DOI：10.13234/j.issn.2095-2805.2026.4.196 **中图分类号**：TM912.4 **文献标志码**：A

基于鲸鱼算法优化 CNN 对叉车电池 SOH 进行预测

徐泽明(中国电源学会学生会员)，李凯昂，顾玉琦，赵 超
(浙江农林大学光机电工程学院，杭州 310000)

摘要：铅酸电池健康状态 SOH(state of health)是铅酸电池可靠运行的重要指标，针对叉车电池的健康状态预测精确度低的问题，提出了1种基于鲸鱼算法 WOA(whale optimization algorithm)的卷积神经网络 CNN(convolutional neural networks)预测模型 WOA-CNN。该模型以 CNN 作为基础模型，为了进一步优化 CNN 模型的性能，引入鲸鱼算法作为1种全局优化方法，通过搜索空间中的最优解来优化CNN的权重和偏差。为了验证WOA-CNN模型的有效性，使用了叉车电池的实际数据集进行实验。实验结果表明，WOA-CNN 在预测叉车电池 SOH 时，相比于未优化的 CNN，均方误差、均方根误差、平均绝对误差、平均绝对百分比误差分别降低了 29.4%、19.7%、41.5%、19.5%；相比于传统的反向传播 BP(back propagation)神经网络，分别降低了 42.2%、31.1%、64.7%、54.8%，具有更小的预测误差、更高的准确性和稳定性。WOA-CNN 预测模型为电动叉车电池健康管理提供了有力的支持，从而延长电池寿命，并提高叉车的可靠性。

关键词：叉车电池；健康状态；鲸鱼算法；卷积神经网络

Predicting SOH of Forklift Batteries Based on CNN Optimized by Whale Optimization Algorithm

XU Zeming, *Student Member*, *CPSS*, LI Kai'ang, GU Yuqi, ZHAO Chao
(College of Optical, Mechanical and Electrical Engineering, Zhejiang Agriculture and Forestry University, Hangzhou 310000, China)

Abstract: The state of health (SOH) of lead-acid batteries is an important indicator for their reliable operation. A prediction model based on convolutional neural networks (CNN) optimized by the whale optimization algorithm (WOA) was proposed to solve the problem of low prediction accuracy of SOH of forklift batteries. First, CNN was taken as the basic model for the WOA-CNN model. Then, to further optimize the performance of the CNN model, the WOA algorithm was introduced to optimize the weight and bias of CNN by searching the optimal solution in space. To verify the validity of the WOA-CNN method, experiments were conducted using a real data set of forklift batteries. Experimental results show that the WOA-CNN model reduced the mean square error, root mean square error, mean absolute error and mean absolute percentage error in predicting the SOH of forklift batteries by 29.4%, 19.7%, 41.5% and 19.5% respectively compared with the unoptimized CNN neural network, and it reduced these errors by 42.2%, 31.1%, 64.7% and 54.8% respectively compared with the traditional BP neural network, exhibiting smaller prediction errors, higher accuracy and higher stability. The WOA-CNN prediction model provides strong support for the battery health management of electric forklifts, thus extending the battery life and improving the forklift reliability.

Keywords: Forklift battery; state of health (SOH); whale optimization algorithm (WOA); convolutional neural networks (CNN)

收稿日期：2023-11-20；**修回日期**：2024-01-05；**录用日期**：2024-01-22；**网络首发日期**：2024-04-26
基金项目：浙江省重点研发计划项目子项目(2023C02053)
This work is supported by Sub-projects of Zhejiang Key R&D Program under the grant 2023C02053

叉车主要用于装卸货物、堆存货物，在仓储、制造等短距离运输领域的应用范围十分广泛[1]。铅酸电池是电动叉车的主要电源之一，其生产技术成熟、可靠性高、生产成本低、环境适应性强。

电池储存和提供电能的能力由健康状态 SOH (state of health)这一指标表示，该指标反映了电池在使用过程中的老化程度和性能退化情况[2]。SOH 不仅会影响其使用寿命和性能，而且随着 SOH 的降低，电池难以满足电动叉车的供能要求，并进一步引发安全问题。因此，研究预测铅酸电池的 SOH 对科学管理和安全使用蓄电池具有重要意义[3]。

目前，SOH 的预测模型大致可分为 3 种类型。第一种是基于电池原理的电化学模型和等效电路模型。然而，电化学模型涉及大量热力学和动力学方程，预测过程比较复杂[4]；等效电路模型由于监测设备成本高、测试条件严格且参数识别困难，因此在在线应用方面存在一定的限制[5]。第二种是基于统计方法的高斯回归模型和统计滤波模型。高斯模型需要训练的参数较多，增加了模型计算的复杂性[6]；统计滤波模型在非稳态的电池工作系统中可能出现算法不稳定的问题，因此存在一定的局限性，并且此方法直接预测 SOH 比较困难，需要大量的样本数据[7-8]。第三种是基于数据驱动的方法，主要包括支持向量机、极限学习机和神经网络。卷积神经网络 CNN(convolutional neural networks)在 SOH 预测方面具有更高的准确性和更强的鲁棒性[9-12]；支持向量机的 SOH 快速准确估计方法具备较高的估计精度[13-14]。

与锂电池相比，铅酸蓄电池的结构、成分和工作原理均有较大不同。因此，难以用锂电池 SOH 的预测模型直接预测铅酸蓄电池的 SOH，无法提供较高的预测精度和适用性。针对上述问题，本文提出 1 种基于鲸鱼算法 WOA(whale optimization algorithm)的 WOA-CNN 铅酸电池 SOH 预测模型。该方法利用卷积神经网络对电池 SOH 的影响因素进行特征提取，快速捕捉数据的特征信息与数据间的相关性，然后构建 WOA-CNN 预测模型对参数进行优化以提高网络的全局搜索能力和学习效率，最后实现对铅酸电池 SOH 的精确预测，为全面评估电动叉车电池健康状态提供理论依据。

1　预测叉车电池 SOH 的 WOA-CNN 模型的提出

1.1　卷积神经网络

CNN 结构如图 1 所示[15]，在 CNN 模型的学习过程中，卷积层利用卷积核从输入样本中提取特征，并将这些特征作为下一层的输入，卷积层计算式为

$$c_i = f(\omega \times \boldsymbol{x}_{i:i+g-1} + b) \tag{1}$$

式中：f 为激活函数；ω 为卷积核；$\boldsymbol{x}_{i:i+g-1}$ 为 i 到 $i+g-1$ 的特征向量；g 为卷积核的大小；b 为偏置项。CNN 具有独特的局部相关性和权值共享结构，这种结构使得 CNN 能够从输入中提取特征和降低数据维度，从而减少模型中的特征参数数量和复杂度[16]。铅酸电池的数据具有时序性并呈现非线性关系，CNN 的这些特性可以提高模型的效率与预测准确性。

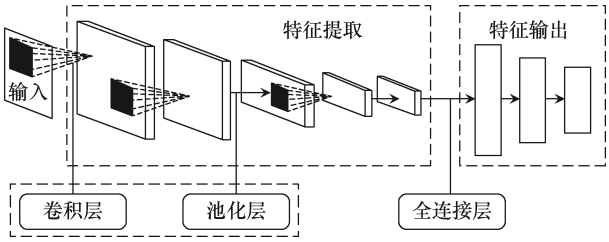


图 1　卷积神经网络结构示意

Fig. 1 Schematic of CNN structure

得到特征矩阵 $\boldsymbol{G}$，$\boldsymbol{G}=[c_1,c_2,\cdots,c_6]$，接着经过池化层，池化层经过采样获得更小维度的特征，即

$$N = \max(c_1, c_2, \cdots, c_{n-g+1}) \tag{2}$$

此处使用的是其最大值，最后将池化层提取的特征输入到全连接层进行特征融合和压缩，并利用激活函数对输入样本进行最终的分类或回归分析[3]。在电动叉车工作的过程中铅酸电池的电压、电流和温度的数据均是随时间变化的，这些变化与电池的 SOH 密切相关，即在局部时间段内，电压、电流和温度与相同的 SOH 预测值之间存在一致的关系。因此，本文利用卷积神经网络对铅酸电池在不同时间点的电压、电流和温度数据建立的数据集进行训练，以学习电压、电流和温度与 SOH 之间

的复杂关系，从而实现对铅酸电池的 SOH 进行预测。

鉴于卷积神经网络在部署时存在效率低的问题，为了提高其性能，本文采用 WOA 对卷积神经网络进行优化。WOA 通过模拟鲸鱼的行为和迁徙策略，能够在搜索空间中进行全局探索，并迅速收敛于全局最优解。

1.2 鲸鱼算法

WOA 是一种模拟座头鲸狩猎行为的启发式优化算法，其具有较高的全局搜索能力、较快的收敛速度、较好的鲁棒性和适应性且易于实现和应用[17]。该算法主要由泡泡网攻击和搜索猎物 2 个阶段组成[18]。

1.2.1 泡泡网攻击

该阶段分为包围猎物和螺旋更新位置 2 个步骤。

(1)包围猎物

WOA 假设座头鲸在发现猎物的位置后会围绕着猎物游动。由于无法确定猎物的位置，该算法假定当前的最佳位置就是目标猎物或最接近猎物的位置，接着其他搜索代理会尝试改变自己的位置，以成为最佳搜索代理[19]。其数学公式分别为

$$\boldsymbol{D}_1 = \left|\boldsymbol{C}\cdot\boldsymbol{X}_r(t) - \boldsymbol{X}_i(t)\right| \tag{3}$$

$$\boldsymbol{X}_i(t+1) = \boldsymbol{X}_s(t) - \boldsymbol{A}\cdot\boldsymbol{D}_1 \tag{4}$$

式中：$\boldsymbol{D}_1$ 为待求解个体与随机鲸鱼的距离向量；$\boldsymbol{X}_s(t)$ 为第 t 次迭代时某随机鲸鱼的位置向量；t 为迭代次数；$\boldsymbol{X}_i(t+1)$ 为当前鲸鱼 i 的位置向量；$\boldsymbol{C}$ 和 $\boldsymbol{A}$ 为系数向量，计算公式分别为

$$\boldsymbol{A} = (2r-1)a \tag{5}$$

$$\boldsymbol{C} = 2r \tag{6}$$

式中：a 为线性收敛因子；r 为区间[0, 1]中的随机值。

(2)螺旋更新位置

鲸鱼在攻击猎物时有其独特的攻击路径，就像螺旋运动，其数学表达式分别为

$$\boldsymbol{X}_i(t+1) = X^*(t) + \mathrm{e}^{mk}\cdot\cos(2\pi k)D_2 \tag{7}$$

$$D_2 = \left|X^*(t) - \boldsymbol{X}_i(t)\right| \tag{8}$$

式中：$X^*(t)$ 为第 t 次迭代时的最佳位置；m 为常数，用于确定对数螺旋的形状，通常取 1；k 为随机数，取值范围为[−1, 1]；D_2 为当前状态下的最优解。

当座头鲸追逐猎物时，它会形成 1 个收缩的圆圈，并沿着螺旋状路径移动，其数学模型为

$$\boldsymbol{X}_i(t+1) = \begin{cases} X^* - \boldsymbol{A}D & p<0.5 \\ X^*(t) + \mathrm{e}^{mk}\cdot\cos(2\pi k)D^* & p\geqslant 0.5 \end{cases} \tag{9}$$

式中：X^* 为最优位置；D 为当前鲸鱼位置与目标猎物位置之间的距离；D^* 为当前鲸鱼位置与全局最优位置 X^* 之间的距离；p 为区间[0, 1]的随机数。

根据式(5)对猎物进行收缩包围后，当距离猎物的系数 $|A|<1$ 时，鲸鱼个体会朝着最优位置逐渐逼近；在 $|A|<1$ 的前提下，$|A|$ 越大，鲸鱼个体越能在较大的空间范围内游动，WOA 的全局优化能力就越强；$|A|$ 越小，鲸鱼个体就能在更小的空间内搜索，仔细寻找猎物，使得鲸鱼算法具有更强的局部寻优能力[20]。

1.2.2 搜寻猎物

鲸鱼实际上是根据彼此的相对位置，通过随机搜索对方的位置来发现猎物的。为了驱使搜索代理远离本地鲸鱼，WOA 引入了 1 个随机值 $|A|$，该值大于等于或小于 1，其数学模型为

$$X(t+1) = \boldsymbol{X}_{\mathrm{rand}} - \boldsymbol{A}\cdot D \tag{10}$$

$$D = \left|\boldsymbol{C}\cdot\boldsymbol{X}_{\mathrm{rand}} - X\right| \tag{11}$$

式中：$X(t+1)$ 为鲸鱼个体在 $t+1$ 次迭代后的新位置；$\boldsymbol{X}_{\mathrm{rand}}$ 是随机位置向量；X 为鲸鱼个体在 t 次迭代后的位置。

1.3 鲸鱼算法优化的卷积神经网络

尽管卷积神经网络的结构参数(如层数、池化方法、激活函数等)在选择过程中可以基于经验进行决策，但训练过程中的初始参数(如迭代次数、批量大小和学习率)并没有明确的选择规则。这可能导致训练后的卷积神经网络陷入局部最优解[21-22]。

综上所述，本文结合 WOA，提出了 WOA-CNN 预测模型来提高 CNN 的全局搜索能力和收敛速

度，以获得 CNN 模型的全局最优参数，并对应最佳适应度值，WOA-CNN 模型的流程如图 2 所示。

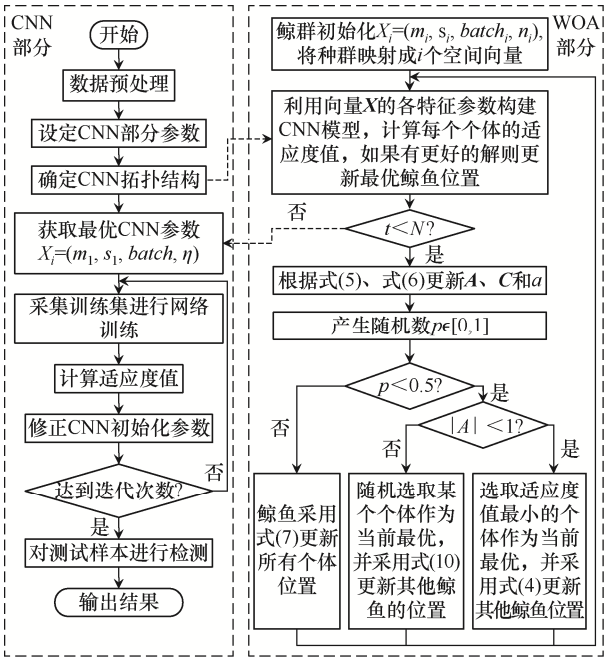


图 2　WOA-CNN 模型的流程

Fig. 2 Flow chart of WOA-CNN

本文采用 WOA 对 1 个卷积层的卷积核数量 m 、大小 s 、训练批次大小 batch 、学习率 η 进行优化，将上述 4 个参数映射为每个鲸鱼个体的空间向量位置，第 n 头鲸鱼的位置为

$$X_i=(m_i,s_i,\text{batch}_i,\eta_i) \tag{12}$$

WOA-CNN 工作的具体步骤如下。

(1)数据预处理，对采集到的数据进行归一化处理。

(2)数据集划分，将数据集按 3:1 的比例分为训练集和测试集。

(3)鲸群初始化，本文将鲸群种群个数设为 30，迭代次数 N 设为 20。

(4)捕食行为，捕食行为的具体步骤为：

步骤 1 对每只鲸鱼的位置进行更新，根据式(7)更新个体鲸鱼位置；

步骤 2 计算更新位置后鲸鱼的适应度值，使用更新后的 CNN 结构参数，分别在训练集和测试集上进行训练与测试，筛选出与当前一代最佳适应度值相对应的鲸鱼位置，并计算适应度值；

步骤 3 判断结束条件，判断迭代次数是否满足 $t>N$ ，如果不满足条件，则重新进行迭代计算，只有在满足条件时，局部深度搜索才会结束。

(5)进行猎物搜寻，经过 N 次迭代优化操作后，鲸群找到了平均损失值最小的一代，这一代对应的鲸鱼位置就是全局最优解，即猎物位置。

(6)模型重构，得到全局最优鲸鱼的位置 $X_i=(m_i,s_i,\text{batch}_i,\eta_i)$ 后，使用最优的卷积核数量、大小、训练批次和学习率这 4 个参数重新构建 CNN 模型，并分别在训练集和测试集上进行训练与测试。

1.4　WOA-CNN 预测 SOH 框架

基于 CNN 框架和 WOA 优化方法，可以构建铅酸电池 SOH 预测的框架，如图 3 所示。具体实现过程如下：

(1)使用电动叉车电池管理系统获取电动叉车工作过程中铅酸电池的电压、电流、温度等参数，对电流、电压、温度数据进行预处理；

(2)对获取的电池数据进行预处理并划分为训练集与测试集；

(3)利用 WOA 优化 CNN 算法的初始参数，建立 WOA-CNN 铅酸电池的 SOH 预测模型；

(4)将测试集数据分为不同样本输入训练好的 SOH 预测模型，进行铅酸电池 SOH 预测算法的测试验证。

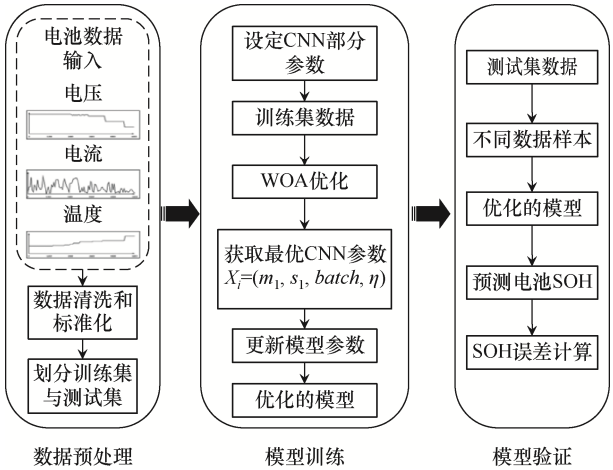


图 3　SOH 预测框架

Fig. 3 Framework for SOH prediction

2 基于WOA-CNN模型的数据集构建

2.1 铅酸电池

本文选择 D-600 型铅酸电池进行试验，将采集到的 75%的数据设为训练集，25%设为测试集。其主要技术参数见表 1。

表 1 D-600 型铅酸电池参数

Tab. 1 Parameters of D-600 lead-acid battery

参数	数值
额定电压/V	48
额定容量/(A·h)	600
充电电流/A	0.8
放电电流/A	1.2
放电电压范围/V	2.6~4.8

2.2 数据采集

铅酸电池 SOH 通常可以通过容量或内阻来进行预测。然而，在电动叉车电池管理系统中，无法通过在线方式实时获取铅酸电池的容量和内阻信息。因此，在电动叉车的运行过程中进行 SOH 的估算时，直接通过测量容量或内阻来衡量铅酸电池的 SOH 是不可行的。

电压、电流和温度是铅酸电池最基本的参数，也是电动叉车电池管理系统可以实时采集到的数据。在对铅酸电池采集到的数据进行分析后，发现电动叉车运行过程中的电压、电流和温度曲线会随着电动叉车工作状态的变化而变化。因此，本文以铅酸电池放电过程中的电压、电流和温度的数据作为 WOA-CNN 预测模型的输入，并将 SOH 作为输出。

本文的电动叉车电池数据集包含了 5 组叉车电池的测试数据，每个电池组由 24 块 D-600 型铅酸电池构成。在室温 25 ℃、充放电倍率为 0.3C、SOC 的上下限为 20%~80%之间的条件下，以标准恒流恒压充放电协议循环试验获得数据，并将每组测试数据随机分成 50 个样本。

本文从容量的角度定义 SOH 并实现对其进行预测，模型参数设置见表 2。

表 2 WOA-CNN 模型参数

Tab. 2 Parameters of WOA-CNN model

参数	数值/型号
输入层	电压、电流、温度
卷积层	Filters=64
全连接层	Unit=1
激活函数	ReLU
优化器	Adam

2.3 SOH 的定义

SOH 用于描述电池的剩余容量和性能与其初始容量和性能之间的比例关系，以评估电池的健康程度并预测其寿命。电池容量是指电池存储电荷的能力，本文从容量角度来定义 SOH，并将电动叉车工作过程中铅酸电池的电压、电流、温度作为输入，通过 WOA-CNN 模型实现对铅酸电池的 SOH 的预测。

2.4 模型的评价

为了定量评价鲸鱼算法优化卷积神经网络的有效性和准确性，本文采用均方误差 MSE(mean square error)、均方根误差 RMSE(root mean square error)、平均绝对误差 MAE(mean absolute error)和平均绝对百分比误差 MAPE(mean absolute percentage error)作为 WOA-CNN 模型的性能评价函数，分别表示为

$$E_{\mathrm{MSE}}=\frac{1}{M}\sum(x_i-t_i)^2 \tag{13}$$

$$E_{\mathrm{RMES}}=\sqrt{\frac{1}{M}\sum(x_i-t_i)^2} \tag{14}$$

$$E_{\mathrm{MAE}}=\frac{1}{M}\sum|x_i-t_i| \tag{15}$$

$$E_{\mathrm{MAPE}}=\frac{1}{M}\sum\frac{|x_i-t_i|}{t_i} \tag{16}$$

式中：M 为样本的数量；x_i 和 t_i 分别为第 i 个样本的预测值和实际值。

3 基于WOA-CNN模型预测铅酸电池SOH结果分析

3.1 WOA-CNN 模型的训练迭代

WOA-CNN 模型在训练迭代过程中的适应度

值见表 3。较小的适应度值表示解的质量更好，根据表 3 的数据可以观察到，从第 9 次迭代开始适应度值不再发生变化。这表明当适应度值为 0.010 808 时，卷积神经网络的初始化参数达到了最优状态，优化后得到的参数为：卷积核的数量 $m=16$、大小 $s=3\times3$、训练批次 $batch=30$、学习率 $\eta=0.001$。

表 3　WOA-CNN 模型适应度值

Tab. 3 Adaptation values of WOA-CNN model

迭代次数	适应度值
1	0.011 587
2	0.011 587
3	0.011 587
4	0.011 587
5	0.011 587
6	0.011 273
7	0.011 273
8	0.011 273
9~20	0.010 808

3.2 WOA-CNN 模型的预测结果

完成训练后，WOA-CNN 模型首先对即将退役的铅酸电池与正在工作的电池进行预测，结果如图 4 所示。可以看出，退役电池 SOH 低于 12%，最低达到 5.31%，电池已经无法正常工作；工作电池 SOH 大于 60%，最大值为 98.43%，这与

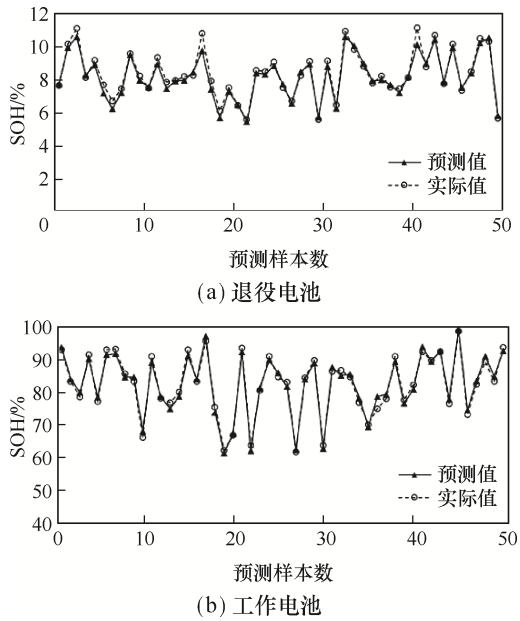


图 4　WOA-CNN 预测结果对比

Fig. 4 Comparison of WOA-CNN prediction results

WOA-CNN 预测值十分接近，证明了此模型的可行性。

为了直观反映算法性能，对输出误差取绝对值。通过观察图 5 中的数据分布，可以看到预测值的趋势和实际值非常相似，并且在大部分数据点上非常接近。其中，退役电池误差最大值为 0.10%，最小值为 0；工作电池误差总体不超过 0.10%，最大值为 0.10%，最小值为 0。这意味着通过该预测模型得到的结果与实际情况比较吻合，表明 WOA-CNN 模型预测 SOH 的效果较好。

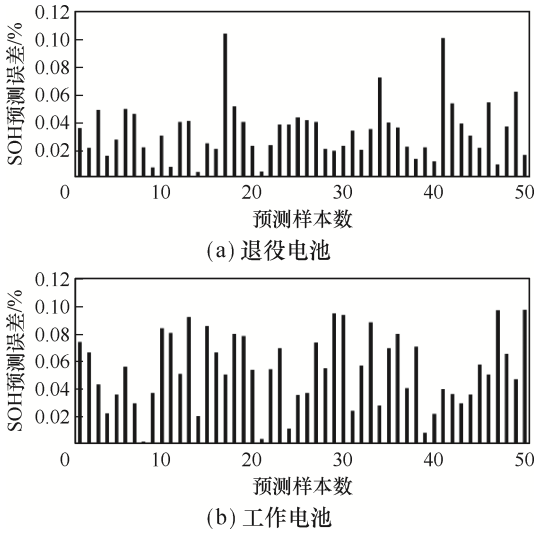


图 5　WOA-CNN 总体预测误差

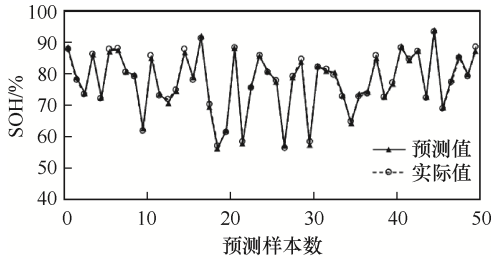
Fig. 5 Overall WOA-CNN prediction errors

为了验证此模型的准确性，本文选取了 2 组工作电池进行 SOH 预测，结果如图 6 所示。

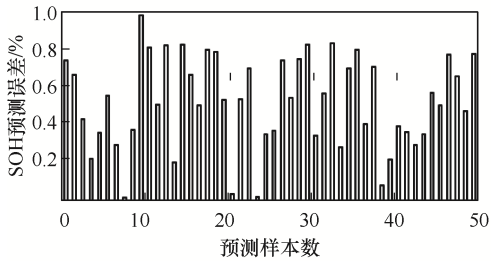
由图 6(a)和(c)可见，电池的预测值与实际值比较接近；由图 6(b)可见，测试电池 1 预测误差最大值为 0.980 0%，最小值为 0.010 0%；由图 6(d)可见，测试电池 2 预测误差最大值为 0.830 0%，最小值为 0.020 0%。总体而言，测试电池的 SOH 大多处于 50%以上，整体呈现出较好的健康状态，这与 WOA-CNN 模型预测结果所反映的电池状况形成呼应，进一步验证了 WOA-CNN 模型在铅酸电池 SOH 预测方面的准确性和可靠性。

为了进一步验证 WOA-CNN 预测模型的准确性，本文选取测试电池 3 并使用未优化的 CNN 与 BP 神经网络对铅酸电池 SOH 进行预测。WOA-

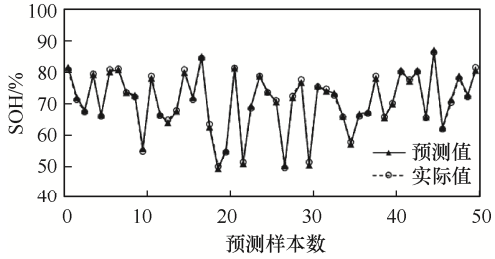
CNN 预测模型与未优化的 CNN 模型和 BP 神经网络模型预测误差的对比如图 7 所示。由图 7 可见，WOA-CNN 模型的预测误差最小，最大为 0.060 0%，最小为 0.000 9%；BP 神经网络模型的预测误差最大，最大为 0.120 0%，最小为 0.020 00%；CNN 模型的预测误差介于两者之间，最大为 0.110 0%，最小为 0.020 0%。这进一步验证了 WOA-CNN 模型在铅酸电池 SOH 预测方面的准确性和可靠性。



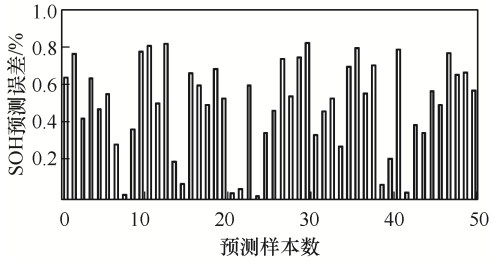
(a) 测试电池1预测结果



(b) 测试电池1预测误差



(c) 测试电池2预测结果



(d) 测试电池2预测误差

图 6 WOA-CNN 在测试电池中的预测结果及误差

Fig. 6 WOA-CNN prediction results and errors for test batteries

针对这 3 种模型的预测结果，本文进行了量化评估，并利用模型评价指标对它们进行了分析和对比。WOA-CNN 预测模型与 BP 神经网络模型和 CNN 模型进行对比训练后的评价结果见表 4。

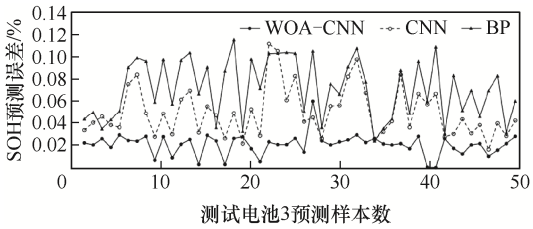


图 7 WOA-CNN，BP 和 CNN 预测结果对比

Fig. 7 Comparison of prediction results among WOA-CNN, BP, and CNN

表 4 模型预测性能分析

Tab. 4 Analysis of model predictive performance

模型	评价指标			
	MSE	RMSE	MAE	MAPE
WOA-CNN	0.152 2	0.390 1	0.315 1	0.038 3
CNN	0.215 6	0.485 7	0.538 6	0.047 6
BP	0.263 2	0.565 9	0.893 2	0.084 7

由表 4 可知，与 CNN 模型和 BP 神经网络模型相比，WOA-CNN 预测模型在所有指标上均表现出明显的改进。具体而言，相对于 CNN 模型，WOA-CNN 预测模型 MSE、RMSE、MAE、MAPE 分别降低了 29.4%、19.7%、41.5%、19.5%；相对于 BP 神经网络模型，WOA-CNN 预测模型 MSE、RMSE、MAE、MAPE 分别降低了 42.2%、31.1%、64.7%、54.8%，表明 WOA-CNN 预测模型具有更高的估计精度。

Sun 等[3]提出 1 种基于 CNN-BiLSTM-Attention 模型的铅酸电池的 SOH 预测方法，预测结果显示，预测误差在 3%左右；胡晨等[23]利用深度神经网络算法建模，对铅酸电池 SOH 进行估算，结果显示预测误差在 1%~5%之间；刘润兴等[24]设计了 1 种铅酸电池健康状态评估装置，运用交流注入法对电池进行交流阻抗谱的采集和测量，结果显示预测整体误差为 2%，最大误差小于 8%，这一结果进一步验证了 WOA-CNN 模型在铅酸电池预测方面的优越性和可靠性。

4　结语

利用 WOA 对卷积神经网络初始参数进行优化，建立了 WOA-CNN 模型，将电池的电压、电流和温度作为输入，以退役电池和工作电池对预测模型进行测试，利用测试电池 1 与测试电池 2 进行验证。实验结果显示，测试电池 1 与测试电池 2 的 SOH 预测误差控制在较低水平，最大值分别仅为 0.980 0%和 0.830 0%。进一步通过测试电池 3 开展多模型对比实验，结果表明：WOA-CNN 模型的预测性能最优，最大误差为 0.060 0%；未优化的 CNN 模型预测误差介于 WOA-CNN 与 BP 神经网络之间；传统 BP 神经网络模型的预测误差最大，达到 0.120 0%。因此，本文提出的鲸鱼算法优化的卷积神经网络在铅酸电池 SOH 预测上相比传统 BP 算法具有更优秀的性能，预测精度更高，效果更出色。

参考文献：

[1] 陈佩珊, 李思奇, 周嘉欣, 等. 叉车的发展概述及前景展望[J]. 起重运输机械, 2021(22): 19-24.
Chen Peishan, Li Siqi, Zhou Jiaxin, et al. Development overview and prospect of forklift truck [J]. Hoisting and Conveying Machinery, 2021(22): 19-24. (in Chinese)

[2] Huotari M, Arora S, Malhi A, et al. Comparing seven methods for state-of-health time series prediction for the lithium-ion battery packs of forklifts [J]. Applied Soft Computing, 2021, 111: 107670.

[3] Sun Shuo, Sun Junzhong, Wang Zongliang, et al. Prediction of battery SOH by CNN-BiLSTM network fused with attention mechanism [J]. Energies, 2022, 15(12): 4428.

[4] 申江卫, 周灿彪, 舒星, 等. 宽温度环境下基于改进电化学模型的锂电池荷电状态估计[J]. 储能科学与技术, 2023, 12(9): 2904-2916.
Shen Jiangwei, Zhou Canbiao, Shu Xing, et al. State of charge estimation for lithium batteries based on an improved electrochemical model at a wide temperature environment [J]. Energy Storage Science and Technology, 2023, 12(9): 2904-2916. (in Chinese)

[5] 刘虹灵, 别传玉, 宋华伟, 等. 基于等效电路模型 RBF 网络的电池容量快速预测[J]. 稀有金属, 2023, 47(6): 915-922.
Liu Hongling, Bie Chuanyu, Song Huawei, et al. Fast prediction of battery capacity based on equivalent circuit model and RBF network [J]. Chinese Journal of Rare Metals, 2023, 47(6): 915-922. (in Chinese)

[6] 吕佳朋, 史贤俊, 王康. 基于高斯过程回归的电池容量预测模型[J]. 电子测量技术, 2020, 43(3): 43-48.
Lü Jiapeng, Shi Xianjun, Wang Kang. Battery capacity prediction model based on Gaussian process regression [J]. Electronic Measurement Technology, 2020, 43(3): 43-48. (in Chinese)

[7] 刘子豪, 张雪松, 林达, 等. 基于扩展卡尔曼滤波的储能电池能量和功率状态联合估计方法[J]. 储能科学与技术, 2023, 12(3): 913-922.
Liu Zihao, Zhang Xuesong, Lin Da, et al. Joint energy and power state estimation method for energy storage battery based on extended Kalman filter [J]. Energy Storage Science and Technology, 2023, 12(3): 913-922. (in Chinese)

[8] 徐超, 李立伟, 杨玉新, 等. 基于改进粒子滤波的锂电池 SOH 预测[J]. 储能科学与技术, 2020, 9(6): 1954-1960.
Xu Chao, Li Liwei, Yang Yuxin, et al. Lithium-ion battery SOH estimation based on improved particle filter [J]. Energy Storage Science and Technology, 2020, 9(6): 1954-1960. (in Chinese)

[9] Yang Niankai, Song Ziyou, Hofmann H, et al. Robust state of health estimation of lithium-ion batteries using convolutional neural network and random forest [J]. Journal of Energy Storage, 2022, 48: 103857.

[10] 张凯飞, 张金龙, 吕满平. 基于 SSA-BPNN 的锂离子电池 SOH 估算[J]. 电源学报, 2024, 22(5): 278-285.
Zhang Kaifei, Zhang Jinlong, Lü Manping. Estimation of lithium-ion battery SOH based on SSA-BPNN [J]. Journal of Power Supply, 2024, 22(5): 278-285. (in Chinese)

[11] 陈媛, 段文献, 何怡刚, 等. 带降噪自编码器和门控递归混合神经网络的电池健康状态估算[J]. 电工技术学报, 2024, 39(24): 7933-7949.
Chen Yuan, Duan Wenxian, He Yigang, et al. Battery health state estimation with denoising autoencoder and gated recurrent hybrid neural network [J]. Transactions of China Electrotechnical Society, 2024, 39(24): 7933-7949. (in Chinese)

[12] 黄凯, 孙恺, 郭永芳, 等. 基于观测方程重构滤波算法的锂离子电池荷电状态估计[J]. 电工技术学报, 2024, 39(7): 2214-2224.
Huang Kai, Sun Kai, Guo Yongfang, et al. State of charge estimation of lithium-ion battery based on enhanced extended Kalman filter algorithm with observation equation reconstruction [J]. Transactions of China Electrotechnical Society, 2024, 39(7): 2214-2224. (in Chinese)

[13] 徐彬翔, 郑林锋, 黄乙恒, 等. 基于改进最小二乘支持向量机的锂离子电池健康状态快速估计方法[J]. 电气工程学报, 2022, 17(4): 11-19.
Xu Binxiang, Zheng Linfeng, Huang Yiheng, et al. Fast estimating the state of health of lithium-ion batteries based on improved least squares support vector machine [J]. Journal of Electrical Engineering, 2022, 17(4): 11-19. (in Chinese)

[14] 陆楠, 孙越, 彭鹏, 等. 数据驱动的钠离子电池健康状态评估方法研究[J]. 电源学报, 2024, 22(1): 1-10.
Lu Nan, Sun Yue, Peng Peng, et al. Research on data-driven health state evaluation method for sodium-ion batteries [J]. Journal of Power Supply, 2024, 22(1): 1-10. (in Chinese)

[15] Zhou Danhua, Li Zhanying, Zhu Jiali, et al. State of health monitoring and remaining useful life prediction of lithium-ion batteries based on temporal convolutional network [J]. IEEE Access, 2020, 8: 53307-53320.

[16] 陈峥, 李金元, 舒星, 等. 基于混合神经网络的锂离子电池健康状态估算[J]. 昆明理工大学学报(自然科学版), 2022, 47(3): 87-95.
Chen Zheng, Li Jinyuan, Shu Xing, et al. State of health estimation for lithium-ion battery based on hybrid neural network [J]. Journal of Kunming University of Science and Technology (Natural Sciences), 2022, 47(3): 87-95. (in Chinese)

[17] 赵丙秀, 董宁. 基于 WOA-BP 神经网络下马铃薯产量预测分析模型[J]. 农机化研究, 2024, 46(3): 47-51.
Zhao Bingxiu, Dong Ning. Potato yield prediction analysis model based on WOA-BP neural network [J]. Journal of Agricultural Mechanization Research, 2024, 46(3): 47-51. (in Chinese)

[18] Mohammed H M, Umar S U, Rashid T A. A systematic and meta-analysis survey of whale optimization algorithm [J]. Computational Intelligence and Neuroscience, 2019: 8718571.

[19] 赵家城, 孙坚, 徐红伟. 基于改进鲸鱼算法的锂电池模型参数辨识[J]. 电源学报, 2025, 23(7): 283-293.
Zhao Jiacheng, Sun Jian, Xu Hongwei. Parameter identification of lithium battery model based on improved whale optimization algorithm [J]. Journal of Power Supply, 2025, 23(7): 283-293. (in Chinese)

[20] 薛太林, 张超, 闫来清, 等. 基于 WOA-BP 神经网络的锂离子电池健康状态估算[J]. 山东电力技术, 2022, 49(10): 16-22, 37.
Xue Tailin, Zhang Chao, Yan Laiqing, et al. Health state estimation of lithium-ion battery based on WOA-BP neural network [J]. Shandong Electric Power, 2022, 49(10): 16-22, 37. (in Chinese)

[21] 陈国麟, 姚行艳. 基于 CNN-Transformer 的锂离子电池健康状态估计[J]. 重庆工商大学学报(自然科学版), 2024, 41(2): 66-73.
Chen Guolin, Yao Xingyan. State of health estimation of lithium-ion battery based on CNN-transformer [J]. Journal of Chongqing Technology and Business University (Natural Sciences Edition), 2024, 41(2): 66-73. (in Chinese)

[22] 张宇, 周天宇, 张永康, 等. 一种改进的 CNN-Seq2Seq 电池荷电与健康状态联合估计方法[J]. 电源学报, 2026, 24(1): 217-224.
Zhang Yu, Zhou Tianyu, Zhang Yongkang, et al. Improved CNN-Seq2Seq joint estimation method for SOC and SOH of batteries [J]. Journal of Power Supply, 2026,

(下转第 270 页)

Kang Jinsong, Han Renjie, Zhao Yuanzhe, etal. Robust predictive control technology for long-stator linear synchronous motor in maglev system [J]. Journal of Power Supply, 2026, 24(2): 291-300. (in Chinese)

[22] 庄莹, 裴玮, 刘子奇, 等. 提升低压直流配电稳定性的时滞模型预测附加控制[J]. 电工技术学报, 2023, 38(12): 3248-3263.
Zhuang Ying, Pei Wei, Liu Ziqi, etal. Time-delay model predictive additional control strategy to improve the stability of low-voltage DC distribution system [J]. Transactions of China Electrotechnical Society, 2023, 38(12): 3248-3263. (in Chinese)



王雪纯

作者简介：

王雪纯(2002—)，女，中国电源学会学生会员，本科。研究方向：有源电力滤波器的谐波补偿。E-mail：cynthia_hedwig@163.com。

龙波(1980—)，男，中国电源学会会员，通信作者，博士，副教授。研究方向：新能源发电系统及其控制。E-mail：longbo_1978@uestc.edu.cn。

(责任编辑：孙美菊)

(上接第 204 页)

24(1): 217-224. (in Chinese)

[23] 胡晨, 金翼, 崔邴晗, 等. 基于深度学习的铅酸电池健康状态估计[J]. 电池, 2021, 51(1): 63-67.
Hu Chen, Jin Yi, Cui Binghan, et al. State of health estimation of lead-acid battery based on deep learning [J]. Battery Bimonthly, 2021, 51(1): 63-67. (in Chinese)

[24] 刘润兴, 盖玉成, 杨品哲, 等. 基于交流阻抗谱的铅酸蓄电池健康状态检测[J]. 储能科学与技术, 2023, 12(11): 3499-3507.
Liu Runxing, Gai Yucheng, Yang Pinzhe, et al. Health-status detection of lead-acid battery based on AC impedance spectroscopy [J]. Energy Storage Science and Technology, 2023, 12(11): 3499-3507. (in Chinese)



徐泽明

作者简介：

徐泽明(1997—)，男，中国电源学会学生会员，硕士研究生。研究方向：电池管理系统，电池健康度预测。E-mail：1287754487@qq.com。

李凯昂(2001—)，男，硕士研究生。研究方向：数字化设计与制造技术。E-mail：1561611733@qq.com。

顾玉琦(1979—)，女，通信作者，博士，副教授。研究方向：电池管理系统，储能技术。E-mail：guyuqi@zafu.edu.cn。

赵超(1980—)，男，博士，教授。研究方向：电池管理系统，储能技术。E-mail：zhaochao@zafu.edu.cn。

(责任编辑：耿越)