X}_j(t)| \quad (14)$$

式中: \mathbf{D} 表示第 j 只鲸鱼到猎物之间的距离; b 为对数螺旋形状常数; l 为随机数且 $l \in [-1, 1]$ 。

假设两种位置更新方式的概率相同, 建立位置更新

的数学模型:

$$X_j(t+1) = \begin{cases} X^*(t) - A \cdot D, & p < 0.5 \\ De^{bl} \cos 2\pi l + X^*(t), & p \geq 0.5 \end{cases} \quad (15)$$

式中: p 为随机数且 $p \in [0, 1]$ 。

3) 随机寻找猎物, 鲸鱼进行随机寻找猎物的行为, 可以使用随机值 $|A| \geq 1$ 来迫使搜索代理远离参考鲸鱼并进行全局搜索, 位置更新方式数学模型如下:

$$D = |C \cdot X_{rand} - X| \quad (16)$$

$$X_j(t+1) = X_{rand} - A \cdot D \quad (17)$$

式中: X_{rand} 表示随机位置向量。

2.2 WOA 算法优化

为解决 WOA 算法易陷入局部最优的问题, 引入混沌理论自适应权重, 改善算法泛化能力^[20]。自适应权重公式如下:

$$\omega^* = \omega_0 + (\omega_{t_{max}} - \omega_0) \cdot \lg(1 + 10t/t_{max}) \quad (18)$$

式中: ω_0 表示惯性权重初值; $\omega_{t_{max}}$ 最大迭代次数 t_{max} 的惯性权重。

利用式 (18) 对式 (9)、(13)、(17) 进行权重更新得到:

$$X_j(t+1) = \omega^* \cdot X^*(t) - A \cdot D \quad (19)$$

$$X_j(t+1) = De^{bl} \cos 2\pi l + \omega^* X^*(t) \quad (20)$$

$$X_j(t+1) = \omega^* X_{rand} - A \cdot D \quad (21)$$

3 基于 WOA-RF 的航空镍镉电池 SOC 预测模型

本文实验数据在实验室条件下, 获取放电过程中的电压、电流、温度以及 SOC。具体测试电池和测试条件如表 1 所示。

表 1 试验电池参数

Table 1 Test battery parameters

参数名称	参考值/说明	备注
电池型号	20NG25A	长虹电源生产
电池大小	370×174×229	长×宽×高
标称电压	24 V	20 °C
湿态重量	23.95±0.4 kg	满电状态

实验设置如下: 由于一个蓄电池组由 6 个单体袋式镍镉电池串联, 且封装好的蓄电池组测试点难以选取, 因此实验中选取 8 个单体镍镉电池作为实验对象。将同一批次的 8 个单体袋式镍镉电池随机分为 4 组, 每组两个蓄电池, 分别在恒温箱于 20 °C、0 °C、-10 °C 和 -20 °C, 湿度 < 30% 条件下保温静置 2 h, 确保蓄电池温度同环境温度一致, 采用混合脉冲功率特性测试 (hybrid pulse power

characteristic, HPPC)。每组蓄电池循环放电 5 次, 放电截至电压为 2.4 V, 测试脉冲充放电电流为 5 C, 充放电时间为 10 s, 采样频率为 50 Hz, 放电电流大小为 1 C。

具体测试步骤如下:

- 1) 以 1 C 倍率为镍镉蓄电池充满电, 此时 SOC=1。
 - 2) 分别将镍镉蓄电池置于 20 °C、0 °C、-10 °C、-20 °C 恒温环境下, 静止 2 h。
 - 3) 采用 5 C 倍率大小的脉冲电流对电池进行放电, 持续时间 30 s, 静置 40 s。
 - 4) 采用 5 C 倍率大小的脉冲电流对电池进行充电, 持续时间 30 s, 静置 40 s。
 - 5) 以 1 C 倍率进行恒流放电, 放电容量达到 0.1 C 后停止, 认为此时 SOC=0.9, 静置 1 h。
 - 6) 重复步骤 3)~4), 直至电池 SOC=0。
- 所得放电曲线如图 1 所示。

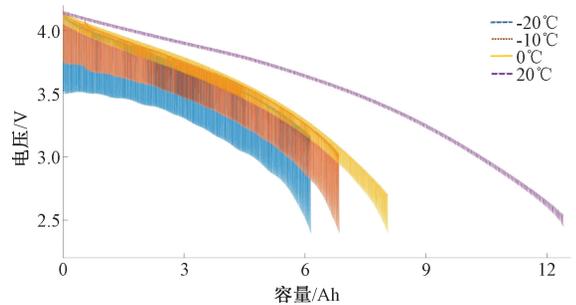


图 1 HPPC 放电曲线

Fig. 1 HPPC discharge curve

考虑到 HPPC 测试是定时采集数据, 会采集到静置时间数据, 静置状态电流为 0, SOC 未发生变化, 对于模型训练没有实际意义且会带来干扰, 因此对数据进行筛选, 仅保留放电状态数据。

3.1 WOA-RF 模型的构建

RF 模型具有模型简单以及回归分析性能强等优点, 但模型的超参数对训练精度具有较大影响, 本文引入改进的 WOA 优化 RF 模型, 对决策树个数和决策树最大深度两个超参数进行寻优, 建立 WOA-RF 航空镍镉蓄电池 SOC 预测模型流程如图 2 所示。

1) 数据预处理, 将所得数据进行归一化, 并划分为训练集、测试集和验证集, 将前 9 组中, 随机选取 7 组放电循环作为训练集, 2 组放电循环为测试集, 最后 1 组放电循环为验证集;

2) 初始化 RF 参数, 设置超参数组搜索上下限, 初始化 WOA 参数设置种群数量;

3) 确认最佳搜索代理, 迭代更新位置;

4) 计算适用度值, 并记录;

5) 满足终止条件, 输出最优超参数组;

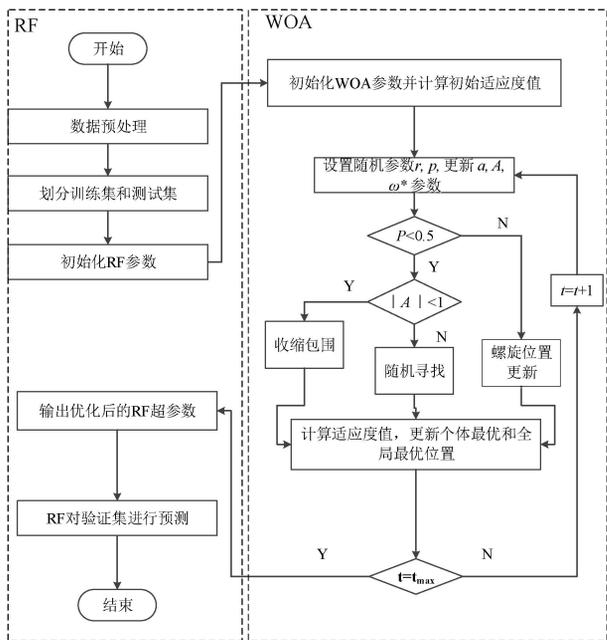


图 2 WOA-RF 算法流程

Fig. 2 WOA-RF algorithm flow chart

6) 利用最优超参数组训练随机森林模型, 得到 WOA-RF 预测模型;

7) 将测试数据作为输入验证预测模型的有效性, 并反归一化 SOC 预测结果。

3.2 模型评价指标

为评估 WOA-RF 模型的预测效果, 采用平均绝对误差 (MAE)、均方根误差 (RMSE) 和决定系数 R^2 作为评价指标对模型的性能进行评估^[21], 其计算公式为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (22)$$

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2} \quad (24)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (f_i - y_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2} \quad (25)$$

式中: n 为样本数; f_i, y_i, \bar{y} 分别为 SOC 的预测值、SOC 的真实值、SOC 真实值的平均值。其中 MAE、RMS 的值越小, 预测值与真实值之间的差距越小, R^2 值越接近 1, 模型拟合效果越好。

4 仿真结果对比

4.1 WOA 优化结果

选择最小化错误率作为适应度函数值, WOA 种群数量为 30, 种群迭代次数 100, 适应度值随迭代次数变化情

况如图 3 所示, 当迭代结束后, 输出优化超参数组合。

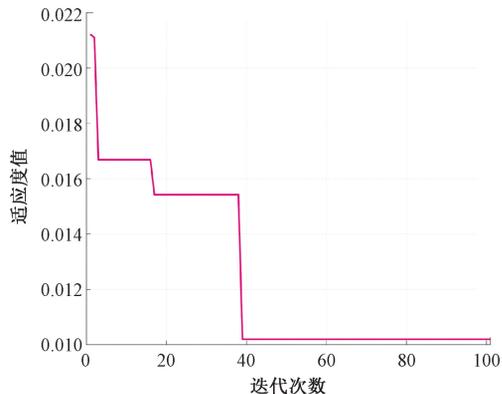
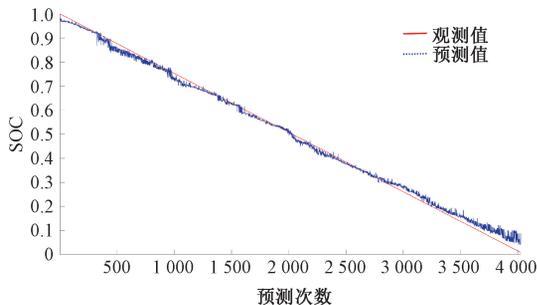


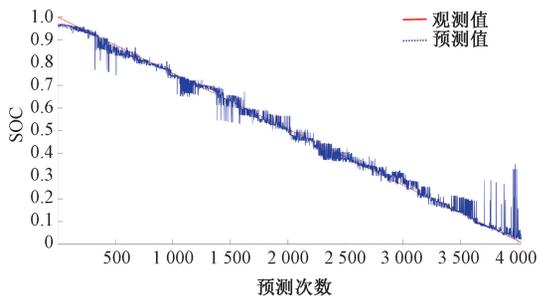
图 3 WOA 迭代优化曲线

Fig. 3 WOA iterative optimization curve

经过 39 次迭代后, 此时已经得到最优超参数, 当将迭代 100 次的超参数组, 即优化后的决策树个数和决策树最大深度训练随机树模型, 并用于 25 °C 下的放电循环数据进行航空镍镉蓄电池 SOC 预测, 得到 WOA-RF 模型验证集的评估结果曲线, 并将未优化超参数的依据经验设置的 RF 模型评估结果曲线进行对比如图 4 所示, 性能评估指标如表 2 所示。



(a) WOA-RF



(b) RF

图 4 WOA-RF 模型和 RF 模型预测值对比

Fig. 4 Comparison of the predicted values of the WOA-RF model and the RF model

由图 4 和表 2 可知, WOA-RF 模型的预测结果决定系数为 98.6%, 远优于未优化后的 RF 模型的 86.6%, 意味着优化后的模型拟合能力得到提升, 效果优于 RF 模

型。WOA-RF 模型预测结果呈现较低的 MAE 和 RMSE，意味着比 RF 模型预测精度更高，更加接近实际值。因此通过改进的 WOA 对于超参数的寻优，提高了 RF 模型拟合性能和预测精度。

表 2 WOA-RF 和 RF 预测模型性能评估指标
Table 2 WOA-RF and RF predictive model performance evaluation indicators

预测模型	MAE	RMSE	R^2
WOA-RF	0.012 2	0.015 6	0.986
RF	0.025 4	0.037 2	0.866

4.2 不同预测模型对比

为了验证 WOA-RF 模型具有较好的预测结果，将引入粒子群优化的 BP 模型和 SVM 模型的回归预测进行对比研究，预测结果如图 5 和 6 所示。

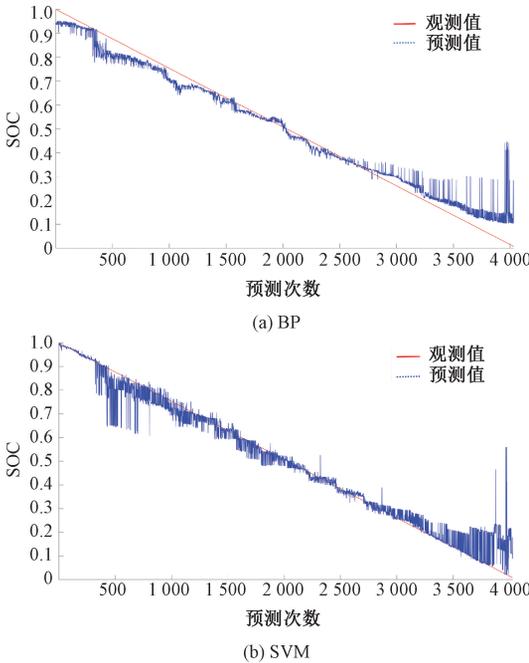


图 5 BP 模型和 SVM 模型预测值曲线
Fig. 5 Predicted value curves of BP model and SVM model

根据量化各模型的预测性能指标，分析各模型的预测性能，如图 7 和表 3 所示，可以看出即使未优化的 RF 模型对比 SVM 和 BP 模型 R^2 更接近 1，MAE 和 RMSE 值更小，表明在 RF 模型更贴合于预测 SOC。对比 WOA-RF 和其他算法优化 RF 模型 PSO-RF 模型、GA-RF 模型 F，WOA 优化后的 RF 模型比其他算法优化后的拟合性能更优和预测精度更高。同时，虽然 PSO-PF 和 GA-RF 模型优化性能对比未优化后的 RF 模型具有优势，但其计算时间要长，时间复杂度远高于 RF 算法，执行速度慢。

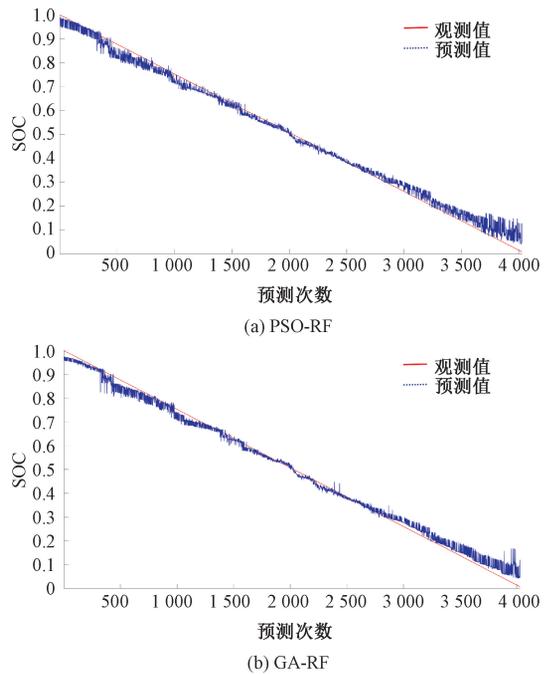


图 6 PSO-RF 模型和 GA-RF 模型预测值曲线
Fig. 6 Predicted value curves of PSO-RF model and GA-RF model

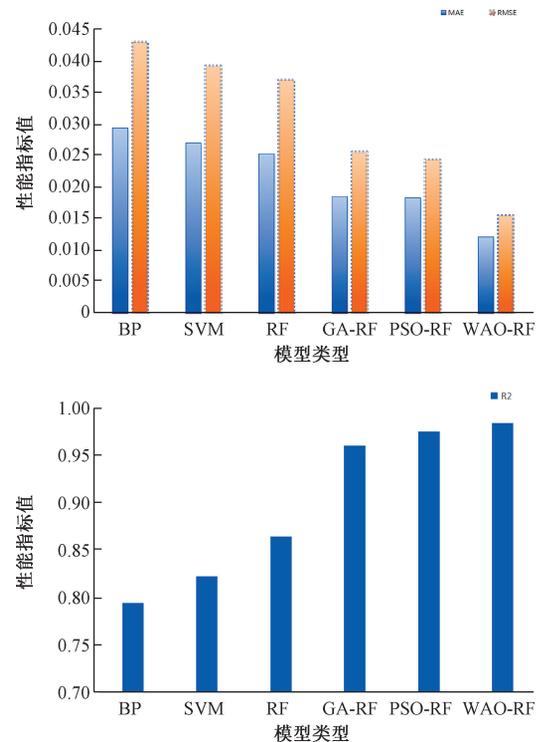


图 7 各模型评价指标对比
Fig. 7 Comparison of evaluation indexes of each model

4.3 低温下 WOA-RF 模型

为验证所提优化模型可靠性，将处于低温下所得的

放电循环数据进行训练,并同样在最后一次放电循环上进行验证得到不同温度预测曲线如图 8~10 所示。

表 3 不同预测模型性能评估指标

Table 3 Performance evaluation metrics of different prediction models

预测模型	MAE	RMSE	R^2
BP	0.029 5	0.043 2	0.795
SVM	0.027 1	0.039 4	0.823
GA-RF	0.018 6	0.025 7	0.972
PSO-RF	0.018 4	0.024 5	0.981

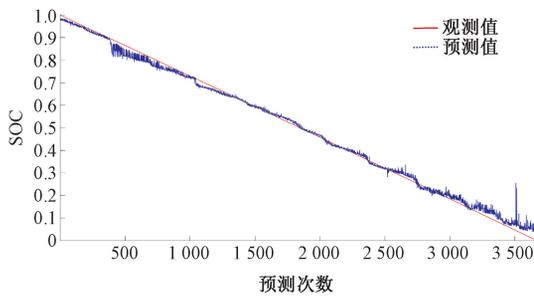


图 8 WOA-RF 模型 0 °C 预测曲线

Fig. 8 Prediction curve of WOA-RF model at 0 °C

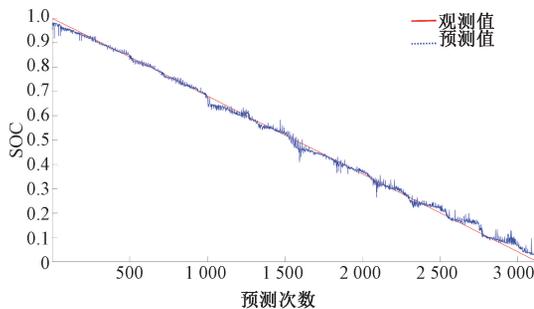


图 9 WOA-RF 模型 -10 °C 预测曲线

Fig. 9 Prediction curve of WOA-RF model at -10 °C

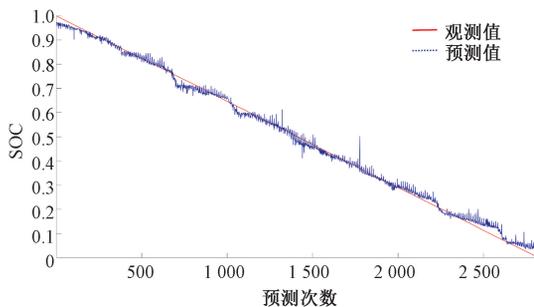


图 10 WOA-RF 模型 -20 °C 预测曲线

Fig. 10 Prediction curve of WOA-RF model at -20 °C

度和拟合性能,表明模型对于外界温度的抗干扰性较强,能够适应低温环境下的预测要求。

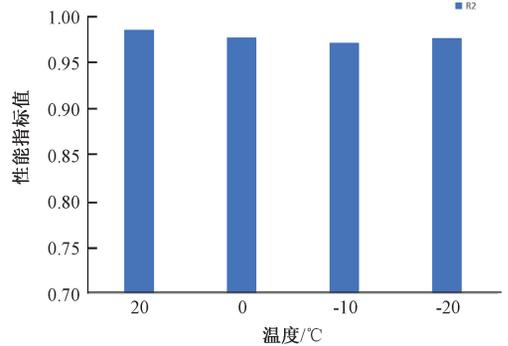
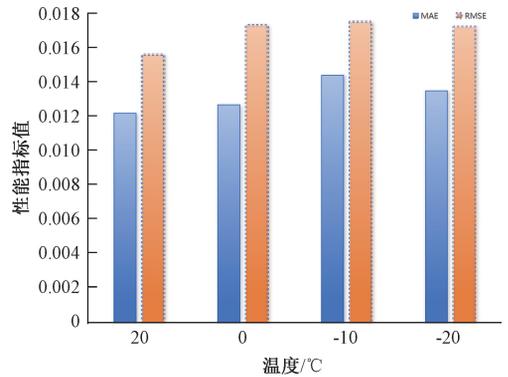


图 11 各温度评价指标对比

Fig. 11 Comparison of temperature evaluation indexes

表 4 各低温下性能评估指标

Table 4 Performance evaluation indexes at different low temperatures

数据温度/°C	MAE	RMSE	R^2
0	0.012 7	0.017 3	0.981
-10	0.014 4	0.017 5	0.979
-20	0.013 5	0.017 2	0.982

5 结 论

本研究围绕航空镍镉电池 SOC 预测这一关键技术问题展开,针对传统预测模型精度不足、环境适应性差的局限性,提出了一种融合 WOA 与 RF 的混合预测模型。研究的核心思路是通过集成随机森林的多决策树优势处理非线性特征,并引入改进的鲸鱼优化算法对 RF 的核心超参数进行全局寻优,从而提升模型的预测精度与泛化能力。核心技术包括基于 CART 算法和 Bagging 抽样技术的随机森林回归模型构建,以及结合混沌理论自适应权重的 WOA 算法优化方法,有效解决了传统人工调参效率低下和模型易陷入局部最优的问题。技术难点在于如何在极端温度环境下保持模型的鲁棒性,以及通过自适应权重机制平衡算法的全局搜索与局部开发能

如图 11 和表 4 所示,所提出的 WOA 模型在不同温度下对航空镍镉蓄电池的 SOC 预测同样具有较高的精

力。实验结果表明,WOA-RF 模型在标准温度下的 MAE 低至 1.22%, R^2 高达 0.986, RMSE 为 1.56%,显著优于传统 RF、BPNN、SVR 等模型;在低温环境下($-20\text{ }^{\circ}\text{C} \sim 0\text{ }^{\circ}\text{C}$),其 MAE 仍保持在 1.5%以内, RMSE 保持在 1.75%以内, R^2 高于 0.975,展现出卓越的环境适应性。本文研究不仅验证了 WOA-RF 模型在航空镍镉电池 SOC 预测中的先进性和必要性,还为极端工况下的电池状态监测提供了可靠的技术支持,具有工程应用价值。

参考文献

- [1] SENTHILKUMAR M, TANUJA K, SATYAVANI T, et al. Effect of temperature and discharge rate on electrochemical performance of fiber Nickel-Cadmium cell [J]. Russian Journal of Electrochemistry, 2022, 58(1): 43-49.
- [2] ZHANG T, DUAN W-L, HUANG S-L, et al. Improving design of the temperature-controlling device for aircraft Ni-Cd battery [J]. Chinese Journal of Power Sources, 2008, 32(11): 772-775.
- [3] TEKIN M, KARAMANGIL M I. Comparative analysis of equivalent circuit battery models for electric vehicle battery management systems [J]. Journal of Energy Storage, 2024, 86(11): 177-184.
- [4] HOW D N T, HANNAN M A, LIPU M S H, et al. State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review [J]. IEEE Access, 2019, 7(4): 136116-136136.
- [5] FENG F, LU R G, ZHU C B. A combined state of charge estimation method for lithium-ion batteries used in a wide ambient temperature range [J]. Energies, 2014, 7(5): 3004-3032.
- [6] PILLAI P, SUNDARESAN S, KUMAR P, et al. Open-circuit voltage models for battery management systems: A review [J]. Energies, 2022, 15(18): 304-332.
- [7] GARCÍA-PLAZA M, SERRANO-JIMÉNEZ D, CARRASCO J E G, et al. A Ni-Cd battery model considering state of charge and hysteresis effects [J]. Journal of Power Sources, 2015, 275(4): 595-604.
- [8] ZENG Y, LI Y, YANG T. State of charge estimation for lithium-ion battery based on unscented Kalman filter and long short-term memory neural network [J]. Batteries-Basel, 2023, 9(7): 618-624.
- [9] ZHANG R F, XIA B Z, LI B H, et al. State of the art of lithium-ion battery SOC estimation for electrical vehicles [J]. Energies, 2018, 11(7): 147-152.
- [10] GUO N, FANG Y, TIAN Z L, et al. Research on SOC fuzzy weighted algorithm based on GA-BP neural network and ampere integral method [J]. The Journal of Engineering, 2019, 2019(15): 576-580.
- [11] 姜洁,戴龙泉,王勇. 基于 PSO-SVM 的电动汽车电池 SOC 估算方法 [J]. 电源技术, 2015, 39(3): 521-532.
LOU J, DAI L Q, WANG Y. SOC estimation method of electric vehicle battery based on PSO-SVM [J]. Power Technology, 2015, 39(3): 521-532.
- [12] 孙爱芬,赤娜. 基于改进的高斯过程回归的 SOC 估计算法 [J]. 储能科学与技术, 2022, 11(1): 253-257.
SUN AI F, CHI N. SOC estimation algorithm based on improved Gaussian process regression [J]. Energy Storage Science and Technology, 2022, 11(1): 253-257.
- [13] YU H Q, ZHANG L S, WANG W T, et al. State of charge estimation method by using a simplified electrochemical model in deep learning framework for lithium-ion batteries [J]. Energy, 2023, 278(7): 253-267.
- [14] ZIEGLER A, KÖNIG I R. Mining data with random forests: Current options for real-world applications [J]. Wiley Interdisciplinary Reviews-Data Mining and Knowledge Discovery, 2014, 4(1): 55-63.
- [15] 白浩,潘姝慧,邵向潮,等. 基于小波去噪与随机森林的配电网高阻接地故障半监督识别方法 [J]. 电力系统保护与控制, 2022, 50(20): 79-87.
BAI H, PAN SH H, SHAO X CH, et al. A high impedance grounding fault semi-supervised identification method based on wavelet denoising and random forest [J]. Power System Protection and Control, 2022, 50(20): 79-87.
- [16] 张国治,陈康,方荣行,等. 基于 DGA 与鲸鱼算法优化 Logit Boost-决策树的变压器故障诊断方法 [J]. 电力系统保护与控制, 2023, 51(7): 63-72.
ZHANG G ZH, CHEN K, FANG R X, et al. Transformer fault diagnosis based on DGA and a whale algorithm optimizing a Logit Boost-decision tree [J]. Power System Protection and Control, 2023, 51(7): 63-72.
- [17] 张建涛,刘志祥,张双侠,等. 基于 WOA-RF 的边坡稳定性预测模型 [J]. 高压物理学报, 2024, 38(3): 194-205.
ZHANG J T, LIU ZH X, ZHANG SH X, et al. Slope stability prediction model based on WOA-RF [J]. Chinese Journal of High Pressure Physics, 2024, 38(3): 194-205.
- [18] UTKIN L V, KOVALEV M S, COOLEN F P A. Imprecise weighted extensions of random forests for classification and regression [J]. Applied Soft Computing, 2020, 92(1): 153-157.
- [19] SINGH A. Laplacian whale optimization algorithm [J]. International Journal of System Assurance Engineering

and Management, 2019, 10(4): 713-730.

- [20] KAUR G, ARORA S. Chaotic whale optimization algorithm [J]. Journal of Computational Design and Engineering, 2018, 5(3): 275-284.
- [21] XIA Y H, YE Z H, HUANG L M, et al. Research on a high-precision state-of-charge estimation method based on forgetting factor recursive least squares and adaptive extended Kalman filter applied to LiFePO4 battery [J]. Electronics, 2023, 12(17): 374-381.

作者简介



雷晓犇, 1996 年于空军工程学院获得学士学位, 1999 年于空军工程学院获得硕士学位, 2018 年于西北工业大学获得博士学位, 现为空军工程大学教授, 主要研究方向为装备智能检测与健康管理。

E-mail: leixiaoben@aliyun.com

Lei Xiaoben received a B. Sc. degree and M. Sc. degree from the Air Force Engineering University in 1996 and 1999, and Ph. D. from Northwestern Polytechnical University in 2018. Now he is a professor at Air Force Engineering University. His main research interests include intelligent equipment detection and

health management.



胡新华 (通信作者), 2023 年于空军工程大学获得学士学位, 现为空军工程大学硕士研究生, 主要研究方向为航空电力系统分析与控制。

E-mail: 19856471735@163.com

Hu Xinhua (Corresponding author)

received a B. Sc. degree from Air Force Engineering University in 2023. Now he is a M. Sc. candidate at Air Force Engineering University. His main research interests include the analysis and control of aviation power systems.



王浩, 2022 年于空军工程大学获得学士学位, 2024 年于空军工程大学获得硕士学位, 现为空军工程大学博士研究生, 主要研究方向为等离子体流动控制。

E-mail: 496706722@qq.com

Wang Hao received a B. Sc. degree from

Air Force Engineering University in 2022 and a M. Sc. degree from the same university in 2024. Now he is a Ph. D. candidate at Air Force Engineering University. His main research interest includes plasma flow control.