

DOI: 10.19783/j.cnki.pspc.250681

# 基于贝叶斯神经网络与 H5N1 优化算法的电流互感器 J-A 模型磁滞参数高效识别

张鹏<sup>1</sup>, 张敏<sup>2</sup>, 黄伟<sup>1</sup>, 阮璇<sup>1</sup>, 龚新勇<sup>1</sup>, 杨鹏杰<sup>1</sup>, 杨博<sup>3</sup>

(1. 云南电网有限责任公司昆明供电局, 云南 昆明 650000; 2. 云南电力调度控制中心, 云南 昆明 650000;  
3. 昆明理工大学电力工程学院, 云南 昆明 650000)

**摘要:** 电流互感器 Jiles-Atherton 模型磁滞参数的精准识别对电力系统测量与保护至关重要, 但实际中测量噪声、数据采集不充分等问题会降低参数识别精度。为此, 提出一种基于贝叶斯神经网络(Bayesian neural network, BNN)与 H5N1 优化算法的电流互感器 J-A 模型磁滞参数识别策略。BNN 用于数据预处理, 包括数据去噪与预测, 以此提升数据质量。H5N1 优化算法则用于 J-A 模型磁滞参数的识别。同时, 选取其他多种元启发式算法进行对比验证。仿真结果表明, 基于 BNN 的数据预处理结合 H5N1 优化算法, 相较于未进行数据预处理的情况, 能显著提高磁滞参数识别的精度与稳定性, 为电流互感器 J-A 模型参数识别提供了更高效准确的方法。例如, 在去噪数据下, 准确率提高了 22.90%, 误差为 1.2386; 在预测数据下, 准确性提高了 89.33%, 误差为 0.7267。

**关键词:** 电流互感器; J-A 模型; H5N1 优化算法; 贝叶斯神经网络; 参数识别

## Efficient identification of J-A model hysteresis parameters for current transformers based on Bayesian neural network and H5N1 optimization algorithm

ZHANG Peng<sup>1</sup>, ZHANG Min<sup>2</sup>, HUANG Wei<sup>1</sup>, RUAN Xuan<sup>1</sup>, GONG Xinyong<sup>1</sup>, YANG Pengjie<sup>1</sup>, YANG Bo<sup>3</sup>

(1. Kunming Power Supply Bureau, Yunnan Power Grid Co., Ltd., Kunming 650000, China; 2. Yunnan Power Dispatching and Control Center, Kunming 650000, China; 3. Faculty of Electric Power Engineering, Kunming University of Science and Technology, Kunming 650000, China)

**Abstract:** Accurate identification of hysteresis parameters in the Jiles-Atherton (J-A) model of current transformers is crucial for power system measurement and protection. However, in practice, problems such as measurement noise and insufficient data acquisition often degrade parameter identification accuracy. To address these challenges, a J-A model hysteresis parameter identification strategy for current transformers based on a Bayesian neural network (BNN) and the H5N1 optimization algorithm is proposed. BNN is used for data preprocessing, including denoising and prediction, thereby improving data quality. The H5N1 optimization algorithm is used for identifying hysteresis parameters of the J-A model. Meanwhile, multiple metaheuristic algorithms are selected for comparative validation. Simulation results show that the combination of BNN based data preprocessing and H5N1 optimization algorithm can significantly improve the accuracy and stability of hysteresis parameter identification compared to approaches without data preprocessing, providing a more efficient and accurate method for parameter identification of current transformer J-A model. For example, under denoising data, the identification accuracy increases by 22.90%, with an error of 1.2386; under predicted data conditions, the accuracy is improved by 89.33%, with an error of 0.7267.

This work is supported by the National Natural Science Foundation of China (No. 62263014).

**Key words:** current transformer; J-A model; H5N1 optimization algorithm; Bayesian neural network; parameter identification

**基金项目:** 国家自然科学基金项目资助(62263014); 云南电网有限责任公司科技项目资助(YNKJXM20240333)“基于图形化的电网事故重构推演关键技术研究及应用”

## 0 引言

在电力系统的复杂架构中, 二次设备犹如精密的神经网络, 时刻保障着系统的稳定运行与高效管理。其中, 电流互感器作为关键组件, 发挥着不可或缺的作用<sup>[1-5]</sup>。它承担着将一次侧大电流精准转换为二次侧小电流的重要使命, 这一转换过程不仅关乎电力系统安全稳定运行的根基, 更是电能计量准确性的核心保障。电流互感器性能的优劣, 直接影响到电力系统的调度决策、故障诊断以及电能交易等关键环节, 一旦其出现偏差, 可能导致系统保护误动或拒动, 引发严重的电力事故, 甚至造成巨大的经济损失。因此, 深入研究电流互感器的相关特性与参数识别方法, 具有重要的现实意义和紧迫性<sup>[6-8]</sup>。

J-A 模型作为一种经典的磁滞模型, 能够较为精确地描绘电流互感器铁芯的磁滞特性。准确识别其中的 J-A 参数, 是利用该模型对电流互感器进行精确建模与分析的核心前提。通过精确的参数识别, 可以深入了解电流互感器在不同工况下的磁滞行为, 为电力系统的优化设计、故障预测以及性能提升提供坚实的理论依据<sup>[9]</sup>。然而, 在实际工程应用中, 电流互感器面临着复杂多变的运行环境。温度、湿度、电磁干扰等多种因素相互作用, 使得其磁滞特性并非一成不变。这种动态变化给 J-A 参数识别带来了诸多挑战, 传统的参数识别方法在应对复杂环境下的参数变化时, 往往显得力不从心<sup>[10-11]</sup>。

随着电力系统规模的不断扩大和智能化程度的日益提高, 对电流互感器性能监测与参数识别的精度和效率提出了更高的要求。在智能电网时代, 大量分布式电源接入、电力电子设备广泛应用, 使得电力系统的动态特性更加复杂<sup>[12-13]</sup>。电流互感器作为数据采集的关键节点, 其参数识别的准确性直接影响到整个电力系统的监控与控制效果。因此, 开展针对电流互感器 J-A 参数识别的高效、精准方法研究, 已成为当前电力系统领域的重要课题<sup>[14]</sup>。

目前, 针对电流互感器 J-A 参数识别, 研究人员已经提出并应用了多种方法。在传统方法中, 最小二乘法凭借其原理简单、计算便捷的特点, 在早期参数识别研究中得到了广泛应用。文献[15]通过构建目标函数, 利用测量数据与模型预测数据之间的误差平方和最小化来求解参数。然而, 最小二乘法对测量数据的噪声较为敏感。在实际工程中, 由于测量设备精度限制、数据采集环境复杂等因素, 获取的数据往往存在噪声、缺失值等问题。当数据存在较大噪声或异常值时, 最小二乘法的识别结果容易产生偏差, 导致参数识别精度下降。此外, 该

方法在处理非线性问题时, 需要复杂的迭代计算, 收敛速度较慢, 且可能陷入局部最优解, 难以保证全局最优性。

文献[16]针对目前辨识方法存在的计算时间长和寻优能力差等问题, 提出了一种改进的粒子群算法对 J-A 磁滞模型中的关键参数进行辨识。该算法将遗传选择策略引入到粒子群算法中, 通过增加粒子群的多样性来提高算法的全局搜索能力, 从而提高 J-A 磁滞模型关键参数辨识的准确度。但改进后的粒子群算法在参数优化过程中, 仍然受到算法自身参数设置的影响, 不同的参数组合可能导致不同的识别结果, 且在处理大规模数据时, 计算效率仍有待提高。

文献[17]针对现有 J-A 磁滞模型参数提取方法存在的收敛速度慢、求解精度低的问题, 提出一种基于随机性优化算法——模拟退火(simulated annealing, SA)与确定性优化算法(levengberg-marquardt, L-M)混合的 J-A 模型参数提取方法, 该方法综合了 SA 算法全局搜索能力强以及 L-M 算法局部收敛速度快的优点。然而, 混合算法的实现过程较为复杂, 需要合理调整两种算法的权重和切换时机, 否则可能导致算法性能不稳定, 且对初始参数的选择较为敏感。

此外, 上述方法在实际应用中还存在一个共同的问题, 即对数据的质量和数量要求较高。在实际工程中, 由于测量设备精度限制、数据采集环境复杂等因素, 获取的数据往往存在噪声、缺失值等问题, 且数据量可能有限。这在一定程度上限制了传统参数识别方法的性能, 导致识别结果不稳定、精度不高。

为了克服现有方法的不足, 提高电流互感器 J-A 参数识别的精度和效率, 本文提出一种基于贝叶斯神经网络(Bayesian neural network, BNN)进行数据预测扩充, 同时对数据进行加噪去噪处理, 采用 H5N1 优化算法进行二次设备电流互感器的 J-A 参数识别研究的新方法。通过利用贝叶斯神经网络对有限数据进行预测扩充, 可以生成更多符合实际分布的模拟数据, 从而丰富数据集, 提高数据的完整性和可靠性, 为后续的参数识别提供更优质的数据基础。对数据进行加噪及去噪处理, 能够进一步验证本文所提方法的鲁棒性。H5N1 优化算法具有独特的搜索机制和良好的全局寻优能力, 能够有效避免陷入局部最优解, 提高参数识别的精度和稳定性。将贝叶斯神经网络的数据预测扩充与 H5N1 优化算法的参数识别能力相结合, 有望为电流互感器 J-A 参数识别提供一种更加高效、精准的解决方案。本文的研究贡献如下:

1) 本文研究了数据不足、数据丢失和噪声数据

对 J-A 模型参数识别准确性的影响。基于 BNN 的数据预处理以降低噪声和预测数据集, 可以获得更准确的  $H$ - $B$  特性曲线, 从而提高精度。

2) 本文采用 H5N1 算法提高参数识别精度, 面对高维、非线性等复杂数据, 能精准捕捉特征关系, 利用优化技巧避免局部最优, 提升精度与鲁棒性。

3) 本文通过对 8 个算法的仿真结果进行比较, 验证了 H5N1 算法在去噪数据和预测数据上都优于其他算法。

## 1 Jiles-Atherton 磁滞模型

J-A 模型用于描述铁磁材料的磁滞行为, 基于磁畴壁运动的能量平衡原理, 其核心方程包括总磁化强度  $M$  与有效磁场强度  $H_{\text{eff}}$  的关系<sup>[18]</sup>。

1) 磁化强度分解方程

$$M = M_{\text{rev}} + M_{\text{irr}} \quad (1)$$

式中:  $M$  为总磁化强度;  $M_{\text{rev}}$  为可逆磁化分量;  $M_{\text{irr}}$  为不可逆磁化分量。

2) 不可逆磁化强度微分方程

$$\frac{dM_{\text{irr}}}{dH_{\text{eff}}} = \frac{\delta_M (M_{\text{an}} - M_{\text{irr}})}{k\theta} \quad (2)$$

$$H_{\text{eff}} = H + \alpha M \quad (3)$$

$$\delta_M = \begin{cases} 1 & \text{sgn}(M_{\text{an}} - M) \cdot \text{sgn}(dH/dt) \geq 0 \\ 0 & \text{sgn}(M_{\text{an}} - M) \cdot \text{sgn}(dH/dt) < 0 \end{cases} \quad (4)$$

式中:  $\delta_M$  为物理解约约束系数;  $M_{\text{an}}$  为无磁滞磁化强度(Langevin 函数描述, 见式(5));  $k$  为磁滞损耗系数;  $\theta$  为方向符号(+1 为  $dH/dt > 0$ , -1 为  $dH/dt < 0$ );  $H$  为外加磁场;  $\alpha$  为磁畴耦合系数。

3) 无磁滞磁化强度

$$M_{\text{an}} = M_s \left[ \coth\left(\frac{H_{\text{eff}}}{a}\right) - \frac{a}{H_{\text{eff}}} \right] \quad (5)$$

式中:  $M_s$  为饱和磁化强度;  $a$  为形状参数, 与材料特性相关。

4) 可逆磁化强度

$$M_{\text{rev}} = c(M_{\text{an}} - M_{\text{irr}}) \quad (6)$$

式中:  $c$  为可逆磁化系数(无量纲,  $0 \leq c \leq 1$ )。

5) 能量守恒方程

$$\mu_0 \delta_M \int M_{\text{an}} dH_{\text{eff}} = \mu_0 \delta_M \int M dH_{\text{eff}} + \mu_0 k \theta \int \frac{dM_{\text{irr}}}{dH_{\text{eff}}} dH_{\text{eff}} \quad (7)$$

式中:  $\mu_0$  为真空磁导率,  $\mu_0 = 4\pi \times 10^{-7}$ 。

6) J-A 逆模型

由式(1)一式(7), 可得 J-A 逆模型如式(8)所示。

$$\frac{dM}{dB} = \frac{\delta_M (M_{\text{an}} - M) + ck\theta \frac{dM_{\text{an}}}{dH_{\text{eff}}}}{\mu_0 \left\{ (1-\alpha) \left[ \delta_M (M_{\text{an}} - M) + ck\theta \frac{dM_{\text{an}}}{dH_{\text{eff}}} \right] + k\theta \right\}} \quad (8)$$

式中:  $B$  为磁化强度。

从以上 J-A 模型可看出, 其各参数具有明确的实际物理意义, 不正确的取值极易造成 J-A 模型辨识度的下降。待提取的 J-A 模型参数分别为  $M_s$ 、 $\alpha$ 、 $a$ 、 $c$ 、 $k$ <sup>[19]</sup>。

## 2 J-A 模型参数识别设计

### 2.1 贝叶斯神经网络

BNN 假设权重服从均值为  $\mu$ 、方差为  $\delta$  的高斯分布, 且每个权重对应独立的高斯分布。贝叶斯神经网络通过优化权重的均值和方差进行训练, 其结构如图 1 所示。

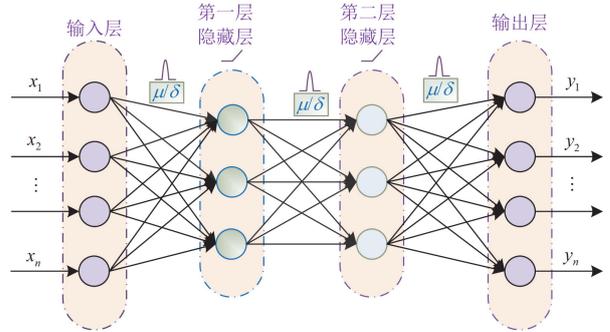


图 1 贝叶斯神经网络结构图

Fig. 1 Structure diagram of Bayesian neural network

在贝叶斯神经网络中, 模型参数  $\omega$  使用概率分布进行描述。首先, 基于先验经验, 引入一个先验分布  $p(\omega)$  来描述参数  $\omega$  可能取的值。假设已知实验数据集  $D = \{(x_1, t_1), (x_2, t_2), \dots, (x_n, t_n)\}$ , 其中  $x_n$  和  $t_n$  ( $n=1, 2, 3, \dots, N$ ) 分别为输入数据和输出数据,  $N$  为实验数据的数量。根据贝叶斯定理, 先验分布  $p(\omega)$  会按照文献[20]所述进行更新, 如式(9)所示。

$$p(\omega|D) = \frac{p(D|\omega)p(\omega)}{p(D)} \propto p(D|\omega)p(\omega) \quad (9)$$

式中:  $p(D|\omega)$  是一个似然函数, 其中包含了从观测数据中获得的关于参数  $\omega$  的信息;  $p(\omega|D)$  是已知数据  $D$  情况下参数  $\omega$  的后验概率分布, 即后验分布;  $p(D)$  是实验数据的分布, 它作为一个归一化常数, 确保后验分布是一个有效的概率密度函数。

似然函数  $p(D|\omega)$  通常采用高斯分布, 如式(10)所示。

$$p(D|\omega) = e^{-\frac{x^2}{2}} \quad (10)$$

$$X^2 = \sum_{n=1}^N \left( \frac{y(x, \omega) - t_n}{\Delta t_n} \right)^2 \quad (11)$$

$$y(x, \omega) = \varepsilon + \sum_{j=1}^L b_j \tanh \left( u_j + \sum_{i=1}^I d_{ij} x_{ij} \right) \quad (12)$$

式中:  $t_n$  为对应输入  $x_{ij}$  的真实观测量;  $\Delta t_n$  是与第  $n$  个数据相关的噪声误差;  $\varepsilon$  为隐藏层的权重;  $b_j$  为第  $j$  个隐藏层的偏差;  $u_j$  为第  $j$  个输出层的权重;  $d_{ij}$  为第  $j$  个输出层的第  $i$  个输入量的偏差;  $x_{ij}$  为第  $j$  个隐藏层神经元的第  $i$  个输入量;  $L$  为隐藏层神经元的数量;  $I$  为输入量的数量<sup>[21]</sup>。

## 2.2 H5N1 优化算法

H5N1 病毒独特而有效的特性, 尤其是其快速传播、突变和环境适应的能力, 是 H5N1 优化算法的灵感来源。H5N1 优化算法利用了病毒的适应性和动态特性。为了建立 H5N1 病毒的数学模型, 受病毒影响的群体最初分为两个不同的组: 家禽和人类。H5N1 病毒主要传播给家畜, 然后通过接触家禽及其排泄物、接触受污染的家居用品或食物、接触被感染者, 以此传播给感染率较低的人类<sup>[22]</sup>。

H5N1 优化算法提出了一种替代方案来调整病毒的位置, 可用于模拟 H5N1 病毒的行为, 如式(13)所示。

$$\begin{cases} x_j^i = p_{MP3,j}^i + R_j^i (F_{g,j}^i - F_{p,j}^i), P_{\text{attack}} < P_1 \\ x_j^i = x_j^i + \frac{R_j^i (p_{MP1,j}^i - p_{MP2,j}^i) + R_j^i (F_{g,j}^i - x_j^i)}{2}, P_{\text{attack}} \geq P_1 \end{cases} \quad (13)$$

式中:  $x_j^i$  为第  $i$  个病毒在第  $j$  维的位置;  $p_{MP1,j}^i$ 、 $p_{MP2,j}^i$  和  $p_{MP3,j}^i$  为第  $i$  个病毒在第  $j$  维生成的排列矩阵;  $R_j^i$  为第  $i$  个病毒在第  $j$  维的随机值[0,1]的矩阵;  $F_{g,j}^i$  为病毒在第  $j$  维的全局最优位置;  $F_{p,j}^i$  为第  $i$  个病毒在第  $j$  维局部最优位置;  $P_{\text{attack}}$  为病毒传播家禽的概率;  $P_1$  为病毒对家禽或人类的传播率。

对病毒如何因家禽和人类环境中的不利条件而变异进行建模, 构建可以捕获病毒突变特征的方程。

$$\overline{x_{\text{old},j}} = \overline{F_{g,j}} \quad (14)$$

$$\begin{cases} x_{\text{new},j}^i = x_j^i + R_j^i (F_{g,j}^i - x_j^i), P_{\text{attack}} < P_1; P_{\text{adapt}} \leq P_2 \\ x_{\text{new},j}^i = x_j^i + R_j^i (F_{g,j}^i - F_{p,j}^i), P_{\text{attack}} \geq P_1; P_{\text{adapt}} \leq P_2 \end{cases} \quad (15)$$

$$x_{\text{mutate},j}^i = c \times \frac{(x_{\text{new},j}^i + x_{\text{old},j}^i) r_3 w}{2} \quad (16)$$

式中:  $\overline{x_{\text{old},j}}$  表示病毒在第  $j$  维的先前全局最优位置分量;  $\overline{F_{g,j}}$  为病毒在第  $j$  维的全局最优位置分量;

$x_{\text{new},j}^i$  表示第  $i$  个病毒在第  $j$  维被搜索的新位置;  $x_{\text{mutate},j}^i$  表示第  $i$  个病毒在第  $j$  维突变后的位置;  $P_{\text{adapt}}$  为表征病毒适应性的随机参数;  $P_2$  表示感染后宿主存活概率或病毒的突变率, 即病毒适应的概率;  $r_3$  为[0,1]的随机数;  $w$  为权重系数。

H5N1 中最重要的参数之一是权重系数  $w$ , 它对维持病毒的有效利用起着重要作用。定义如式(17)所示。

$$w = w \times w_d \quad (17)$$

$$w_d = w_{\min} + (w_{\max} - w_{\min}) e^{-\left(\frac{t}{T}\right)} \quad (18)$$

式中:  $t$  为当前迭代次数;  $T$  为最大迭代次数;  $w_d$  为权重阻尼;  $w_{\min}$  为最小权重;  $w_{\max}$  为最大权重。

此外, 由于突变并不总是产生有利的结果, 因此需要一个系数来控制病毒的适应性, 其方程式如式(19)所示。

$$q = \frac{1}{1 + e^{-10(t/T - 0.5)}} + r_4(1 - p) \quad (19)$$

式中:  $r_4$  为[0,1]的随机数。

在更新全局最优值之前, 病毒的当前位置更新方式如式(20)所示。

$$x_j^i = x_{p,j}^i \times m_{xp} + x_j^i \times m_x \quad (20)$$

式中:  $x_{p,j}^i$  为父代病毒在第  $j$  维上的位置;  $m_x$  为当前病毒中突变系数的向量;  $m_{xp}$  为病毒种群中突变系数的向量。

最后, 算法将使用随机机制的全局最优解决方案进行更新, 如式(21)所示。

$$[F_g, X_g] = \begin{cases} [F(x_{\text{mutate}}), X_{\text{mutate}}], P_{\text{adapt}} \leq P_2 \text{ and } p_s \leq p \\ \min(F(x)), \text{others} \end{cases} \quad (21)$$

式中:  $F_g$  为全局最优位置;  $X_g$  表示保存所有病毒全局最优位置的二维矩阵;  $x_{\text{mutate}}$  表示病毒突变后的位置;  $X_{\text{mutate}}$  表示保存所有病毒突变后位置的二维矩阵;  $p_s$  为[0,1]的随机数。

## 2.3 目标函数

本文选取对误差高度敏感的拟合标准差——均方根误差(root mean square error, RMSE)作为算法的评价指标, 也就是目标函数。借此, 将 J-A 磁滞模型参数的提取问题转化为求解目标函数最小值的优化问题, 目标函数表达式如式(22)所示。

$$F_{\text{RMSE}} = \sqrt{\frac{\sum_{i=1}^N [H_{\text{real}}(i) - H_{\text{cal}}(i)]^2}{N}} \quad (22)$$

式中:  $H_{\text{real}}$  为磁场强度实测值;  $H_{\text{cal}}$  为磁场强度计

算值。

同时本文也采用拟合曲线的重叠度  $R^2$  作为评价指标, 表达式如式(23)所示。

$$R^2 = \frac{\sum_{i=1}^N (H_{cal}(i) - H_{real}(i))^2}{\sum_{i=1}^N (H_{real}(i) - \bar{H}_{real})^2} \quad (23)$$

式中:  $\bar{H}_{real}$  为输出磁场强度的实际平均值。

### 2.4 参数识别过程

本研究提出的基于BNN-H5N1的J-A模型参数识别过程主要包括数据采集、数据预处理和最优参数提取3个步骤, 如图2所示。

参数识别的具体流程见图3。实现过程如下: 首先, 收集J-A模型的磁场强度和磁通密度数据,

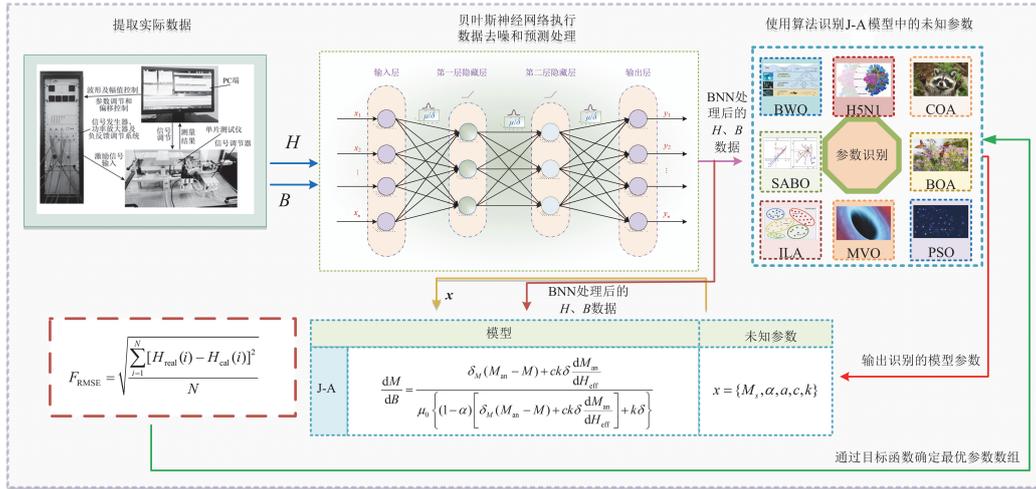


图2 基于BNN-H5N1的参数识别示意图

Fig. 2 Schematic diagram of parameter recognition based on BNN-H5N1

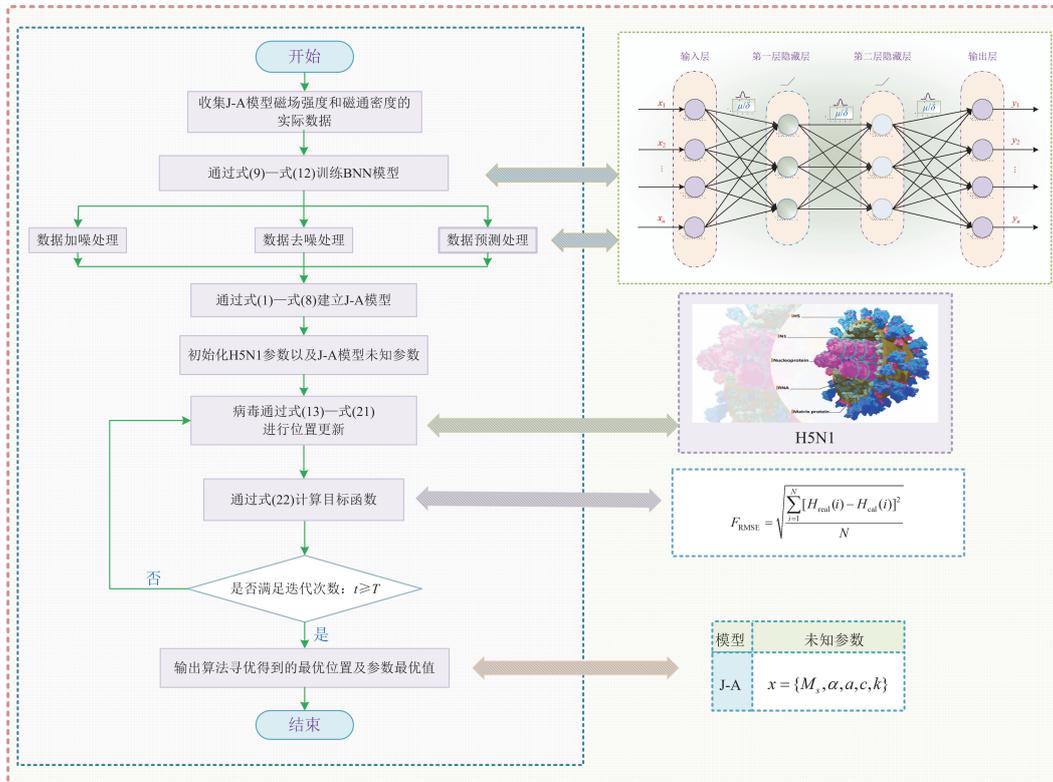


图3 基于BNN-H5N1的J-A模型参数识别流程图

Fig. 3 Flow chart of parameter recognition of J-A model based on BNN-H5N1

并基于这些数据训练 BNN 模型;接着,在数据预处理阶段对收集的数据进行去噪和预测,以获得更准确、更丰富的数据集;最后,利用 H5N1 优化算法从处理后的数据集中提取最优参数。具体识别步骤如表 1 所示。

表 1 基于 BNN-H5N1 的 J-A 模型参数识别步骤

Table 1 Steps of BNN-H5N1-based J-A model parameter identification

- 1 确定 J-A 模型;
- 2 收集 J-A 模型的实测  $H-B$  数据;
- 3 通过 BNN 对测量的  $H-B$  数据进行加噪、去噪及预测处理;
- 4 初始化 H5N1 的病毒种群规模等参数;
- 5 设置  $t=0$ ;
- 6 WHILE  $t \leq T$
- 7 FOR1  $I=1:s$
- 8 通过式(13)确定第  $i$  个个体感染动物或人类;
- 9 通过式(15)更新感染后第  $i$  个个体的位置;
- 10 通过式(16)更新第  $i$  个个体突变后的位置;
- 11 通过式(22)计算第  $i$  个个体的适应度值;
- 12 END FOR1
- 13 设置  $t=t+1$ ;
- 14 END WHILE
- 15 输出 J-A 模型的最优参数。

## 2.5 比较时间复杂度分析

在分析 BNN-H5N1 的时间复杂度时,有必要考虑 BNN 训练、算法初始化和主循环的成本。BNN 的训练成本很高,表示为  $O(A \cdot R \cdot f^2)$ ,其中  $A$  是训练周期的数量, $R$  是参数的数量, $f$  是每层的神经元数量,具体取决于网络结构和训练数据量。算法的初始化阶段包括随机选择个体并评估目标函数,时间复杂度分别为  $O(s \cdot d)$  和  $O(s \cdot C_{obj})$ 。其中  $s$  是总体大小, $d$  是维度, $C_{obj}$  表示目标函数成本。主循环基于函数求值的最大次数。因此,BNN-H5N1 的总时间复杂度约为  $O(\text{Max\_Sun-Eval} \cdot (s \cdot d + s \cdot C_{obj}) + A \cdot R \cdot f^2)$ 。

## 3 算例分析

由于工作环境复杂,J-A 模型容易受到噪声的影响。这种噪声会影响 J-A 模型的参数识别,导致最终识别结果不准确。本文采用了 BNN 方法,进一步关联并减少了数据中的噪声。BNN 去噪的结果如图 4 所示。

实际上,数据量在一定程度上会影响参数识别的准确性。然而,有时磁场强度和磁通密度数据不足且难以获取。因此,本文通过 BNN 对现有的  $H-B$  数据进行训练,然后进行数据预测。图 5 展示了通过 BNN 获得的预测结果。

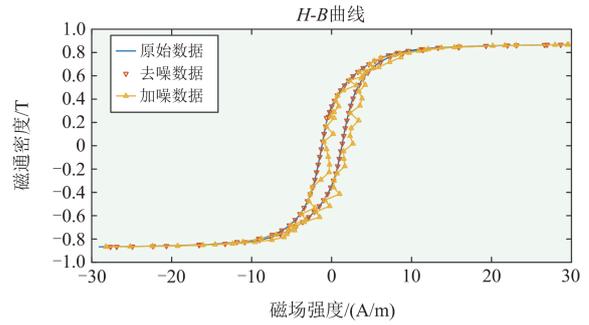


图 4 基于 BNN 的数据去噪结果图

Fig. 4 Data denoising results based on BNN

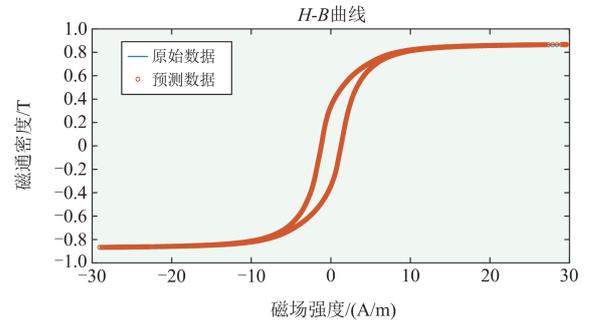


图 5 基于 BNN 的数据预测结果图

Fig. 5 Data prediction results based on BNN

在本节中,BNN 和 8 种元启发式算法,包括 H5N1、蝴蝶优化算法(butterfly optimization algorithm, BOA)<sup>[23]</sup>、白鲸优化算法(beluga whale optimization, BWO)<sup>[24]</sup>、智能实时逻辑算法(intelligible-in-time logics algorithm, ILA)<sup>[25]</sup>、多元宇宙优化算法(multi-universe optimization, MVO)<sup>[26]</sup>、粒子群优化(particle swarm optimization, PSO)<sup>[27]</sup>、基于减法平均的优化器(subtraction average based optimizer, SABO)<sup>[28]</sup>和改进的海鞘群优化算法(improved salp swarm algorithm, ISSA)<sup>[29]</sup>被用来提取 J-A 模型的参数。表 2 列出了每种元启发式算法的主要参数。在基于元启发式算法的参数识别之前,训练好的 BNN 被用于预测、去噪和添加噪声到收集的数据中。利用预测数据、加噪数据、去噪数据和原始数据,8 种元启发式算法均被用来识别 J-A 模型的未知参数。

### 3.1 加噪及去噪数据

表 3 展示了使用不同元启发式算法对加噪数据和去噪数据的参数识别结果。其中,“N”和“DN”分别代表使用加噪数据和去噪数据的结果。对于 H5N1 算法,在噪声数据下识别得到的 RMSE 为 1.5222;而去噪数据下的 RMSE 降低至 1.2386。这表明去噪处理显著提高了参数识别的准确性,降低了预测误差。通过对比不同算法在去噪前后的参数

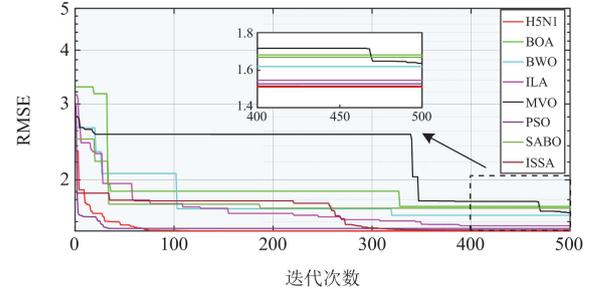
表 2 各元启发式算法的参数设置

算法	参数	数值
H5N1	$P_1$ (感染概率)	0.8
	$P_2$ (存活概率)	0.85
BOA	$p$ (蜕变概率)	0.8
BWO	$\alpha$ (随机维度)	0.8
ILA	$N_1$ (模型数量)	2
	$m_1$ (第一阶段迭代百分比)	0.33
	$m_2$ (第二阶段迭代百分比)	0.33
	$B_{min}$ (边界最小值)	0.4
	$B_{max}$ (边界最大值)	0.6
PSO	$c_1$ (自学系数)	2
	$c_2$ (集体学习系数)	2
	$w_p$ (惯性权重)	0.6
所有算法	$T$ (最大迭代次数)	500
	$S_A$ (种群数量)	30
	$R_n$ (运行次数)	10

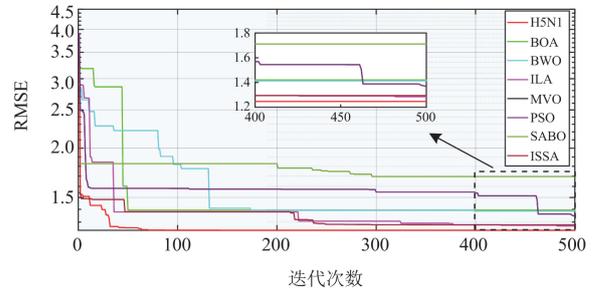
识别结果,可以发现各算法在去噪效果上存在差异。其中 MVO 的减少幅度最大,达到了 24.56%。相比之下, SABO 的减少幅度最小,为 1.42%,其次是 BOA 减少了 24.52%, PSO 减少了 24.37%, ILA 减少了 23.19%, H5N1 减少了 22.90%, BWO 减少了 19.41%, ISSA 减少了 19.53%。这表明不同算法在去噪能力和参数识别精度上各有优势。

图 6 展示了 RMSE 的收敛曲线。可以看出,基于去噪数据的结果在收敛精度、稳定性和速度上都

优于使用噪声数据的结果。同时可以看出,不管是在噪声数据和去噪数据上, H5N1 在收敛速度以及识别精度上都明显优于其他算法,充分展现了其卓越的性能。



(a) 噪声数据



(b) 去噪数据

图 6 8 种算法在噪声数据和去噪数据下获得的 RMSE 收敛曲线

Fig. 6 Convergence curves of RMSE obtained by eight algorithms under noisy data and denoising data

表 3 基于 8 种算法的 J-A 模型噪声数据和去噪数据的参数识别结果

Table 3 Parameter identification results of noise data and denoising data of J-A model based on eight algorithms

算法	数据	未知参数					RMSE
		$a$	$k$	$c$	$\alpha$	$M_s$	
H5N1	N	1.1522	2.3790	0.1658	$1.1657 \times 10^{-6}$	$7.1953 \times 10^5$	1.5222
	DN	1.3661	2.4836	0.1839	$2.3959 \times 10^{-6}$	$7.2656 \times 10^5$	<b>1.2386</b>
BOA	N	1.0822	3.3163	0.2097	$2.2965 \times 10^{-6}$	$7.1827 \times 10^5$	1.7353
	DN	1.3686	4.0309	0.4125	$2.2331 \times 10^{-6}$	$7.3071 \times 10^5$	<b>1.3936</b>
BWO	N	1.0000	5.0000	0.5855	$1.0000 \times 10^{-6}$	$7.1698 \times 10^5$	1.6552
	DN	1.0000	3.0197	0.4127	$1.0000 \times 10^{-6}$	$7.1779 \times 10^5$	<b>1.3862</b>
ILA	N	1.2515	2.3664	0.2001	$2.1170 \times 10^{-6}$	$7.2221 \times 10^5$	1.5655
	DN	1.1069	2.6197	0.2315	$1.1831 \times 10^{-6}$	$7.1963 \times 10^5$	<b>1.2708</b>
MVO	N	1.2824	4.6572	0.5236	$2.9170 \times 10^{-6}$	$7.2462 \times 10^5$	1.6766
	DN	1.6606	2.8505	0.3031	$2.9940 \times 10^{-6}$	$7.3706 \times 10^5$	<b>1.3460</b>
PSO	N	1.4151	2.3637	0.1427	$3.0000 \times 10^{-6}$	$7.2554 \times 10^5$	1.5430
	DN	1.4534	2.4964	0.1780	$3.0000 \times 10^{-6}$	$7.2860 \times 10^5$	<b>1.2407</b>
SABO	N	1.1115	5.0000	0.4726	$2.8391 \times 10^{-6}$	$7.194 \times 10^5$	1.7192
	DN	1.8852	3.5118	0.2829	$2.6792 \times 10^{-6}$	$7.4742 \times 10^5$	<b>1.6951</b>
ISSA	N	1.2496	2.4776	0.1618	$2.0038 \times 10^{-6}$	$7.2178 \times 10^5$	1.5287
	DN	1.3074	3.8456	0.4502	$2.7083 \times 10^{-6}$	$7.2569 \times 10^5$	<b>1.2789</b>

图 7 展示了 10 次迭代后各算法 RMSE 的分布情况。从图中得出, 经过数据去噪处理后, 大部分算法的 RMSE 分布范围均显著缩减, 其上下限值也随之降低, 异常值得到有效抑制甚至被完全消除。这一现象充分表明, 数据去噪显著提升了各算法在参数识别过程中的优化准确性与稳定性。其中, H5N1 算法在去噪前后均展现出极高的稳定性, 其箱线图几乎呈现为一条直线, 凸显了该算法在复杂数据处理环境下的卓越性能与可靠性。

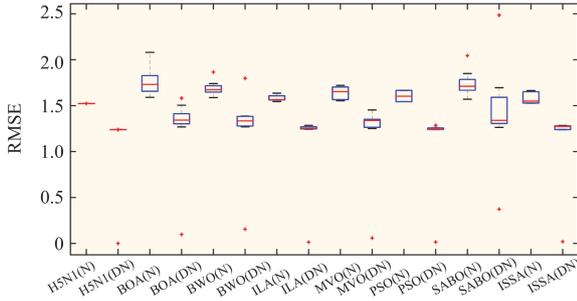


图 7 加噪数据和去噪数据下 8 种算法的 RMSE 箱型图  
Fig. 7 Box plot of RMSE of eight algorithms under noisy data and denoising data

图 8 展示了在去噪数据中, 通过 8 种算法中性能最优的 H5N1 算法所获得的  $H-B$  曲线。观察结果显示,  $H-B$  曲线的重叠度  $R^2$  为 8.6037%, 这表明参数识别结果符合预期。

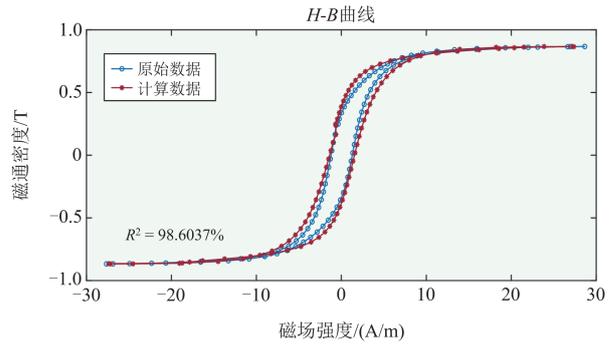


图 8 基于去噪数据的 H5N1 算法拟合曲线  
Fig. 8 Fitted curve of H5N1 algorithm based on denoising data

### 3.2 原始及预测数据

表 4 总结了在不同训练数据下, 8 种算法的识别结果。其中, “O” 表示原始数据, “P” 表示预测数据。对于 H5N1 算法, 在原始数据下识别得到的 RMSE 为 1.3758; 而在预测数据下, RMSE 降低至 0.7267。这表明预测数据在某些情况下能够更准确地反映系统特性。通过对比不同算法在原始数据与预测数据下的表现, 可以评估各算法的适用性和鲁棒性。结果显示, BWO 的减少幅度最大, 达到了 93.45%。相比之下, PSO 的减少幅度最小, 仅为 9.33%, 其次是 ILA 减少了 90.43%, H5N1 减少 89.33%, SABO 减少了 70.35%, ISSA 减少了 68.58%, MVO 减少了 66.31%, BOA 减少了 50.93%。

表 4 基于 8 种算法的 J-A 模型原始数据与预测数据的参数识别结果

Table 4 Parameter identification results of the original data and predicted data of J-A model based on eight algorithms

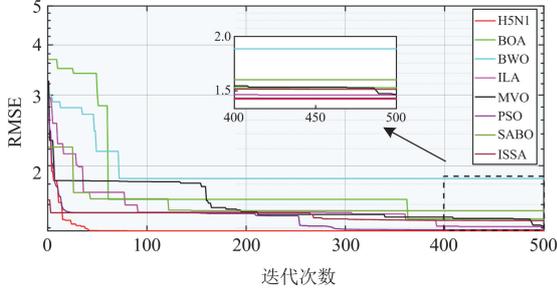
算法	数据	未知参数					RMSE
		$a$	$k$	$c$	$\alpha$	$M_s$	
H5N1	O	1.2173	2.3851	0.1694	$1.7317 \times 10^{-6}$	$7.2114 \times 10^5$	1.3758
	P	1.0000	1.7793	0.5993	$1.0000 \times 10^{-6}$	$7.1611 \times 10^5$	<b>0.7267</b>
BOA	O	1.2061	2.3401	0.2676	$1.6873 \times 10^{-6}$	$7.2235 \times 10^5$	1.4738
	P	1.1251	2.0753	0.7771	$1.5273 \times 10^{-6}$	$7.1793 \times 10^5$	<b>0.9765</b>
BWO	O	1.7748	3.9340	0.4223	$2.9829 \times 10^{-6}$	$7.4264 \times 10^5$	1.8577
	P	1.2126	1.4614	0.3343	$2.9747 \times 10^{-6}$	$7.2050 \times 10^5$	<b>0.9603</b>
ILA	O	1.1097	2.6609	0.2265	$1.4184 \times 10^{-6}$	$7.1875 \times 10^5$	1.4097
	P	1.0000	1.5952	0.5293	$1.0357 \times 10^{-6}$	$7.1640 \times 10^5$	<b>0.7403</b>
MVO	O	1.4066	2.4884	0.1612	$2.2822 \times 10^{-6}$	$7.2712 \times 10^5$	1.4148
	P	1.2054	1.8523	0.5720	$2.1711 \times 10^{-6}$	$7.2171 \times 10^5$	<b>0.8507</b>
PSO	O	1.3934	2.4064	0.1547	$3.0000 \times 10^{-6}$	$7.2514 \times 10^5$	1.3846
	P	1.2180	4.0062	1.0000	$3.0000 \times 10^{-6}$	$7.2006 \times 10^5$	<b>1.2664</b>
SABO	O	1.2319	4.7453	0.5911	$2.8623 \times 10^{-6}$	$7.2303 \times 10^5$	1.5447
	P	1.0000	3.3268	0.8553	$1.0000 \times 10^{-6}$	$7.1756 \times 10^5$	<b>0.9068</b>
ISSA	O	1.1780	2.9270	0.3011	$1.7638 \times 10^{-6}$	$7.2125 \times 10^5$	1.4596
	P	1.1770	1.4719	0.4040	$2.2886 \times 10^{-6}$	$7.2048 \times 10^5$	<b>0.8658</b>

从图 9 可以看出, 虽然部分算法收敛速度较原始数据慢, 但预测数据结果的误差统一比原始数据

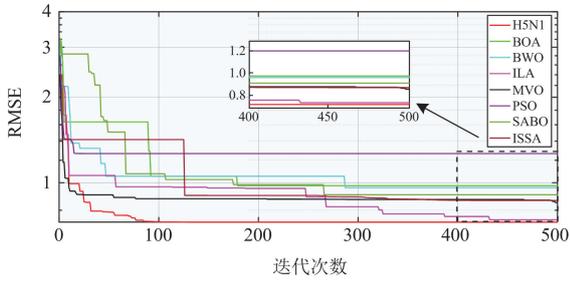
结果小。

从图 10 中可以清晰地观察到, 相较于基于原始

数据所得的结果, 利用预测数据计算出的 RMSE 的上限、下限以及中位数均呈现出了明显的下降趋势。其中, H5N1 算法在预测前后均展现出了极高的稳定性以及精确度。



(a) 原始数据



(b) 预测数据

图 9 8 种算法在原始数据和预测数据下获得的 RMSE 收敛曲线

Fig. 9 RMSE convergence curves obtained by eight algorithms under the original data and predicted data

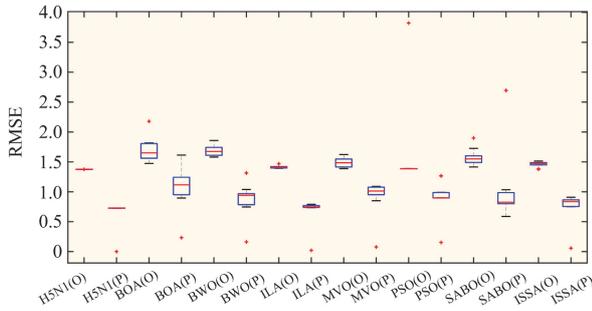


图 10 原始数据和预测数据下 8 种算法的 RMSE 箱型图  
Fig. 10 Box plot of RMSE for eight algorithms under original data and predicted data

图 11 展示了在预测数据中, 通过 8 种算法中性能最优的 H5N1 算法所获得的  $H-B$  曲线。观察结果显示,  $H-B$  曲线的重叠度  $R^2$  为 99.4201%。这一数据证明了参数识别结果的精确性符合预期标准, 同时也凸显了数据扩充策略在显著提升参数识别精度方面所发挥的关键作用。

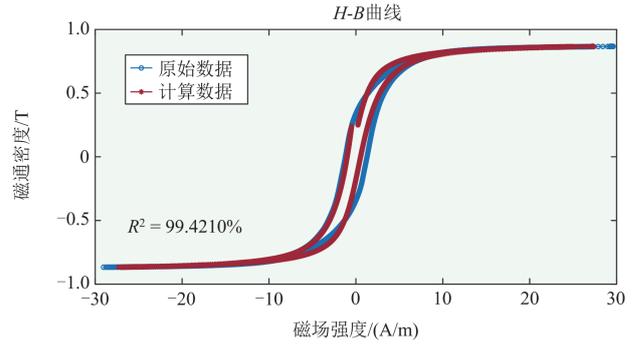


图 11 基于预测数据的 H5N1 算法拟合曲线

Fig. 11 Fitted curve of H5N1 algorithm based on predicted data

### 3.3 敏感度分析

稳健的元启发式算法模型通常对参数的敏感性较低。在确保剩余参数和训练测试数据不变的情况下, 使用控制变量法对构建的 H5N1 模型进行了参数敏感性测试。所选的灵敏度测试参数包括感染概率、存活概率以及最大迭代次数。通过将种群数量和最大迭代次数的数值上下浮动 20%, 重新训练和测试模型, 以比较它们在测试精度方面的变化, 结果如图 12 所示。总体而言, H5N1 模型对上述参数的敏感性相对较弱, 即使上述参数上下波动 20%, 其测试的均方根误差基本无波动。

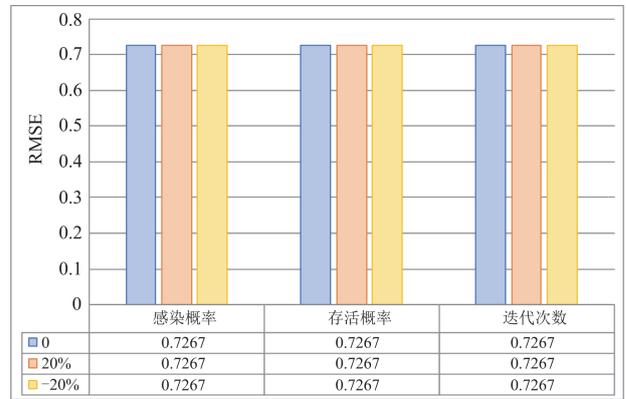


图 12 在关键参数上下波动 20% 的情况下 BNN-H5N1 的测试精度比较

Fig. 12 Comparison of testing accuracy of BNN-H5N1 under key parameters with 20% up and down fluctuations

### 3.4 结果对比

为清晰地展示每个元启发式算法的性能, 本文采用雷达图展示基于去噪数据以及预测数据的 8 种算法的 5 个 RMSE 指标, 即最小值、最大值、标准差、中位数和平均值。分数越高, 算法的 RMSE 值越低, 参数识别性能越好。在图 13 中, H5N1 算法的 5 个 RMSE 指标均低于其他 7 种算法, 表明 H5N1 算法在识别 J-A 模型参数方面具有最高的准确性。

同样地, 在图 14 中, 基于预测数据, H5N1 算法在 J-A 模型参数识别上表现出绝对的准确性。综上所述, 经过 BNN 处理后, H5N1 算法在识别 J-A 模型参数方面的能力远超其他算法。

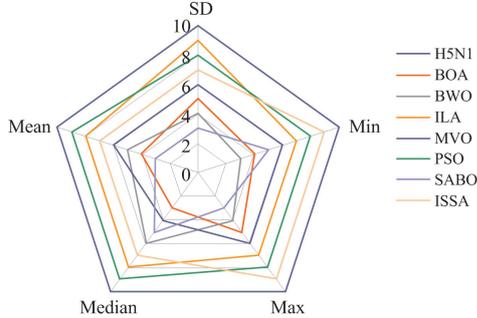


图 13 8 种算法在去噪数据下的 5 种 RMSE 指标雷达图

Fig. 13 Radar chart of five RMSE indexes of eight algorithms under denoising data

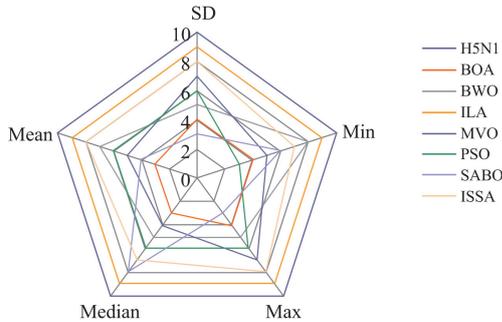


图 14 8 种算法在预测数据下的 5 种 RMSE 指标雷达图

Fig. 14 Radar chart of five RMSE indicators for eight algorithms under prediction data

## 4 结论

本文提出了一种基于贝叶斯神经网络与 H5N1 优化算法的电流互感器 J-A 模型磁滞参数高效识别方法。通过 BNN 对电流互感器相关数据进行预处理, 有效减轻了数据噪声、数据不足以及数据缺失等不利因素对参数识别的影响, 提升了数据质量。随后, 利用 H5N1 优化算法对 J-A 模型磁滞参数进行识别。

实验结果显示, 经过 BNN 数据预处理(包括去噪与预测)后, 磁滞参数识别的准确性得到显著提高。与现有相关算法相比, 所提方法在参数识别精度和可靠性方面更具优势。此外, 准确提取电流互感器 J-A 模型磁滞参数对于优化实际电力系统的测量与保护具有重要意义。

在未来研究中, 可将 BNN 与 H5N1 优化算法的组合应用于电流互感器其他相关数据的处理, 进

一步提升磁滞参数识别的精度, 构建更为稳定、准确的电流互感器 J-A 模型, 为电力系统的安全稳定运行提供更有力的支持。

## 参考文献

- [1] 牛伟民, 樊艳芳, 张鑫宇, 等. 基于阻抗幅值波动差异的新型参数识别方向元件[J]. 电力系统保护与控制, 2023, 51(3): 117-125.  
NIU Weimin, FAN Yanfang, ZHANG Xinyu, et al. Novel parameter identification directional element based on impedance amplitude fluctuation difference[J]. Power System Protection and Control, 2023, 51(3): 117-125.
- [2] 徐文浩, 徐启峰, 谢楠. 基于四电平编码与弱光通信的极低功耗传光式电流互感器[J]. 电力系统保护与控制, 2024, 52(5): 148-157.  
XU Wenhao, XU Qifeng, XIE Nan. An ultra-low power optical current transformer based on four-level coding and weak-light communication[J]. Power System Protection and Control, 2024, 52(5): 148-157.
- [3] 席瑞翎, 季亮, 姜恩宇, 等. 基于参数自修正的配电网故障定位数字孪生技术研究[J]. 电力系统保护与控制, 2024, 52(11): 11-20.  
XI Ruiling, JI Liang, JIANG Enyu, et al. Digital twin of distribution network fault location based on parameter self-correction[J]. Power System Protection and Control, 2024, 52(11): 11-20.
- [4] 姚力, 许灵洁, 李舜, 等. 基于数字比较法的宽频标准电流互感器溯源技术研究[J]. 电测与仪表, 2024, 61(8): 97-103.  
YAO Li, XU Lingjie, LI Shun, et al. Research on traceability technology of broadband standard current transformer based on digital comparison method[J]. Electrical Measurement & Instrumentation, 2024, 61(8): 97-103.
- [5] 徐文浩, 徐启峰, 谢楠. 基于四电平编码与弱光通信的极低功耗传光式电流互感器[J]. 电力系统保护与控制, 2024, 52(5): 148-157.  
XU Wenhao, XU Qifeng, XIE Nan. An ultra-low power optical current transformer based on four-level coding and weak-light communication[J]. Power System Protection and Control, 2024, 52(5): 148-157.
- [6] 张鼎衢, 杨路, 肖勇, 等. 基于零磁通原理的宽量程电流互感器传变特性[J]. 南方电网技术, 2024, 18(11): 150-158.  
ZHANG Dingqu, YANG Lu, XIAO Yong, et al. Transfer characteristics of wide-range current transformer based on zero-flux theorem[J]. Southern Power System Technology, 2024, 18(11): 150-158.
- [7] 王波, 尹仕红, 肖勇, 等. 基于 RFC-SAGA-RBF 的直流偏磁下 CT 畸变电流反衍方法[J]. 南方电网技术, 2024, 18(12): 51-61.  
WANG Bo, YIN Shihong, XIAO Hong, et al. Inverse propagation method of CT distortion current under dc bias based on RFC-SAGA-RBF[J]. Southern Power System

- Technology, 2024, 18(12): 51-61.
- [8] YANG B, LIANG B, QIAN Y, et al. Parameter identification of PEMFC via feedforward neural network-pelican optimization algorithm[J]. Applied Energy, 2024, 361.
- [9] YANG B, LI D Y, ZENG C Y, et al. Bald eagle search algorithm for parameter identification of proton exchange membrane fuel cell[J]. Frontiers in Energy Research, 2022, 10.
- [10] YANG B, ZENG C, WANG L, et al. Parameter identification of proton exchange membrane fuel cell via Levenberg-Marquardt backpropagation algorithm[J]. International Journal of Hydrogen Energy, 2021, 46(44): 22998-23012.
- [11] YANG B, CHEN Y, GUO Z, et al. Levenberg- Marquardt backpropagation algorithm for parameter identification of solid oxide fuel cells[J]. International Journal of Energy Research, 2021, 45: 17903-17923.
- [12] YANG B, WANG J, ZHANG X, et al. Comprehensive overview of meta-heuristic algorithm applications on PV cell parameter identification[J]. Energy Conversion and Management, 2020, 208.
- [13] YANG B, WANG J, ZHANG M, et al. A state- of-the-art survey of solid oxide fuel cell parameter identification: modelling, methodology, and perspectives[J]. Energy Conversion and Management, 2020, 213.
- [14] ZENG C, YANG B, HAN Y. Parameter identification for solid oxide fuel cell models: crucial comments[J]. Frontiers in Energy Research, 2022, 10.
- [15] KIS P, IVÁNYI A. Parameter identification of Jiles-Atherton model with nonlinear least-square method[J]. Physica B: Physics of Condensed Matter, 2003, 343(1): 59-64.
- [16] 曹伟, 王路, 雷民, 等. 基于改进粒子群算法的电流互感器 J-A 模型参数辨识[J]. 电测与仪表, 2021, 58(5): 70-77.  
CAO Yi, WANG Lu, LEI Min, et al. Parameter identification for J-A hysteresis model of current transformer based on improved particle swarm optimization algorithm[J]. Electrical Measurement & Instrumentation, 2021, 58(5): 70-77.
- [17] 刘任, 李琳, 王亚琦, 等. 基于随机性与确定性混合优化算法的 Jiles-Atherton 磁滞模型参数提取[J]. 电工技术学报, 2019, 34(11): 2260-2268.  
LIU Ren, LI Lin, WANG Yaqi, et al. Parameter extraction for Jiles-Atherton hysteresis model based on the hybrid technique of stochastic and deterministic optimization algorithm[J]. Transactions of China Electrotechnical Society, 2019, 34(11): 2260-2268.
- [18] 赵越, 李琳, 刘任. 基于人工鱼群与 Levenberg-Marquardt 混合算法的 Jiles-Atherton 磁滞模型参数提取[J]. 华北电力大学学报(自然科学版), 2018, 45(6): 21-27, 51.  
ZHAO Yue, LI Lin, LIU Ren. Artificial fish swarm and Levenberg-Marquardt hybrid algorithm-based parameter extraction of Jiles-Atherton hysteresis model[J]. Journal of North China Electric Power University (Natural Science Edition), 2018, 45(6): 21-27, 51.
- [19] 林希, 张浩民, 刘振祥. 基于收缩因子改进 PSO 算法的 J-A 磁滞模型参数辨识[J]. 电气工程学报, 2024, 19(1): 187-195.  
LIN Xi, ZHANG Haomin, LIU Zhenxiang. Parameter identification of J-A dynamic hysteresis model based on an improved constriction factor PSO algorithm[J]. Journal of Electrical Engineering, 2024, 19(1): 187-195.
- [20] PENG J, YANG M, TIAN Y, et al. Parameter identification for turbulence models in shock wave boundary layer interference using an improved Bayesian neural network[J]. Aerospace Science and Technology, 2025, 163.
- [21] YANG B, LI D Y, ZENG C, et al. Parameter extraction of PEMFC via Bayesian regularization neural network based meta-heuristic algorithms[J]. Energy, 2021, 228.
- [22] XUAN T, TIEN T B, NGOC H T. The H5N1 algorithm: a viral-inspired optimization for solving real-world engineering problems[J]. Engineering Computations, 2025, 42(3): 1024-1096.
- [23] ARORA S, SINGH S. Butterfly optimization algorithm: a novel approach for global optimization[J]. Soft Computing, 2019, 23(3): 715-734.
- [24] ZHONG C, LING G, MENG Z. Beluga whale optimization: a novel nature-inspired metaheuristic algorithm[J]. Knowledge-based Systems, 2022, 251.
- [25] MASOOMEH M, HOSEIN N. Incomprehensible but Intelligible-in-time logics: theory and optimization algorithm[J]. Knowledge-based Systems, 2023, 264.
- [26] NOREÑA G F L, GÓMEZ B V, BOLAÑOS I R, et al. An effective parameter estimation on thermoelectric devices for power generation based on multiverse optimization algorithm[J]. Results in Engineering, 2025, 25.
- [27] PREMKUMAR M, RAVICHANDRAN S, HASHIM T J T, et al. Fitness-guided particle swarm optimization with adaptive Newton-Raphson for photovoltaic model parameter estimation[J]. Applied Soft Computing, 2024, 167.
- [28] PAVEL T, MOHAMMAD D. Subtraction-average-based optimizer: a new swarm-inspired metaheuristic algorithm for solving optimization problems[J]. Heliyon, 2024, 10(15).
- [29] CAI Y, CHEN H. An improved salp swarm algorithm for permutation flow shop vehicle routing problem[J]. Scientific Reports, 2025, 15(1): 6704-6704.

收稿日期: 2025-06-26; 修回日期: 2025-07-18

作者简介:

张 鹏(1989—), 男, 硕士, 工程师, 研究方向为电力系统运行与控制; E-mail: 1121732303@qq.com

张 敏(1984—), 男, 硕士, 高级工程师, 研究方向为电网调度; E-mail: 407199543@qq.com

杨 博(1988—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为基于人工智能的新能源系统优化与控制。E-mail: yangbo\_ac@outlook.com

(编辑 魏小丽)