

DOI: 10.13382/j.jemi.B2205634

# 基于 IHHO-BP 神经网络的模拟电路故障诊断\*

王力<sup>1</sup> 张露露<sup>2</sup>

(1. 中国民航大学职业技术学院 天津 300300; 2. 中国民航大学电子信息与自动化学院 天津 300300)

**摘要:**针对模拟电路故障类型多、故障状态不稳定以及故障数据冗余,使得模拟电路故障诊断困难的问题,提出利用改进哈里斯鹰算法(improved Harris Hawks optimization, IHHO)优化反向传播(back propagation, BP)神经网络,实现模拟电路故障特征选择与诊断。首先,将非线性自适应因子、柯西变异和随机差分扰动引入哈里斯鹰算法,实现收敛速度和精度的提升;其次,采用 IHHO 对模拟电路的单一故障和组合故障仿真数据进行特征选择,完成数据预处理;最后,采用 IHHO-BP 算法,对预处理后的故障数据进行训练和测试,实现模拟电路故障诊断。诊断结果表明,所提方法的诊断精度相较于其他算法提升了 5.5%。

**关键词:**模拟电路;特征选择;故障诊断;改进哈里斯鹰算法;反向传播神经网络

**中图分类号:** TN4 **文献标识码:** A **国家标准学科分类代码:** 510.4030

## Fault diagnosis of analog circuit based on IHHO-BP neural network

Wang Li<sup>1</sup> Zhang Lulu<sup>2</sup>

(1. College of Vocational Technology, Civil Aviation University of China, Tianjin 300300, China;

2. School of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

**Abstract:** The improved Harris Hawks optimization algorithm (IHHO) is proposed to solve the problem that analog circuit fault diagnosis is difficult due to multiple fault types, unstable fault states and redundant fault data. IHHO optimized back propagation (BP) neural network to realize fault feature selection and diagnosis of analog circuits. Firstly, the nonlinear adaptive factor, Cauchy variation and stochastic difference perturbation are introduced into the Harris Hawks optimization algorithm to improve the convergence speed and accuracy. Secondly, IHHO is used to select the characteristics of the single fault and the combined fault simulation data of the analog circuit to complete the data preprocessing. Finally, IHHO-BP algorithm is used to train and test the preprocessed fault data to realize the fault diagnosis of analog circuits. The diagnostic results show that the proposed method improves the diagnostic accuracy by 5.5% compared with other algorithms.

**Keywords:** analog circuit; feature selection; fault diagnosis; improved Harris Hawks optimization; back propagation neural network

## 0 引言

现代电子工业中,模拟电路被广泛应用于国防、控制、通信和图像处理等领域,然而在运行期间发生的电路故障会对此类系统造成严重影响<sup>[1]</sup>。随着模拟电路集成度的日益增加,电路故障类型和故障状态复杂以及故障数据量大等问题,使得模拟电路故障诊断困难<sup>[2]</sup>。

传统模拟电路故障诊断方法主要分为测前模拟和测

后模拟,前者较为典型的方法为故障字典法和概率统计法,后者最具代表性的方法为参数辨识法和故障验证法。而传统诊断方法存在计算量大、过程繁琐、对经验依赖性过强等局限,近年来将人工智能算法引入模拟电路故障诊断<sup>[3-4]</sup>,其中神经网络泛化性能良好,计算能力强被广泛用于故障诊断,但由于其收敛速度慢、容易陷入局部极值等弊端使得模拟电路故障诊断精度低。因此,模拟电路故障诊断精度的提高成为该领域的研究热点。

模拟电路故障诊断精度的提高主要依赖故障特征选

收稿日期: 2022-06-29 Received Date: 2022-06-29

\* 基金项目: 国家自然科学基金民航联合基金(U1733119)、中央高校基本业务费项目(3122017107)资助

择<sup>[5]</sup>以及诊断模型的选择与优化<sup>[6]</sup>,群智能算法作为新兴人工智能算法,算法简单易实现、鲁棒性高且寻优能力强,日渐成为主流优化算法。文献[7-9]分别利用粒子群算法和遗传算法进行特征选择,维持特征数据结构的同时实现了数据降维。文献[10-12]分别利用粒子群算法和遗传算法优化 BP 神经网络的权重和阈值,实现 BP 神经网络的学习效率和诊断精度的提升。针对粒子群算法和遗传算法受参数限制严重,寻优路径单一且种群多样性差等局限,文献[13-15]提出利用参数较少,寻优策略多的 HHO 进行特征选择和诊断模型的优化,进一步实现特征数据更优选择以及诊断精度的提升。然而无法实现全局搜索和局部探索的平衡,易陷入局部最优解等问题是单一群智能算法的通病。

综上,针对上述问题,本文提出一种改进哈里斯鹰算法,实现对复杂数据的特征选择和诊断模型的优化。首先,对模拟电路进行故障仿真,确定故障类别得到故障数据;然后,利用 IHHO 结合 BP 神经网络完成故障数据的特征选择;最后,将特征选择后的最优子集作为输入,利用 IHHO 优化 BP 神经网络的权重和阈值,实现模拟电路的故障诊断。本文采用两种国际通用模拟电路 Sallen-Key 带通滤波电路和 CSTV 低通滤波电路验证所提方法的效果。

## 1 HHO

HHO 是模拟哈里斯鹰狩猎行为的一种新型群智能算法,算法的灵活度高,寻优策略多,主要分为全局搜索和局部探索两个阶段。

### 1.1 全局搜索

全局搜索与局部探索之间的平衡是影响群智能算法性能的关键,这两个阶段的转变由逃逸因子  $E$  决定:

$$E = E_0 \cdot E_1 \quad (1)$$

$$E_0 = 2 \left( 1 - \frac{t}{T} \right) \quad (2)$$

式中:  $E_0$  为  $(-1, 1)$  中的随机数,代表每次迭代中兔子的初始能量;  $E_1$  为线性自适应因子;  $T$  为最大迭代次数,当  $|E| \geq 1$  时算法进入全局搜索阶段。在此阶段,哈里斯鹰部署了两种位置更新策略,第 1 种策略为根据兔子的位置占据据点 ( $q < 0.5$ ),第 2 种策略为近距离栖息 ( $q \geq 0.5$ )。这两种策略被赋予了相等的概率  $q$ ,  $X(t+1)$  的更新规则如下:

$$X(t+1) = \begin{cases} X_{rand}(t) - r_1 | X_{rand}(t) - 2r_2 X(t) |, & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3(LB + r_4(UB - LB)), & q < 0.5 \end{cases} \quad (3)$$

式中:  $t$  为当前迭代次数,  $X(t)$  为第  $t$  次迭代中哈里斯鹰位置向量,  $X(t+1)$  为哈里斯鹰下次迭代位置向量。  $X_{rand}(t)$  为随机哈里斯鹰个体,  $X_{rabbit}(t)$  为兔子的位置向量即最优哈里斯鹰个体的位置向量。  $LB$  和  $UB$  分别为特定问题决策变量的上界和下界。  $r_1, r_2, r_3$  和  $r_4$  为  $(0, 1)$  中的随机数。  $X_m(t)$  为当前种群中所有成员的平均位置向量。

### 1.2 局部搜索

当  $|E| < 1$  时算法进入局部探索阶段,在此过程中,算法依据兔子的逃逸能量  $E$  和逃跑倾向  $r$ ,引入 4 种策略来模拟哈里斯鹰的狩猎行为。

当  $|E| \geq 0.5$  且  $r \geq 0.5$  时,哈里斯鹰实施软包围,公式如下:

$$X(t+1) = D(t) - E | JX_{rabbit}(t) - X(t) | \quad (4)$$

$$\Delta X(t) = X_{rabbit}(t) - X(t) \quad (5)$$

$$J = 2(1 - r_5) \quad (6)$$

式中:  $\Delta X(t)$  为当前哈里斯鹰个体与兔子的距离,  $J$  为兔子的跳跃强度。

当  $|E| < 0.5$  且  $r \geq 0.5$  时,兔子的逃逸能量不足,哈里斯鹰采取硬包围策略,公式如下:

$$X(t+1) = X_{rabbit}(t) - E | D(t) | \quad (7)$$

当  $|E| \geq 0.5$  且  $r < 0.5$  时,兔子的逃逸能量和逃跑倾向都很高,哈里斯鹰采取渐进式快速俯冲软包围,公式如下:

$$X(t+1) = \begin{cases} Y, F(Y) < F(X(t)) \\ Z, F(Z) < F(X(t)) \end{cases} \quad (8)$$

$$Y = X_{rabbit}(t) - E | JX_{rabbit}(t) - X_m(t) | \quad (9)$$

$$Z = Y + S \cdot LF(D) \quad (10)$$

式中:  $S$  为大小为  $1 \times D$  的随机列表,  $D$  为变量维度,  $F$  为适应度函数,  $LF$  为 Levy 飞行函数,用于模拟哈里斯鹰在狩猎期间快速、突然和不规则的移动。

当  $E < 0.5$  且  $r < 0.5$  时,哈里斯鹰采用渐进式快速俯冲硬包围,哈里斯鹰的决策机制与式(8)相同,更新位置  $Y$  的公式如下:

$$Y = X_{rabbit}(t) - E | JX_{rabbit}(t) - X_m(t) | \quad (11)$$

## 2 IHHO

HHO 相较其他群智能算法,参数较少,结构完整且易于使用,但同样存在易陷入局部最优,难以平衡全局搜索和局部探索的问题<sup>[16]</sup>。因此,本文针对以上问题对 HHO 进行了改进。

### 2.1 非线性自适应因子

在基本 HHO 中,当  $|E| \geq 1$  且  $|E|$  的值越大,鹰群的搜索空间越大,全局搜索能力越强;当  $|E| < 1$  时,鹰

群会根据兔子的状态实时更新抓捕策略,但寻优策略复杂多变,寻优效果的高低并不能仅用  $|E|$  的数值大小判定。然而  $E$  在寻优全过程呈线性变化,无法灵活实现全局搜索与局部探索的过渡以及鹰群抓捕策略的转换。因此,本文引入非线性自适应因子  $E_1$ ,其定义如下:

$$E_1 = \sin\left(\frac{t\pi}{T} + \frac{\pi}{2}\right) + 1 \quad (12)$$

根据改进前后自适应因子  $E_1$  公式得到的对比曲线如图 1 所示。

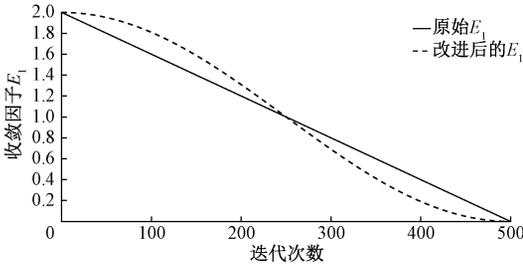


图 1 非线性自适应因子迭代曲线对比

Fig. 1 Comparison of nonlinear adaptive factor iteration curve

由图 1 可知,改进后的  $E_1$  曲线前期变化平缓使得鹰群可以扩大搜索范围即算法的全局搜索能力更优,中后期下降速度较快随后趋于平缓,标志着算法可实现从全局搜索阶段向局部探索阶段的迅速转换,以及鹰群抓捕策略的灵活切换。

### 2.2 柯西变异

HHO 在进入局部探索阶段后,随着迭代次数增加,种群的多样性递减,极易出现早熟现象,陷入局部最优。为提高算法种群多样性,本文引入柯西变异策略。

标准柯西分布的密度函数为:

$$f(x) = \frac{1}{\pi(x^2 + 1)}, \quad -\infty < x < \infty \quad (13)$$

柯西变异策略的引入可以在当前 Harris 鹰个体附近产生较大扰动,使得柯西分布函数的范围更广, Harris 鹰捕获到兔子的概率提升,算法拥有更优的种群多样性。位置更新公式如下:

$$X(t+1) = X_{rabbit} \cdot (1 + \text{cauchy}(0,1)) \quad (14)$$

$$\text{Cauchy}(0,1) = \tan((\text{rand} - 0.5) \cdot \pi) \quad (15)$$

式中:  $\text{cauchy}(0,1)$  为柯西随机数,  $\text{rand}$  为  $(0,1)$  中的随机数。

### 2.3 随机差分扰动

在基本 HHO 的中后期,鹰群仅进行局部搜寻即小范围的对兔子实施抓捕,导致算法将局部最优解认定为全局最优解,使得算法陷于局部最优。为克服这一缺陷,本文引入随机差分扰动策略,通过对当前 Harris 鹰个体位置、兔子位置和鹰群中随机选择的 Harris 鹰个体位置进

行随机差分扰动,进而产生新的 Harris 鹰个体位置,增强群体多样性,使算法跳出局部最优。具体公式如下:

$$X(t+1) = r \cdot (X_{rabbit} - X(t)) + r \cdot (X'(t) - X(t)) \quad (16)$$

式中:  $X'(t)$  是随机选择的 Harris 鹰个体位置向量。

### 2.4 IHHO 流程

IHHO 流程如图 2 所示。

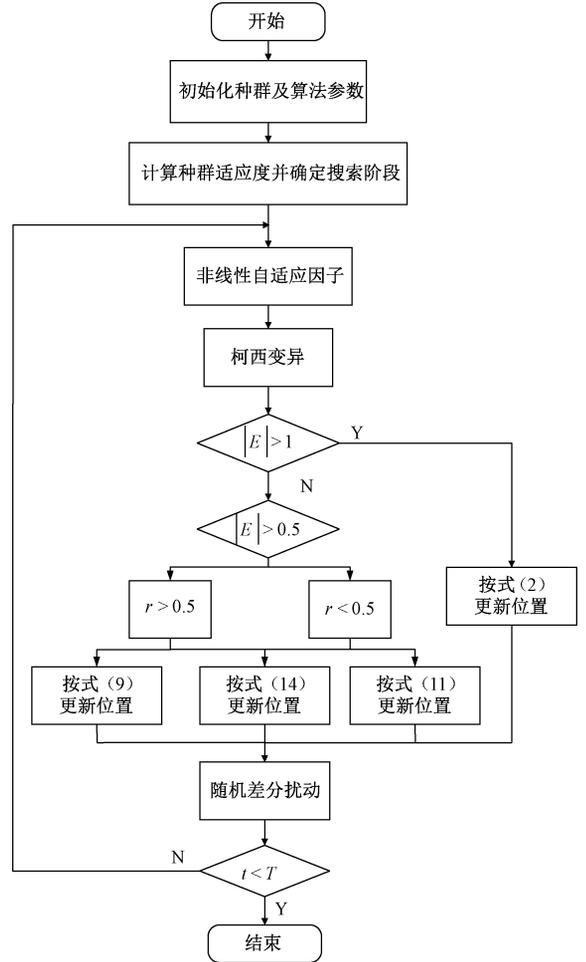


图 2 IHHO 流程

Fig. 2 Flow chart of IHHO

## 3 基于 IHHO-BP 的故障诊断

模拟电路故障诊断的重点分为两部分,一是对模拟电路进行故障特征选择,二是利用诊断网络实现故障诊断,但网络参数寻优较为困难。本文利用 IHHO-BP 分别完成故障特征选择和诊断模型参数寻优,进而实现模拟电路故障诊断。

### 3.1 BP 神经网络

BP 神经网络是一种典型的多层前馈网络,采用并行分布式处理定性和定量问题,其适用范围广,学习复杂非

线性能力强<sup>[17]</sup>, 尤其适合解决包含噪声、不稳定和非线性的特征数据。BP 神经网络由输入层、多个隐含层和输出层组成, 各层之间实现全连接, 结构如图 3 所示。

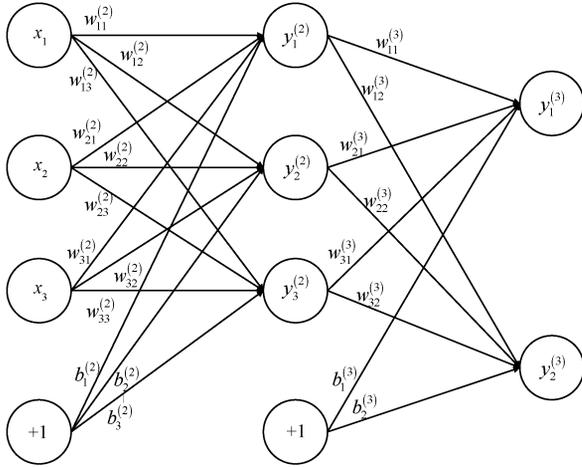


图 3 神经网络结构图

Fig. 3 Neural network structure diagram

### 3.2 特征选择

特征选择作为数据预处理的必要步骤, 去除原始故障数据中的冗余和不相关特征, 实现数据降维, 从而获取最优特征子集, 是后续诊断技术稳定发挥的前提<sup>[18]</sup>。本文利用 BP 神经网络创建网络模型, 以 IHHO 作为寻优算法, 将 IHHO 与 BP 神经网络相结合用于特征选择。

#### 1) 二进制编码

由于特征选择的结果只存在两种可能性即被选中和被舍弃, 因此可将特征选择转化为二进制优化问题。设定数值为 1 的代表可用特征, 数值为 0 的代表不相关特征。特征选择的目的是摒弃不相关特征, 选择数值为 1 的可用特征。

#### 2) 适应度函数

适应度函数对于 IHHO 中 Harris 鹰位置的更新以及算法优化的方向有着至关重要的作用。本文选择 BP 神经网络诊断精度和特征子集大小两个维度生成适应度函数, 通过对数据适应度函数的计算, 获取最优特征子集。适应度函数的表达式如下:

$$fit = k \cdot \sigma(D) + w \frac{|S|}{|N|} \quad (17)$$

$$\sigma(D) = 1 - Acc \quad (18)$$

式中:  $\sigma(D)$  为  $D$  维特征空间的误差,  $Acc$  为诊断精度。  $k$  和  $w$  分别为诊断精度的权值和特征子集大小的权值, 且  $w = 1 - k$ , 即诊断精度的占比越大, 对应特征子集的权值越小。  $S$  为特征子集大小,  $N$  为数据集的特征总数。

### 3.3 IHHO 优化 BP 神经网络

BP 神经网络用于许多实际问题, 但随着应用范围的

扩大, 收敛速度慢、容易陷入局部极值的弊端也不容忽视。本文使用 IHHO 优化 BP 神经网络的权值和阈值, 可以有效实现模拟电路故障诊断精度的提升。

步骤 1) 数据预处理。包括对原始数据进行特征选择以及训练集和测试集的划分, 并对数据进行规范化处理。

步骤 2) 参数设置。确定 BP 神经网络的拓扑结构, 并初始化 IHHO 的种群大小  $N$ , 种群维度  $M$ , 种群区间  $[lb \ ub]$  和最大迭代次数  $T$ , 得到初始种群。

步骤 3) 计算种群适应度值。将初始化的权重和阈值赋给新建的 BP 神经网络, 利用训练样本训练网络, 测试样本测试网络, 得到测试精度用于计算种群适应度。

步骤 4) 更新种群。选择适应度高的个体作为兔子, 并根据逃逸能量更新策略选择鹰的位置, 进而得到新的种群。

步骤 5) 更新权重和阈值。记录种群中兔子的位置向量, 更新 BP 神经网络的权值和阈值, 选择诊断模型的最优参数, 用于模拟电路的故障诊断。

步骤 6) 故障诊断。判断循环是否满足误差要求, 利用 BP 神经网络对模拟电路进行故障诊断并输出诊断结果。

模拟电路故障诊断整体流程如图 4 所示。

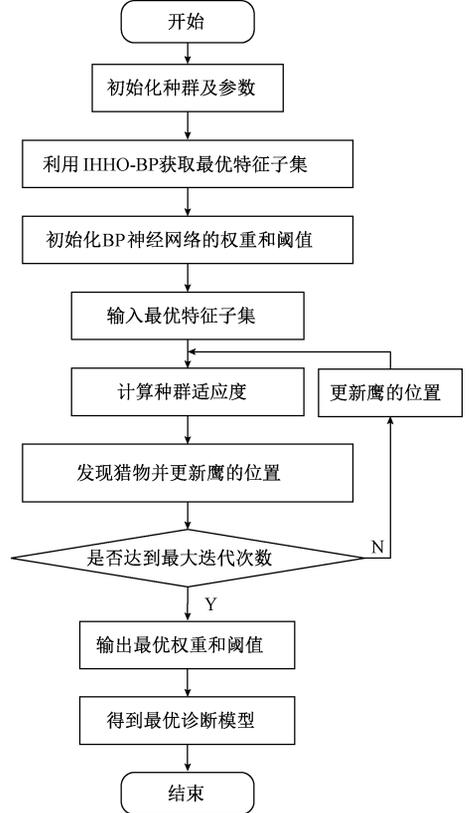


图 4 故障诊断流程图

Fig. 4 Fault diagnosis flow chart

## 4 实验结果与分析

### 4.1 计算复杂度分析

HHO 的计算复杂度主要来自于种群初始化、种群个体最佳适应度更新和种群个体更新 3 个部分。对于 HHO 种群规模为  $N$ , 最大迭代次数为  $T$ , 问题维度为  $D$ , 初始化的计算复杂度为  $O(N)$ , 最佳适应度更新的计算复杂度为  $O(T \times N)$ , 个体更新的计算复杂度为  $O(T \times N \times D)$ , 因此 HHO 总计算复杂度为  $O(\text{HHO}) = O(N) + O(T \times N) + O(T \times N \times D) \approx O(T \times N \times D)$ 。IHHO 种群初始化和种群最佳适应度更新阶段与 HHO 保持不变, 且非线性自适

应因子更新阶段的计算复杂度与 HHO 中个体更新的计算复杂度一致, 而柯西变异的复杂度为  $O(T)$ , 随机差分扰动的计算复杂度为  $O(T \times N)$ , 故 IHHO 的计算复杂度为  $O(\text{IHHO}) = O(N) + O(T \times N) + O(T \times N \times D) + O(T) + O(T \times N) \approx O(T \times N \times D)$ 。

综合上述分析, IHHO 与 HHO 的计算复杂度相同, 且相较于 HHO, IHHO 在全局搜索和局部探索方面有显著的提升。

### 4.2 算法性能分析

为验证所提算法的性能, 依据文献[19]选择包括高维单峰( $F_1 \sim F_5$ )、高维多峰( $F_6 \sim F_8$ )和低维多峰( $F_9 \sim F_{10}$ )共 10 个测试函数进行评估, 函数公式详见表 1。

表 1 测试函数  
Table 1 Test functions

函数	维度	范围	最优值
$F_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
$F_2(x) = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	30	$[-10, 10]$	0
$F_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	30	$[-100, 100]$	0
$F_4(x) = \max_i \{ x_i , 1 \leq i \leq n\}$	30	$[-100, 100]$	0
$F_5(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	$[-1.28, 1.28]$	0
$F_6 = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$	30	$[-32, 32]$	0
$F_7 = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	$[-600, 600]$	0
$F_8 = \frac{\pi}{n} \{10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2\} + \sum_{i=1}^n u(x_i, 10, 100, 4)$	30	$[-50, 50]$	0
$y_i = 1 + \frac{x_i + 1}{4}, u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m x_i > a \\ 0 & -a < x_i < a \\ k(-x_i - a)^m x_i < -a \end{cases}$	30	$[-50, 50]$	0
$F_9 = \sum_{i=1}^{11} [a_i - \frac{x(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4}]^2$	4	$[-5, 5]$	0
$F_{10} = - \sum_{i=1}^{10} [(X - a_i)(X - a_i)^T + c_i]^{-1}$	4	$[0, 10]$	-10.536 4

同时本文将 IHHO 与粒子群算法 (PSO), 遗传算法 (GA) 和基本哈里斯鹰算法 (HHO) 进行对比测试, 每种寻优算法的参数均采用相同的初始化设定即: 种群大小为 40, 最大迭代次数为 500, 种群维度为 100, 算法具体重要参数设置详见表 2。该实验以平均值 (Ave) 和标准差 (Std) 为衡量标准, 为降低随机因素对结果的影响, 均运行 30 次取平均, 对比结果如表 3 所示。图 5 以各算法在  $F_2$ 、 $F_5$ 、 $F_6$  以及  $F_{10}$  测试函数中的收敛曲线对比为例, 进

一步展现各算法性能对比。

表 2 参数设置  
Table 2 Parameter settings

算法	参数
IHHO	$E_1 \in (-1, 1)$
HHO	$E_0 \in (-1, 1)$
GA	$P_c = 0.95, P_m = 0.05$
PSO	$C_1 = 1.5, C_2 = 1.5, W = 0.75$

表 3 算法测试结果对比  
Table 3 Comparison of algorithm test results

		IHHO	HHO	GA	PSO
$F_1$	Ave	0	$5.6078 \times 10^{-92}$	$2.6084 \times 10^3$	24.5774
	Std	0	$2.1616 \times 10^{-91}$	375.1600	19.3097
$F_2$	Ave	$2.8486 \times 10^{-301}$	$2.5381 \times 10^{-50}$	$1.9236 \times 10^8$	23.0208
	Std	0	$9.3053 \times 10^{-50}$	$1.0535 \times 10^9$	9.1381
$F_3$	Ave	0	$1.3256 \times 10^{-74}$	$1.4278 \times 10^4$	169.4363
	Std	0	$6.6480 \times 10^{-74}$	$3.4202 \times 10^3$	81.8043
$F_4$	Ave	$1.2589 \times 10^{-300}$	$7.8038 \times 10^{-48}$	32.0538	16.1223
	Std	0	$4.1496 \times 10^{-47}$	5.7661	4.7317
$F_5$	Ave	0.0014	0.0101	$5.7657 \times 10^5$	$1.4766 \times 10^4$
	Std	0.0039	0.0115	$1.7128 \times 10^5$	$1.1758 \times 10^4$
$F_6$	Ave	$8.8818 \times 10^{-16}$	$8.8818 \times 10^{-16}$	12.8770	9.2387
	Std	0	0	3.3838	1.4765
$F_7$	Ave	0	0	25.8619	0.6225
	Std	0	0	4.3687	0.1773
$F_8$	Ave	$3.7758 \times 10^{-7}$	$7.8295 \times 10^{-6}$	$3.3223 \times 10^3$	15.2482
	Std	$7.7950 \times 10^{-7}$	$1.0035 \times 10^{-5}$	$9.0805 \times 10^3$	8.5000
$F_9$	Ave	$3.3075 \times 10^{-4}$	$3.4728 \times 10^{-4}$	0.0069	0.0077
	Std	$1.7337 \times 10^{-5}$	$3.6583 \times 10^{-5}$	0.0089	0.0091
$F_{10}$	Ave	-10.5355	-5.1242	-4.9803	-7.6060
	Std	0.0013	0.0056	3.1809	3.7060

由表 3 数据可知,在相同测试条件下 IHHO 的 Ave 和 Std 值均是最低,验证了 IHHO 的性能优于其他算法。测试函数中单峰体现算法的局部寻优能力,而多峰则代

表算法的全局搜索能力,结合图 5 各算法收敛曲线对比可知,IHHO 在各类函数寻优过程中收敛速度快且出现较多拐点,进一步证明了 IHHO 明显的综合性能优势。

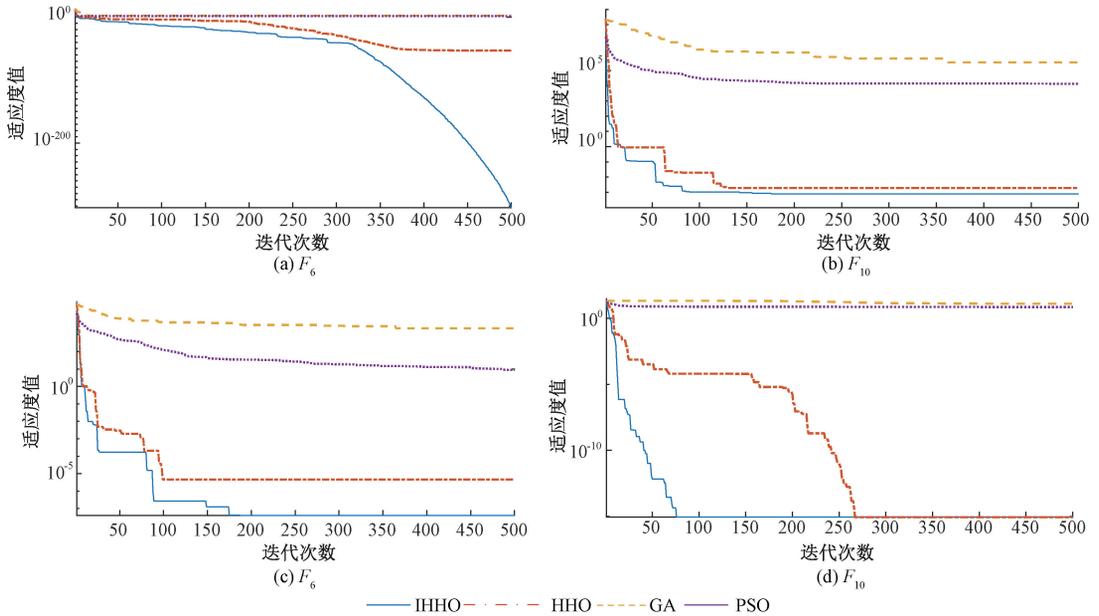


图 5 收敛曲线对比

Fig. 5 Comparison of convergence curves

4.3 电路仿真与诊断分析

本文通过对 Sallen key 带通滤波电路和 CSTV 低通滤波电路进行仿真验证所提方法的可行性。由于大多数

模拟电路故障诊断仅针对单一故障,从实际应用角度考虑缺乏可信度,因此本文选择结合电路的单一故障和组合故障进行故障诊断。

1) Sallen key 带通滤波电路

Sallen key 带通滤波电路电路结构如图 6 所示。

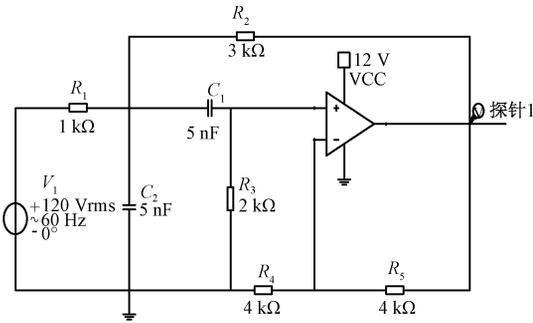


图 6 Sallen key 带通滤波电路原理图

Fig. 6 Schematic diagram of Sallen key bandpass filter circuit

各电路元器件的正常状态值已经在原理图中给出, 实验中电阻和电容的容差分别设置为 5% 和 10%, 并将超出标称值  $\pm 50\%$  的设为故障元器件。运用 Pspice 电路仿真软件, 对电路进行参数扫描以及灵敏度分析, 确定对电路影响最大的几个元器件, 设置单一故障和组合故障, 得到的故障类型如表 4 所示。

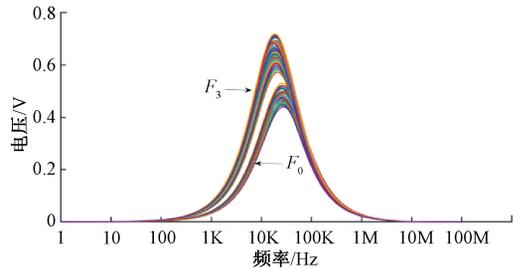
表 4 Sallen key 带通滤波电路故障类型

Table 4 Type of Sallen key bandpass filter circuit fault

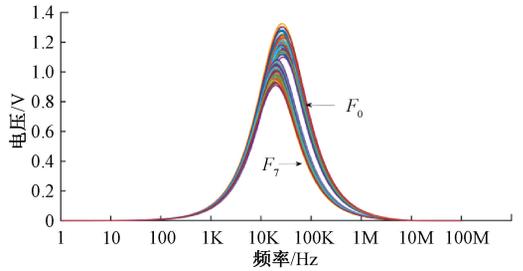
故障编码	故障类型	标称值	故障值
$F_0$	正常	—	—
$F_1$	$R_2 \uparrow$	3 k $\Omega$	[4.6 k $\Omega$ 5.5 k $\Omega$ ]
$F_2$	$R_2 \downarrow$	3 k $\Omega$	[0.5 k $\Omega$ 1.4 k $\Omega$ ]
$F_3$	$R_3 \uparrow$	2 k $\Omega$	[3.1 k $\Omega$ 4.0 k $\Omega$ ]
$F_4$	$R_3 \downarrow$	2 k $\Omega$	[0.1 k $\Omega$ 1.0 k $\Omega$ ]
$F_5$	$C_1 \uparrow$	5 nF	[7.5 nF 9.0 nF]
$F_6$	$C_1 \downarrow$	5 nF	[1.0 nF 2.5 nF]
$F_7$	$C_2 \uparrow$	5 nF	[8.0 nF 9.0 nF]
$F_8$	$C_2 \downarrow$	5 nF	[1.0 nF 2.0 nF]
$F_9$	$C_1 \uparrow C_2 \uparrow$	5 nF 5 nF	[8.1 nF 9.0 nF]
$F_{10}$	$C_1 \downarrow C_2 \downarrow$	5 nF 5 nF	[1.0 nF 2.5 nF]
$F_{11}$	$R_2 \uparrow R_3 \uparrow$	3 k $\Omega$ 2 k $\Omega$	[4.6 k $\Omega$ 5.5 k $\Omega$ ] [3.1 k $\Omega$ 4.0 k $\Omega$ ]
$F_{12}$	$R_2 \downarrow R_3 \downarrow$	3 k $\Omega$ 2 k $\Omega$	[0.5 k $\Omega$ 1.4 k $\Omega$ ] [0.1 k $\Omega$ 1.0 k $\Omega$ ]

以  $F_3, F_7$  和  $F_{10}$  电路故障状态与正常工作状态  $F_0$  的输出电压曲线对比为例, 如图 7 所示。

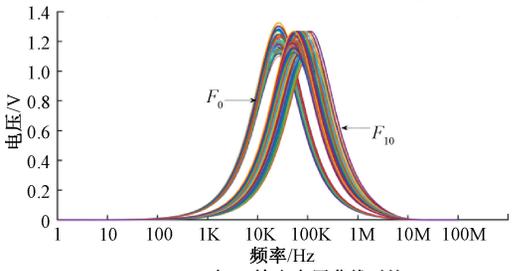
$F_3$  的故障类型为  $R_3$  大于标称值 50% 的故障曲线,  $F_7$  的故障类型为  $C_2$  大于标称值 50% 的故障曲线,  $F_{10}$  的故障类型为  $C_1$  和  $C_2$  均小于标称值 50% 的故障曲线。由图 7 可知, 单一故障曲线与  $F_0$  的输出曲线尽管有幅值和相位上的不同, 也存在众多数值点的重合, 而组合故障曲线与  $F_0$  相比, 不仅幅值和相位不同也鲜有相同的数值点, 且组合故障相较单一故障对电路整体的输出影响更



(a)  $F_0$  与  $F_3$  输出电压曲线对比  
(a) Compare the output voltage curve of  $F_0$  and  $F_3$



(b)  $F_0$  与  $F_7$  输出电压曲线对比  
(b) Compare the output voltage curve of  $F_0$  and  $F_7$



(c)  $F_0$  与  $F_{10}$  输出电压曲线对比  
(c) Compare the output voltage curve of  $F_0$  and  $F_{10}$

图 7 电路正常与故障状态的输出电压曲线对比

Fig. 7 Contrast the output voltage curve of the normal and fault state of the circuit

大, 因此组合故障的诊断十分重要。

对表 4 中正常状态和 12 类故障状态分别进行 10 次参数扫描分析和 10 次蒙特卡洛分析, 得到 1 300 组样本数据。本文按照 8 : 2 的比例划分数据集, 将得到的 1 040 组训练数据和 260 组测试数据输入 BP 神经网络进行故障诊断。为验证本文算法对模拟电路故障诊断的效果, 以测试集的平均精确度为评价标准, 将应用遗传算法优化的 BP 神经网络 (GA-BP), 应用粒子群算法优化的 BP 神经网络 (PSO-BP) 和应用基本 HHO 算法优化的 BP 神经网络 (HHO-BP) 作为对比实验。每种寻优算法的参数设置与上文保持一致, 重复实验 20 次取均值。各寻优算法对 Sallen key 带通滤波电路故障诊断的结果如图 8 所示。

预处理阶段将原始数据与利用 IHHO 特征选择后得到的最优特征子集进行对比, 诊断类别分为单故障和组合故障两类, 诊断阶段利用上述 5 种算法进行验证, 其诊断结果如表 5 所示。

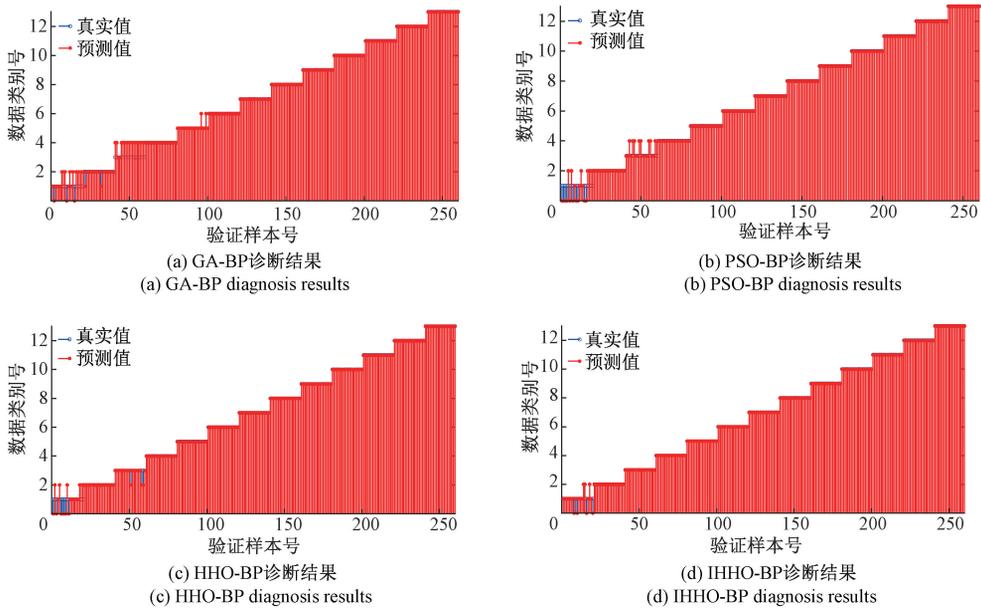


图 8 诊断结果对比

Fig. 8 Comparison of diagnostic results

表 5 Sallen key 带通滤波电路故障诊断结果对比

Table 5 Comparison of fault diagnosis results of Sallen key bandpass filter circuit

诊断对象	诊断方法	诊断类别	诊断精确度/%		诊断类别	诊断精确度/%	
			未优化	优化后		未优化	优化后
Sallen key 带通滤波电路	BP	$F_0 \sim F_8$	91.31	93.62	$F_9 \sim F_{12}$	80.00	84.69
	GA-BP		93.75	95.84		87.75	90.08
	PSO-BP		93.38	95.67		83.50	89.34
	HHO-BP		94.37	96.83		89.22	92.19
	IHHO-BP		96.69	98.33		92.50	95.77

由图 8 和表 5 的诊断效果和诊断精确度可知,将 IHHO 用于故障数据的特征选择以及 BP 神经网络权重和阈值的优化,实现了模拟电路故障诊断精度的有效提升。其中,组合故障的诊断精度比单一故障的诊断精度平均低了 6%,侧面反映出组合故障的诊断难度远高于单一故障故障诊断,但 IHHO-BP 作用于组合故障的诊断精度依旧能够达到 95.77%,证明了 IHHO 对于故障数据的特征选择和 BP 神经网络的优化都优于其他 4 种对比算法。

2) CSTV 低通滤波电路故障诊断

CSTV 低通滤波电路结构如图 9 所示,各电路元器件的标称值已在原理图中给出。

本实验设定电阻的容差为 5%,电容的容差为 10%,并将超出标称值  $\pm 50\%$  的设为故障元器件。运用 Pspice 电路仿真软件,对电路进行参数扫描以及灵敏度分析,确定对电路影响最大的几个元器件,设置单一故障和组合故障,得到的故障类型如表 6 所示。

以  $F_5$ 、 $F_{10}$  和  $F_{15}$  电路故障状态与正常工作状态  $F_0$

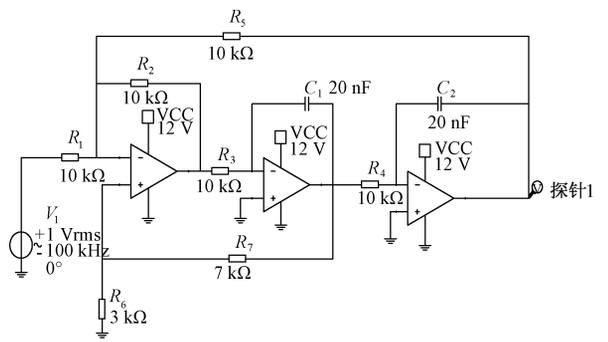


图 9 CSTV 低通滤波电路原理

Fig. 9 CSTV low pass filter circuit schematic diagram

的输出电压曲线对比为例,如图 10 所示。

$F_5$  的故障类型为  $R_3$  大于标称值 50% 的故障曲线,  $F_{10}$  的故障类型为  $R_5$  小于标称值 50% 的故障曲线,  $F_{15}$  的故障类型为  $C_1$ 、 $C_2$  和  $R_5$  同时小于标称值 50% 的故障曲线。由图 10 可以看出,相较于 Sallen key 带通滤波电路, CSTV 低通滤波电路正常工作状态与元器件故障状态对

应的输出曲线区分度更高,不过,两个电路也存在相同点即组合故障对电路整体的输出相较单一故障影响更大,进一步验证了组合故障诊断的必要性。

表 6 CSTV 低通滤波电路故障类型

Table 6 Type of CSTV low pass filter circuit fault

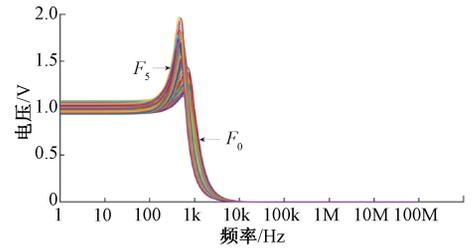
故障编码	故障类型	标称值	故障值
$F_0$	正常	—	—
$F_1$	$C_1 \uparrow$	20 nF	[31 nF 40 nF]
$F_2$	$C_1 \downarrow$	20 nF	[1.0 nF 10 nF]
$F_3$	$C_2 \uparrow$	20 nF	[31 nF 40 nF]
$F_4$	$C_2 \downarrow$	20 nF	[1.0 nF 10 nF]
$F_5$	$R_3 \uparrow$	10 k $\Omega$	[16 k $\Omega$ 25 k $\Omega$ ]
$F_6$	$R_3 \downarrow$	10 k $\Omega$	[0.5 k $\Omega$ 5 k $\Omega$ ]
$F_7$	$R_4 \uparrow$	10 k $\Omega$	[16 k $\Omega$ 25 k $\Omega$ ]
$F_8$	$R_4 \downarrow$	10 k $\Omega$	[0.5 k $\Omega$ 5 k $\Omega$ ]
$F_9$	$R_1 \uparrow$	10 k $\Omega$	[16 k $\Omega$ 25 k $\Omega$ ]
$F_{10}$	$R_5 \downarrow$	10 k $\Omega$	[0.5 k $\Omega$ 5 k $\Omega$ ]
$F_{11}$	$R_1 \downarrow C_1 \downarrow$	10 k $\Omega$ 20 nF	[0.5 k $\Omega$ 5 k $\Omega$ ] [1.0 nF 10 nF]
$F_{12}$	$R_1 \uparrow C_1 \uparrow$	10 k $\Omega$ 20 nF	[16 k $\Omega$ 25 k $\Omega$ ] [31 nF 40 nF]
$F_{13}$	$R_5 \uparrow C_2 \uparrow$	10 k $\Omega$ 20 nF	[16 k $\Omega$ 25 k $\Omega$ ] [31 nF 40 nF]
$F_{14}$	$R_5 \downarrow C_2 \downarrow$	10 k $\Omega$ 20 nF	[0.5 k $\Omega$ 5 k $\Omega$ ] [1.0 nF 10 nF]
$F_{15}$	$R_5 \downarrow C_1 \downarrow C_2 \downarrow$	10 k $\Omega$ 20 nF 20 nF	[2.5 k $\Omega$ 7 k $\Omega$ ] [5.0 nF 14 nF] [5.0 nF 14 nF]

对表 7 中正常状态和 15 类故障状态分别进行 10 次参数扫描分析和 10 次蒙特卡洛分析,得到 1 600 组样本数据。依旧按照 8 : 2 的比例划分数据集,将得到的 1 280 组训练数据和 320 组测试数据输入 BP 神经网络进行故障诊断。由于 BP 神经网络的输出节点数取决于电路故障状态数,因此仅将 BP 神经网络的输出节点数改为 16,其余参数设置与 Sallen key 带通滤波电路故障诊断保持一致。CSTV 低通滤波电路的诊断结果对比如

表 7 CSTV 低通滤波电路故障诊断结果对比

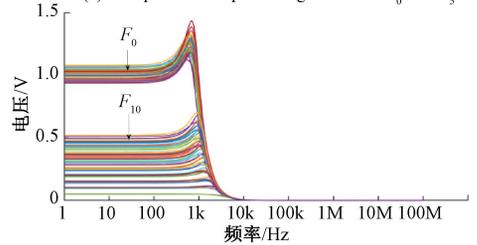
Table 7 Comparison of fault diagnosis results of CSTV low pass filter circuit

诊断对象	诊断方法	诊断类别	诊断精确度/%		诊断类别	诊断精确度/%	
			未优化	优化后		未优化	优化后
CSTV 低通滤波电路	BP	$F_0 \sim F_{10}$	90.15	92.31	$F_{11} \sim F_{15}$	79.37	83.44
	GA-BP		94.62	96.69		83.75	89.06
	PSO-BP		93.77	96.56		83.33	87.56
	HHO-BP		94.33	95.75		88.84	92.31
	IHHO-BP		97.58	98.61		91.49	94.85



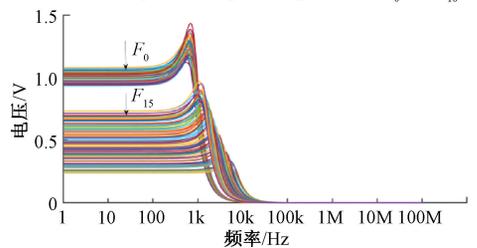
(a)  $F_0$ 与 $F_5$ 输出电压曲线对比

(a) Compare the output voltage curve of  $F_0$  and  $F_5$



(b)  $F_0$ 与 $F_{10}$ 输出电压曲线对比

(b) Compare the output voltage curve of  $F_0$  and  $F_{10}$



(c)  $F_0$ 与 $F_{15}$ 输出电压曲线对比

(c) Compare the output voltage curve of  $F_0$  and  $F_{15}$

图 10 电路正常与故障状态的输出电压曲线对比  
Fig. 10 Contrast the output voltage curve of the normal and fault state of the circuit

图 11 所示。

CSTV 低通滤波电路的优化效果诊断结果如表 7 所示,由表 7 可知,IHHO-BP 对于单故障的诊断精度平均比组合故障的诊断精度高了 5%,且对于组合故障的诊断精度能够达到 94.85%,进一步验证了 IHHO 在数据特征选择以及对 BP 神经网络优化方面的良好性能,且对于不同模拟电路单故障以及组合故障的诊断效果依旧有较大提升。

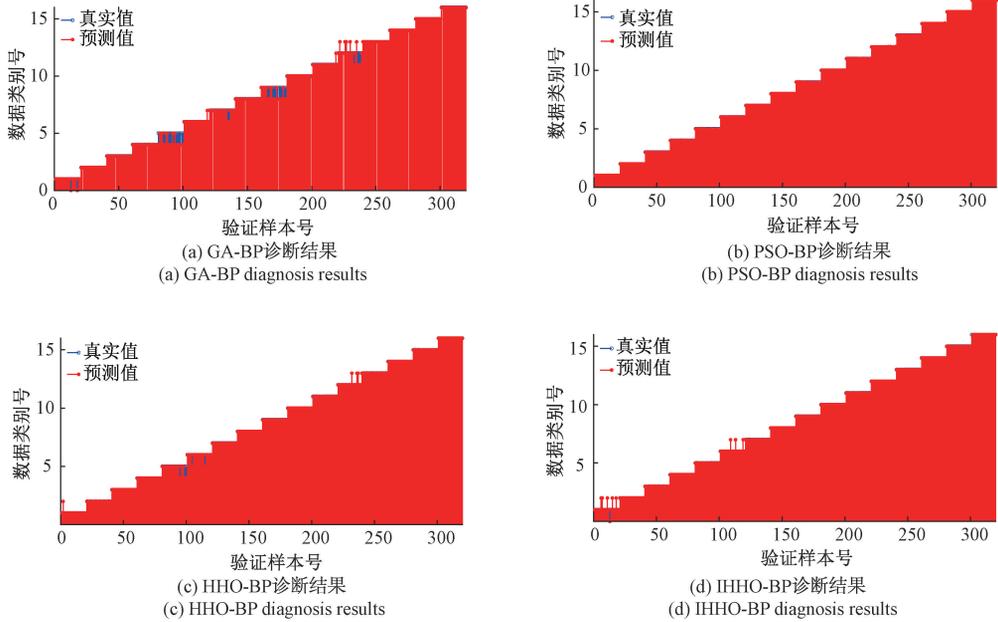


图 11 诊断结果对比

Fig. 11 Comparison of diagnostic results

综上,利用 IHHO 对原始故障数据进行特征选择,可以有效获取高质量的故障数据特征子集,对于提高故障诊断的精度,有着重要意义。且针对传统的 BP 神经网络权值和阈值固定导致的诊断效果不理想问题,采用 IHHO 对 BP 神经网络的权重和阈值进行更新,以提高故障诊断效果。

## 5 结论

针对模拟电路故障诊断困难问题,本文从故障数据特征选择和诊断模型优化两个角度出发,选用适用范围广,操作便捷且具有优秀的全局搜索能力的 HHO 算法,并针对 HHO 种群多样性差,难以平衡全局搜索和局部探索以及易陷入局部最优的问题,提出一种 IHHO 算法,同步实现故障数据的特征选择和 BP 神经网络的优化。本文通过两个国际通用电路进行故障仿真,并结合电路单一故障和组合故障进行验证。实验结果表明,利用 IHHO-BP 特征选择的最优故障特征子集作为输入,且利用 IHHO 优化 BP 神经网络的权重和阈值,实现模拟电路故障诊断,对比原始故障数据以及其他群智能优化算法,模型诊断精度得到有效提升。

## 参考文献

[ 1 ] JI L, HU X. Analog circuit soft-fault diagnosis based on sensitivity analysis with minimum fault number rule[J]. Analog Integrated Circuits and Signal Processing, 2018, 95(1): 163-171.

[ 2 ] 谈恩民,李峰. 结合 LMD 云模型和 ABC-LSSVM 的模拟电路故障诊断[J]. 电子测量与仪器学报, 2020, 34(2): 80-87.  
TAN EN M, LI F. Analog circuit fault diagnosis based on LMD cloud model and ABC-LSSVM [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 80-87.

[ 3 ] NEZHAD H B, MIRI M, GHASEMI M R. New neural network-based response surface method for reliability analysis of structures [J]. Neural Computing and Applications, 2017, DOI:10.1007/s00521-017-3109-2.

[ 4 ] 孙健,胡国兵,王成华. 基于随机投影和 NB 网络的模拟电路故障诊断[J]. 仪器仪表学报, 2019, 40(2): 105-112.  
SUN J, HU G B, WANG CH H. Fault diagnosis of analog circuit based on random projection and NB network [J]. Chinese Journal of Scientific Instrument, 2019, 40(2): 105-112.

[ 5 ] ROSTAMI M, BERAHMAND K, NASIRI E, et al. Review of swarm intelligence-based feature selection methods [J]. Engineering Applications of Artificial Intelligence, 2021, 100: 104210.

[ 6 ] IBRAHIM K S M H, HUANG Y F, AHMED A N, et al. A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forecasting[J]. Alexandria Engineering Journal, 2022, 61(1): 279-303.

[ 7 ] PAUL D, JAIN A, SAHA S, et al. Multi-objective PSO based

- online feature selection for multi-label classification [J]. Knowledge-Based Systems, 2021, 222: 106966.
- [ 8 ] ROSTAMI M, MORADI P. A clustering based genetic algorithm for feature selection [C]. 2014 6th Conference on Information and Knowledge Technology (IKT). IEEE, 2014: 112-116.
- [ 9 ] FATIMA A, MAURYA R, DUTTA M K, et al. Android malware detection using genetic algorithm based optimized feature selection and machine learning [C]. 2019 42nd International Conference on Telecommunications and Signal Processing (TSP). IEEE, 2019: 220-223.
- [10] 马峻,赵飞乐,徐潇,等. MRA-PCA-PSO 组合优化 BP 神经网络模拟电路故障诊断研究[J]. 电子测量与仪器学报, 2018, 32(3): 73-79.  
MA J, ZHAO F L, XU X, et al. Research on fault diagnosis of analog circuit based on MRA-PCA-PSO combination optimization of BP neural network [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(3): 73-79.
- [11] SHEIKHAN M, SHA' BANI A A. PSO-optimized modular neural network trained by OWO-HWO algorithm for fault location in analog circuits[J]. Neural Computing and Applications, 2013, 23(2): 519-530.
- [12] 王力,刘子奇. WPA-IGA-BP 神经网络的模拟电路故障诊断[J]. 系统工程与电子技术, 2021, 43(4): 1133-1143.  
WANG L, LIU Z Q. Analog circuit fault diagnosis based on WPA-IGA-BP neural network [J]. Systems Engineering and Electronics, 2021, 43(4): 1133-1143.
- [13] 马一鸣,石志东,赵康,等. 基于改进哈里斯鹰优化算法的 TDOA 定位 [J]. 计算机工程, 2020, 46(12): 179-184.  
MA Y M, SHI ZH D, ZHAO K, et al. TDOA localization based on improved Harris eagle optimization algorithm [J]. Computer Engineering, 2020, 46(12): 179-184.
- [14] 徐国天,刘猛猛. 基于改进哈里斯鹰算法同步优化特征选择的恶意软件检测方法 [J]. 信息安全, 2021, 21(12): 9-18.  
XU G T, LIU M M. A malware detection method based on improved Harris eagle algorithm for synchronous optimization of feature selection [J]. Information Network Security, 2021, 21(12): 9-18.
- [15] 刘洪波,曲晟岐,徐咏盛. 基于改进哈里斯鹰优化算法的主动配电网规划 [J]. 吉林电力, 2021, 49(5): 16-20, 25.  
LIU H B, QU SH Q, XU Y SH. Active distribution network planning based on improved Harris eagle optimization algorithm [J]. Jilin Electric Power, 2021, 49(5): 16-20, 25.
- [16] GEZICI H, LIVATYALı H. Chaotic Harris Hawks optimization algorithm [J]. Journal of Computational Design and Engineering, 2022, 9(1): 216-245.
- [17] 张创基. 基于 BP 学习的 P2P 网络信任度评价模型优化 [J]. 国外电子测量技术, 2019, 38(6): 38-42.  
ZHANG CH J. Optimization of P2P network trust evaluation model based on BP learning [J]. Foreign Electronic Measurement Technology, 2019, 38(6): 38-42.
- [18] 单帅帅,马清峰,谢雯鑫. 基于小波包能量谱和 ICA 的模拟电路故障特征提取方法 [J]. 电子测量技术, 2021, 44(18): 19-23.  
SHAN SH SH, MA Q F, XIE W X. Fault feature extraction method of analog circuit based on wavelet packet energy spectrum and ICA [J]. Electronic Measurement Technique, 2021, 44(18): 19-23.
- [19] 潘科,张伟,王亚刚. 特种部队算法: 一种新的元启发式算法 [J]. 控制与决策, 2022, 37(10): 2497-2504.  
PAN K, ZHANG W, WANG Y G. Special forces algorithm: A new meta-heuristic algorithm [J]. Control and Decision, 2022, 37(10): 2497-2504.

### 作者简介



王力, 2009 年于南开大学获得博士学位, 现为中国民航大学教授, 主要研究方向为机载电子系统深度维修等。

E-mail: 43464376@qq.com

**Wang Li** received his Ph. D. degree from Nankai University in 2009. Now he is a professor at Civil Aviation University of China. His main research interest includes deep maintenance of airborne electronic systems.



张露露 (通信作者), 2020 年于德州学院获得学士学位, 现为中国民航大学硕士研究生, 主要研究方向为机载电子系统深度维修等。

E-mail: 17862665033@163.com

**Zhang Lulu** (Corresponding author), received her B. Sc. degree from Dezhou College in 2020. Now she is a M. Sc. candidate at Civil Aviation University of China. Her main research interest includes deep maintenance of airborne electronic systems.