

DOI: 10.13382/j.jemi.B2205316

# 基于 IPPA 优化 PNN 的变压器故障诊断研究\*

徐耀松 包力铭 管智峰 王雨虹 阎馨  
(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

**摘要:**针对变压器故障诊断精度低的问题,本文提出一种改进寄生捕食算法(IPPA)优化概率神经网络(PNN)的电力变压器故障诊断模型,首先利用主成分分析(PCA)对故障数据进行数据降维减少无效特征,然后利用混沌反向学习、柯西变异算子和融合贝塔分布的线性递减函数的权重等多策略改进寄生捕食算法(IPPA),提高其优化能力,并使用改进后的 IPPA 算法优化 PNN 网络的平滑因子,以提高 PNN 的分类精度和鲁棒性。最后将 PCA 处理后的数据输入到 IPPA-PNN 模型中进行故障诊断并以变压器数据为依据进行测试,测试结果表明,IPPA-PNN 模型准确率达到 93% 相比于 PPA-PNN 和 PSO-PNN 模型提高了 7% 和 10% 能够有效地提高变压器的故障诊断性能。

**关键词:** 电力变压器;寄生捕食算法;混沌反向学习;柯西变异算子;自适应惯性权重;故障诊断

**中图分类号:** TN06      **文献标识码:** A      **国家标准学科分类代码:** 470.40

## Research on transformer fault diagnosis based on IPPA optimization PNN

Xu Yaosong Bao Liming Guan Zhifeng Wang Yuhong Yan Xin

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

**Abstract:** Aiming at the problem of low accuracy of transformer fault diagnosis, this paper proposes a power transformer fault diagnosis model based on improved parasitic predation algorithm (IPPA) and optimized probabilistic neural network (PNN). Firstly, principal component analysis (PCA) is used to reduce the dimensionality of fault data to reduce invalid features, then use multiple strategies such as chaotic reverse learning, Cauchy mutation operator and the weight of linear decreasing function fused with beta distribution to improve the hunt-prey algorithm (IPPA) and its optimization ability, and use the improved IPPA algorithm to optimize the smoothing factor of the PNN network to improve the classification accuracy and robustness of the PNN. Finally, the PCA-processed data is input into the IPPA-PNN model for fault diagnosis and testing based on the transformer data. The test results show that the accuracy of the IPPA-PNN model reaches 93%, which is 7% and 10% higher than that of the PPA-PNN and PSO-PNN models, and can effectively improve the fault diagnosis performance of the transformer.

**Keywords:** power transformer; parasitic predation algorithm; chaotic reverse learning; Cauchy mutation operator; adaptive inertia weight; fault diagnosis

## 0 引言

油浸式电力变压器是输变电系统最重要的高压设备之一<sup>[1-2]</sup>,决定了电网能否可靠供电。因此,及时准确地了解变压器故障的类型,对于电网的安全运行具有重要意义<sup>[3]</sup>。当变压器发生故障或有潜在故障时,油中溶

解的各种气体( $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$ )的含量会发生显著变化<sup>[4]</sup>。所以,基于溶解气体分析的故障诊断技术在油浸式电力变压器领域得到了广泛应用,其中包括特征气体法和基于 DGA 数据<sup>[5]</sup>的四比、三比法、大卫三角形法<sup>[6]</sup>等。传统的变压器故障诊断方法虽然简单有效,但存在编码缺陷、编码边界过宽、临界值判据缺陷等问题,影响故障分析的可靠性。近年来,随着人工智能

收稿日期: 2022-03-28      Received Date: 2022-03-28

\* 基金项目: 国家自然科学基金(51974151)、辽宁省高等学校创新团队项目(LT2019007)资助

(artificial intelligence, AI) 的发展, 基于 DGA 数据集的变压器故障分类模型的发展, 实现了对变压器故障进行智能诊断。像支持向量机 (support vector machine, SVM)<sup>[7]</sup>、BP 神经网络<sup>[8]</sup>、极限学习机 (extreme learning machine, ELM)<sup>[9]</sup>、深度信念网络 (deep belief networks, DBN)<sup>[10]</sup> 等一些智能算法在变压器故障诊断中都取得了一定研究成果。文献[11]通过对支持向量机的核函数的优化来诊断变压器的故障类型, 代替人为选择参数, 提高了诊断精度。在文献[12]中, 使用残差学习代替了传统 BP 神经网络的恒等映射学习, 利用残差神经网络用于变压器诊断。文献[13]在深度信念网络中利用优化算法改进训练性能函数对变压器故障进行诊断, 文献[14]通过人工鱼群算法对极限学习机的权值及阈值进行优化, 对变压器故障进行诊断取得了较好的诊断效果。在文献[15]中, 采用主成分分析 (principal component analysis, PCA) 对变压器数据进行预处理, 并利用蜂群算法优化 SVM 进行故障诊断。虽然上述模型提高了变压器故障诊断的准确性, 但面对复杂的集中数据存在容易陷入过拟合, 收敛速度慢, 分类精度不稳定等情况。概率神经网络 (probabilistic neural network, PNN) 是常用的有监督神经网络, 其学习过程主要采用贝叶斯分类规则。PNN 模型具有并行分布处理、自组织、自学习等特点。在故障诊断中面对复杂的集中数据具有很好的故障诊断能力。然而, PNN 的网络参数 (模式层平滑因子  $\sigma$ ) 在很大程度上决定了网络的性能, 根据训练数据选取合适的参数往往会提高 PNN 的分类性能<sup>[16]</sup>。人为选择参数, 工作量大, 而且很难将参数调整到最合适值。文献[17]通过 PSO 算法搜索  $\sigma$  值, 文献[18]采用 IFA 算法自动寻找 PNN 网络最佳  $\sigma$  值。这些优化算法虽然取得了一些效果, 但在收敛速度, 全局优化能力等方面不足, 容易陷入局部最优, 影响 PNN 的分类准确度。因此可以通过采用新的智能优化算法去解决全局寻优问题。

针对上述问题, 本文提出一种多策略改进寄生捕食优化算法 (parasitism-predation algorithm, PPA) 优化 PNN 变压器故障诊断模型。首先采用 PCA 对变压器的故障数据进行降维处理去除数据无效特征, 然后结合混沌反向学习、柯西分布和融合贝塔分布的线性递减函数的权重等多策略改进寄生捕食算法, 使全局搜索能力和局部开发的能力达到平衡, 提高 PPA 算法的寻优能力, 之后使用改进后的算法 (IPPA) 对 PNN 的平滑因子进行智能寻优。最后与传统 PPA-PNN 和 PSO-PNN 的诊断效果进行对比, 证明本文所提出的变压器故障分类模型具有更高的准确率。

## 1 寄生捕食优化算法

寄生捕食算法是由 Mohamed 等<sup>[19]</sup> 2019 年提出的一

种新的智能优化算法。该算法实现简单、控制参数少、效率高。具有很好的寻优能力。以乌鸦-布谷鸟-猫系统寄生捕食的行为进行模拟。

1) 初始化。在边界范围内随机初始化, 得到种群的最优巢如下:

$$X_i^{\text{new}} = X_i^{\text{min}} + r_1(X_i^{\text{max}} - X_i^{\text{min}}) \quad (1)$$

2) 筑巢阶段

筑巢阶段是通过两个状态模拟乌鸦飞行。第 1 个状态是随机生成 1 个新的乌鸦位置。

$$X_i^{t+1} = X_i^t + F(X_{r1} - X_i^t) \quad \forall i \in n_{\text{crow}} \quad (2)$$

式中:  $r1$  为随机数  $F$  为莱维飞行函数。第 2 个状态是把超出维度范围的种群按照式(3)重新进行初始化。

$$X_{i,\text{out}}^{\text{new}} = X_{i,\text{out}}^{\text{min}} + (X_{i,\text{out}}^{\text{max}} - X_{i,\text{out}}^{\text{min}}) \text{rand}[0, 1] \quad (3)$$

3) 寄生阶段

此阶段布谷鸟根据适应度选择被寄生的巢。

$$X_{i,\text{new}}^{\text{cuckoo}} = X_{i,\text{old}}^{\text{cuckoo}} + S_G \cdot k \quad (4)$$

$X_{i,\text{old}}^{\text{cuckoo}}$  采用轮盘选择, 选择鸟巢位置,  $S_G$  服从均匀高斯分布,  $k$  定义为二进制矩阵,

4) 捕食阶段

包括 3 个步骤:

(1) 更新每个维度的速度如下:

$$v_{k,d} = v_{k,d} + r_i C(x_{\text{best},d} - x_{k,d}), d = 1, 2, \dots, M \quad (5)$$

式中:  $v_{k,d}$  表示在第 1 个维度上猫的速度,  $x_{\text{best},d}$  表示适应度值最好的猫的位置,  $x_{k,d}$  表示猫的位置,  $C$  为常数,  $r_i$  为  $[0, 1]$  范围内的随机值。

(2) 检查更新速度是否超过最大速度范围。(如果大于最大速度, 将速度限制修改为从 1 线性降低到 0.25)。

(3) 更新 cat 的位置:

$$x_{k,d} = x_{k,d} + v_{k,d} \quad (6)$$

### 1.1 PPA 算法的改进

在标准的 PPA 中采用随机分布的方式对种群进行初始化, 这种方式会造成种群分布不均匀, 导致个体前期搜索存在一定的盲目性, 从而使得算法收敛速度慢, 求解精度低。其次, 在寄生阶段是使用轮盘选择方法选择  $X_{i,\text{new}}^{\text{cuckoo}}$ , 轮盘选择方法是根据适应度值与总适应度值之比作为选择概率, 决定其被选中的可能性<sup>[20]</sup>。这种选择方法会使布谷鸟在高适应度的巢穴中选择的鸟巢, 从而会使搜索空间相对集中, 会导致陷入局部最优的情况。同时, 在追踪阶段, 是使用速度矢量和猫的先前位置来更新跟踪模式下猫的位置, 因为其权重固定, 在后续迭代中容易出现振荡, 导致局部或全局极值附近的优化精度较低。

综上所述, 本文根据以上 PPA 算法的缺陷引入 3 个策略对标准 PPA 算法进行改进: 1) 采用混沌反向学习方法替代原有的随机初始化, 使算法在搜索初期就趋向于全局搜索, 避免早熟; 2) 引入柯西分布策略对鸟巢选择进

行扰动,避免算法陷入局部最优;3)通过在追踪阶段添加自适应惯性权重,以平衡搜索效率和优化精度。改进后的算法流程如图1所示。

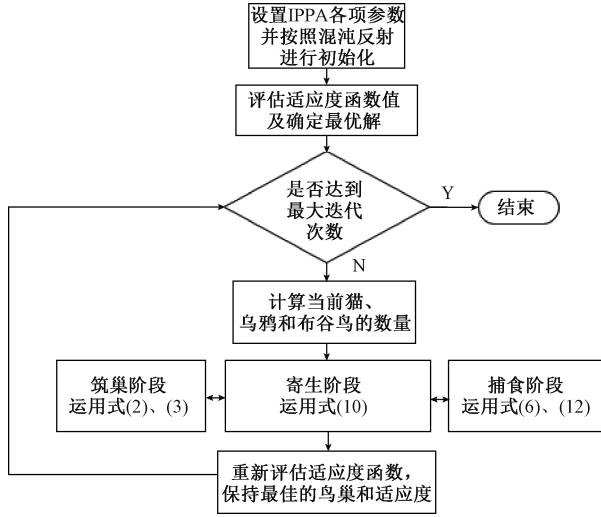


图1 PPA改进后算法流程

Fig. 1 Flowchart of improved PPA algorithm

### 1) 混沌反向学习策略

混沌策略具有随机性、遍历性和规律性的特点。可以应用其遍历性的特点来弥补PPA算法随机种群的不足,使种群均匀分布,提高种群质量。反向学习通过当前解找到对应的反向解,然后评估选择更好的解,从而引导个体寻找最优解。因此本文采用Sin混沌映射和反向学习进行初始化,使种群分布更加均匀,搜索范围变得更广阔,实现对更多优质搜索区域的勘探以提升算法的局部极值逃逸能力和收敛性能。

Sin混沌1维映射表达式如下:

$$\begin{cases} X_{n+1} = \sin(2/X_n), & n = 0, 1, \dots, N \\ -1 \leq X_n \leq 1, & X_n \neq 0 \end{cases} \quad (7)$$

$X_n$ 是取值为 $(-1, 1)$ 的序列且初始值不能设置为0。

假设随机生成的初始种群为 $X_i = [x_{i1}, \dots, x_{id}, \dots, x_{iD}]$ 。其中 $i = 1, 2, \dots, N$ ,则 $X_i$ 对应的反向种群 $X_i^* = [x_{i1}^*, \dots, x_{id}^*, \dots, x_{iD}^*]$ 定义为:

$$X_i^* = x_{\min j} + x_{\max j} - X_i \quad (8)$$

式中: $[x_{\min j}, x_{\max j}]$ 为搜索空间的动态边界。将sin混沌 $X_n$ 和反向学习 $X_i^*$ 结合形成新的种群 $X$ ,在新的种群里选择 $N$ 个适应度较优的个体做为初始种群。

### 2) 柯西变异策略

本文在轮盘选择的基础上引入柯西变异策略,根据柯西分布函数的特性使其能够在短时间内对当前解进行扰动,快速搜索该区域内的优良解。利用柯西变异算子的调节功能,使算法逃离局部最优,继续搜索新区域。柯西分布函数如式(9)所示:

$$f(x) = \frac{1}{\pi} \cdot \frac{\lambda}{\lambda + x^2}, x \in (-\infty, +\infty) \quad (9)$$

对使用轮盘抉择鸟巢位置利用柯西变异算子进行扰动,得到新的鸟巢位置如式(10)所示:

$$X_{i, \text{new}}^{\text{cuckoo}} = \text{Cauchy}(0, \sigma^2) \cdot X_{i, \text{old}}^{\text{cuckoo}} + S_G \cdot k \quad (10)$$

$\text{Cauchy}(0, \sigma^2)$ 为服从柯西分布的柯西算子, $X_{i, \text{old}}^{\text{cuckoo}}$ 为旧鸟巢位置, $S_G$ 服从均匀高斯分布, $k$ 定义为二进制矩阵。

### 3) 融合贝塔分布的线性递减函数的权重

本文在式(5)的基础上加入融合贝塔分布的线性递减函数的权重因子调整方法。通过在位置方程中加入随机选取的权值作为参数,建立新的速度方程形式来提高在最优猫附近的搜索能力。

$$w(k) = w_{\max} - \frac{(w_{\max} - w_{\min})t}{T_{\max}} + \sigma B(p, q) \quad (11)$$

式中: $w_{\max}$ 为0.9, $w_{\min}$ 为0.4。 $t$ 为当前迭代次数, $T_{\max}$ 为最大迭代次数。 $\sigma$ 为惯性权重调整因子取0.1。用于调节权重 $w$ 的偏移度,通过使用这个参数,协调其局部开发和全局探索的能力。 $B(p, q)$ 表示贝塔分布的随机数,其中 $p = 1, q = 2$ ;由式(11)可知,在迭代的开始阶段权重的值比较大,使其具有强大的全局搜索能力。之后随着迭代次数的增加,权重也会减小,算法会逐渐陷入局部最优状态。此时加入贝塔分布的随机调整策略在一定程度上会产生一个随机的值对 $w$ 进行动态调整,使其跳出局部最优状态,向更好的区域探索,以获得更好的优化效果,提高后期的搜索精度,达到平衡搜索速度和优化精度的目的。

改进后的公式为:

$$v_{k,d} = w(k)v_{k,d} + r_i C \cdot (x_{\text{best},d} - x_{k,d}), d = 1, 2, \dots, M \quad (12)$$

式中: $w(k)$ 为自适应权重, $v_{k,d}$ 表示在第1个维度上猫的速度, $x_{\text{best},d}$ 表示适应度值最好的猫的位置, $x_{k,d}$ 表示猫的位置, $c$ 为常数, $r_i$ 为 $[0, 1]$ 范围内的随机值。

### 1.2 IPPA 算法性能分析

对改进算法用标准函数进行仿真测试实验,同时与标准PPA算法和常用的PSO优化算法进行对比,本文选用Step Function和Generalized Penalized Function两个典型的基准测试函数,Step Function属于维度可变单峰函数,它只包含一个全局最优点,可以使用这个函数来测试算法的开发能力。Generalized Penalized Function为维度可变多峰函数,而且包含多个局部最优点,很难找到全局最优,所以可用于来测试算法的全局探索能力<sup>[21]</sup>。

Step Function:

$$f_1(x) = \sum_{i=1}^n ([x_i + 0.5])^2 \quad (13)$$

Generalized Penalized Function:

$$f_2(x) = 0.1 \{ \sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \} + \sum_{i=1}^n u(x_i, 5, 100, 4) \quad (14)$$

对这两个测试函数进行独立仿真实验,最大迭代次数设置为  $T = 500$ ,维数  $D = 30$ ,仿真结果如图 2 和 3 所示。




图 2 PPA、IPPA 和 PSO 对  $f_1$  函数的优化过程

Fig. 2 Optimization process of  $f_1$  function by PPA, IPPA and PSO




图 3 PPA、IPPA 和 PSO 对  $f_2$  函数的优化过程

Fig. 3 Optimization process of  $f_2$  function by PPA, IPPA and PSO

由图 2 和 3 可以看出,在 Step Function 函数测试中,3 种算法都随着迭代次数的增加逐渐收敛。但是 IPPA 的收敛速度明显要快于 PSO 和 PPA,并且需要的迭代次数更少。IPPA 在迭代 38 次就已经达到全局最优解,而 PPA 和 PSO 分别需要 320 次和 110 次才能达到收敛状态并且适应度值较低。在 Generalized Penalized Function 函数测试中 IPPA 在迭代 20 次时,就达到了最优解,而 PPA 则需要 200 次后才逐渐趋近收敛状态。通过以上分析可知,IPPA 算法比 PSO 和 PPA 算法具有更好的收敛

速度和全局优化能力。

## 2 PNN 神经网络

PNN 模型层采用径向基函数,考虑了不同类型样本的交错效应,具有很好的容错能力,与其他网络模型相比具有一定优势。只要样本数据足够多,PNN 就可以收敛到贝叶斯分类器,而不存在反向传播 (backpropagation, BP) 神经网络的局部极小问题。PNN 包含四层网络结构,分别为输入层、模式层、求和层、输出层。其结构图如图 4 所示。

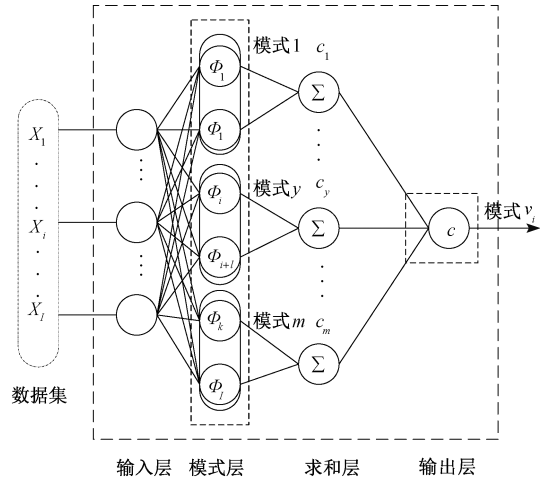


图 4 PNN 神经网络结构图

Fig. 4 PNN neural network structure diagram

输入层的神经元数和样本向量维数相等。模式层是根据自由基的中心和训练样本之间的距离求出来的。每个模式的单元输出为:

$$f_A(\mathbf{X}) = \frac{1}{m} \frac{1}{(2\pi)^{p/2} \sigma^p} \sum_{i=1}^m \exp \left[ \frac{(\mathbf{X} - \mathbf{X}_{Ai})^T (\mathbf{X} - \mathbf{X}_{Ai})}{2\sigma^2} \right] \quad (15)$$

式中:  $\mathbf{X} = (x_1, x_2, x_3, \dots, x_n)$  为输入特征向量,  $\sigma$  为平滑因子。

求和层将同类型模式层神经元的输出权值取平均,结果如下:

$$v_i = \frac{\sum_{j=1}^L \Phi_{ij}}{L} \quad (16)$$

其中,  $v_i$  为第种神经元的输出,  $L$  为第  $i$  种神经元的数量。

输出层中最大输出对应的类型为输出类型。结果如下:

$$\text{Type}(v_i) = \arg\max(v_i) \quad (17)$$

在样本数据和类别确定时,神经网络的网络结构和



神经元数目都是确定的,因此概率神经网络的性能取决于神经网络的参数选择。其中平滑因子作为神经网络重要的输入参数,因此平滑因子对概率神经网络模型的识别性能有重要且直接的影响。如果 $\sigma$ 值选择不当,过大或过小都会使网络收敛过快或容易陷入局部最优,从而导致分类精度大幅下降。所以在诊断模型的设计过程中,需要尝试不同的 $\sigma$ 值来确定最优的平滑因子。IPPA算法因其具有良好的全局优化能力。因此,本文拟通过IPPA算法对PNN的平滑因子( $\sigma$ )进行优化,提升PNN的分类诊断性能。

3 基于 IPPA-PNN 变压器故障诊断模型

本文基于 DGA 数据建立了 PNN 故障诊断模型 (IPPA-PNN)。IPPA 优化 PNN 流程如图 5 所示。

- 1) 获取变压器故障样本数据,对故障样本数据进行预处理,将其划分为训练集和测试集。
- 2) 初始化 PNN 网络,取随机平滑因子 $\sigma$ 。
- 3) 初始化 PPA 算法参数,其中种群规模 $N=30$ ,搜索空间维度 $D$ 设置为 1,最大迭代次数 $T=100$ ,并采用式(8)初始化 IPPA 种群,使种群均匀分布,对位置初始化。
- 4) 计算适应度值,根据目标函数记录当前位置。
- 5) 判断是否满足条件(若是,IPPA 优化终止,若否,继续进行步骤 6)。
- 6) 计算当前猫、乌鸦和杜鹃的数量。
- 7) 根据方程式(2)、(3)、(10)、(12),调整鸟巢位置,得到新的最优解位置。
- 8) 重新评估适应度函数,保持最佳的巢和适应度。
- 9) 返回步骤 5)。
- 10) 如此反复,最后获得 PNN 最优权重,进行 PNN 网络训练。
- 11) 计算测试数据,输出测试集故障分类结果。

4 实验测试及分析

4.1 数据提取

基于变压器实际运行数据建立了具体的电力变压器故障诊断模型。按照 DL/T722—2014 变压器油中溶解气体分析和判断准则,将变压器故障类型分为低能放电、低温过热、高能放电、高温过热、局部放电、中温过热、正常,7 种类型,编号为 0~6。本文搜集了某变压器实际运行过程中的 300 组变压器油中溶解气体( $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$ )含量的数据作为故障诊断模型的输入信息,故障类型的向量编码作为输出信息。将其按照 2:1 的比例分为 200 组训练集,100 组的测试集。训练及测试故障样本数据分配参照表 1 和 2。然后,将数据送入基于

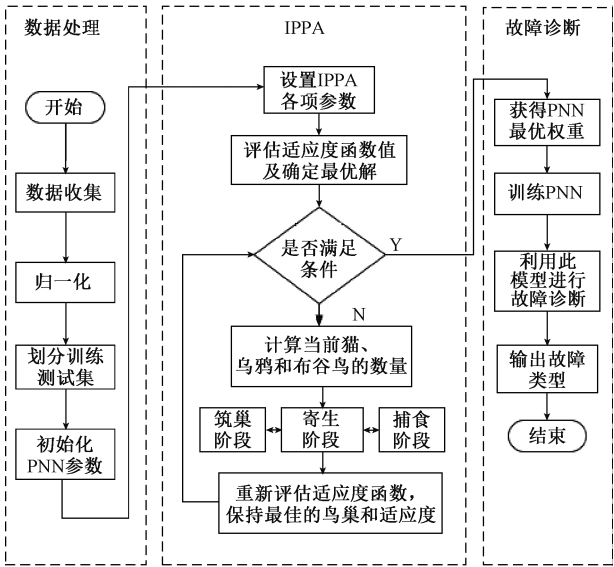


图 5 IPPA-PNN 模型流程  
Fig. 5 Flow chart of IPPA-PNN model

PNN 分类器进行训练。最后,得到了测试集的预测分类结果。

表 1 训练样本数据的分布

Table 1 Data distribution of training samples

| 故障类型  | 低能 | 低温 | 高能 | 高温 | 局部 | 中温 | 正常 |
|-------|----|----|----|----|----|----|----|
| 训练样本数 | 25 | 30 | 40 | 34 | 25 | 26 | 20 |

表 2 测试样本数据的分布

Table 2 Distribution of test sample data

| 故障类型  | 低能 | 低温 | 高能 | 高温 | 局部 | 中温 | 正常 |
|-------|----|----|----|----|----|----|----|
| 测试样本数 | 17 | 15 | 14 | 15 | 12 | 15 | 12 |

4.2 变压器故障数据预处理

变压器原始故障数据由于存在无效和冗余特征会影响模型收敛速度和诊断精度。因此本文采用 PCA 对故障数据进行降维。达到提高模型的收敛速度和诊断精度的目的。

通过计算每个特征值对应的特征向量的贡献率,由图 6 可以看出,前 3 个主成分的累积贡献率达到了 88%,能够获取全部信息,故最终维度确定为 3。部分数据特征提取结果如表 3 所示。

4.3 不同故障诊断模型对比分析

将经 PCA 降维过后的特征信息输入到 IPPA-PNN 的变压器故障诊断模型中,进行分类测试。将其分类结果与 PSO 和 PPA 优化的 PNN 的结果进行对比分析,诊断准确率对比如表 4 所示,诊断结果如图 7~9 所示。




图 6 主成分贡献率图

Fig. 6 Contribution rate of eigenvalues

表 3 部分数据特征提取结果

| Table 3 Feature extraction results of part data |                |                |                |
|---|----------------|----------------|----------------|
| 序号  | 部分特征提取结果       |                |                |
|   | 第一主元           | 第二主元           | 第三主元           |
| 1   | -0.567 423 881 | -0.176 742 909 | -0.082 367 905 |
| 2   | -0.505 051 185 | -0.065 868 3   | -0.041 954 545 |
| 3   | 0.525 978 153  | -0.032 348 546 | -0.003 201 571 |
| 4   | -0.608 949 05  | -0.013 620 584 | -0.015 775 473 |
| 5   | 0.133 932 747  | -0.365 606 271 | 0.549 848 925  |
| 6   | -0.380 037 91  | 0.378 120 06   | -0.065 178 238 |
| 7   | 0.514 632 635  | -0.179 851 059 | -0.001 432 443 |
| 8   | 0.338 560 987  | -0.068 333 103 | -0.007 642 804 |
| 9   | 0.538 092 177  | -0.105 253 648 | 0.280 035 417  |
| 10  | -0.395 807 076 | -0.072 112 93  | -0.158 063 068 |

表 4 变压器故障诊断结果

| Table 4 Transformer fault diagnosis results (%) |         |         |          |
|---|---------|---------|----------|
| 故障类型  | PSO-PNN | PPA-PNN | IPPA-PNN |
|   | 正确率     | 正确率     | 正确率      |
| 低能  | 88.20   | 88.20   | 94.11    |
| 低温  | 86.66   | 86.66   | 93.33    |
| 高能  | 78.60   | 92.85   | 92.85    |
| 高温  | 80.00   | 86.66   | 100.00   |
| 局部  | 91.66   | 91.66   | 91.66    |
| 中温  | 80.00   | 80.00   | 86.66    |
| 正常  | 75.00   | 75.00   | 91.66    |

由图 7~9 可知,经过反复的迭代验证,IPPA-PNN 在变压器故障诊断的应用方面有明显的优势。PSO-PNN 模型故障诊断错误个数为 17 个,PPA-PNN 错误数 14 个,IPPA-PNN 错误数 7 个,PPA 算法比 PSO 算法的故障诊断正确率高 3%。而改进后的 IPPA 算法,故障诊断的正确率比 PSO 和 PPA 算法分别提高 10%和 7%。

经过对 3 种模型实验结果的验证对比,本文所提出




图 7 PSO-PNN 故障诊断结果

Fig. 7 PSO-PNN fault diagnosis results




图 8 PPA-PNN 故障诊断结果

Fig. 8 PPA-PNN fault diagnosis results




图 9 IPPA-PNN 故障诊断结果

Fig. 9 IPPA-PNN fault diagnosis results

的 IPPA-PNN 的变压器故障诊断模型的诊断准确率能够达到 93%,而使用传统 PSO-PNN 以及 PAA-PNN 诊断模

型的准确率分别为83%和86%,结果证明采用IPPA算法优化PNN的平滑因子,比PAA算法优化PNN的平滑因子以及PSO优化PNN的平滑因子具有更高的故障识别正确率。

## 5 结 论

针对电力变压器故障的多样性和复杂性导致诊断模型精度相对低问题,提出了一种基于寄生捕食(IPPA)优化和概率神经网络(PNN)的变压器故障诊断模型。通过对比分析比较,得出如下结论:

1)在标准的狩猎捕食算法的基础上引入了混沌反向学习、柯西变异策略和融合贝塔分布的线性递减函数权重策略,结果表明,该方法有效地提高了算法的收敛速度和精度,证明了改进方法的有效性。

2)用主成分分析法对变压器数据进行预处理,去除数据的无效特征,降低特征向量的维数。同时使用改进后的寄生捕食算法优化PNN的参数,提高了PNN的泛化能力和正确率。

3)通过实际数据对本文所提方法进行验证,实验表明,本文所提出的方法与PPA-PNN和PSO-PNN相比,该方法的准确率分别提高7%和10%,故障诊断准确率达到93%,实用性更强。

## 参考文献

- [1] 田凤兰,张恩泽,潘思蓉,等.基于特征量优选与ICA-SVM的变压器故障诊断模型[J].电力系统保护与控制,2019,47(17):163-170.  
TIAN F L, ZHANG EN Z, PAN S R, et al. Transformer fault diagnosis model based on feature optimization and ICA-SVM [J]. Power System Protection and Control, 2019, 47(17): 163-170.
- [2] 程加堂,熊伟,徐绍坤,等.基于改进粒子群优化神经网络的电力变压器故障诊断[J].高压电器,2012,48(2):42-45.  
CHENG J T, XIONG W, XU SH K, et al. Power transformer fault diagnosis based on improved particle swarm optimization neural network [J]. High Voltage Apparatus, 2012, 48(2): 42-45.
- [3] 王雨虹,王志中,付华,等.多策略改进麻雀算法与BiLSTM的变压器故障诊断研究[J].仪器仪表学报,2022,43(3):87-97.  
WANG Y H, WANG ZH ZH, FU H, et al. Multi-strategy improved sparrow algorithm and bilstm for transformer fault diagnosis [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87-97.
- [4] 陈欢,彭辉,舒乃秋,等.基于蝙蝠算法优化最小二乘双支持向量机的变压器故障诊断[J].高电压技术,2018,44(11):3664-3671.  
CHEN H, PENG H, SHU N Q, et al. Optimization of least square double support vector machine for transformer fault diagnosis based on bat algorithm [J]. High Voltage technology, 2018, 44(11): 3664-3671.
- [5] KHAN S A, MD EQUBAL, ISLAM T. A comprehensive comparative study of DGA based transformer fault diagnosis using fuzzy logic and ANFIS models[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2015, 22(1):590-596.
- [6] 李笑竹,陈志军,樊小朝,等.基于ACS-SA文化基因算法的BP神经网络变压器故障诊断[J].高压电器,2018,54(2):134-139,146.  
LI X ZH, CHEN ZH J, FAN X CH, et al. BP neural network for transformer fault diagnosis based on ACS-SA cultural gene algorithm [J]. High Voltage Apparatus, 2018, 54(2): 134-139, 146.
- [7] 杜绪伟,陈东.基于LBP和LPQ特征融合的PSO-SVM缺陷分类[J].电子测量技术,2020,43(21):122-126.  
DU X W, CHEN D. PSO SVM defect classification based on LBP and LPQ feature fusion [J]. Electronic Measurement Technology, 2020, 43(21): 122-126.
- [8] 赵玲玲,王群京,陈权,等.基于IBBOA优化BP神经网络的变压器故障诊断[J].电工电能新技术,2021,40(9):39-46.  
ZHAO L L, WANG Q J, CHEN Q, et al. Transformer fault diagnosis based on IBBOA optimized BP neural network [J]. New Technology of Electrical Engineering and Energy, 201, 40(9): 39-46.
- [9] 刘宇,廉洪波,王炜.基于改进K-means和DE-ELM的配电网负荷预测研究[J].国外电子测量技术,2019,38(5):45-49.  
LIU Y, LIAN H B, WANG W. Research on load forecasting of distribution network based on improved K-means and DE-ELM [J]. Foreign Electronic Measurement Technology, 2019, 38(5): 45-49.
- [10] 刘仲民,翟玉晓,张鑫,等.基于DBN-IFCM的变压器故障诊断方法[J].高电压技术,2020,46(12):4258-4265.  
LIU ZH M, ZHAI Y X, ZHANG X, et al. Transformer fault diagnosis method based on deep belief network and improved fuzzy C-means clustering [J]. High Voltage Technology, 2020, 46(12): 4258-4265.
- [11] 李黄曼,张勇,张瑶.基于ISSA优化SVM的变压器故障诊断研究[J].电子测量与仪器学报,2021,35(3):123-129.  
LI H M, ZHANG Y, ZHANG Y. Research on transformer fault diagnosis based on ISSA optimized SVM [J]. Journal

- of Electronic Measurement and Instrumentation, 2021, 35(3):123-129.
- [12] 赵文清, 严海, 周震东, 等. 基于残差 BP 神经网络的变压器故障诊断[J]. 电力自动化设备, 2020, 40(2): 143-148.  
ZHAO W Q, YAN H, ZHOU ZH D, et al. BP neural network based on residual winding of transformer fault diagnosis [J]. Electric Power Automation Equipment, 2020, 40(2): 143-148.
- [13] 王德文, 雷倩. 基于贝叶斯正则化深度信念网络的电力变压器故障诊断方法[J]. 电力自动化设备, 2018, 38(5):129-135.  
WANG D W, LEI Q. Power transformer fault diagnosis method based on bayesian regularization deep belief network [J]. Electric Power Automation Equipment, 2018, 38(5):129-135.
- [14] 雷帆, 高波, 袁海满, 等. 基于 DGA 的粗糙集与人工鱼群极限学习机的变压器故障诊断[J]. 高压电器, 2017, 53(10):124-130.  
LEI F, GAO B, YUAN H M, et al. Transformer fault diagnosis based on DGA rough set and artificial fish swarm extreme learning machine [J]. High Voltage Apparatus, 2017, 53(10):124-130.
- [15] 谢国民, 倪乐水. 基于 IABC 优化 SVM 的变压器故障诊断[J]. 电力系统保护与控制, 2020, 48(15): 156-163.  
XIE G M, NI L SH. IABC optimizing SVM based transformer fault diagnosis [J]. Power System Protection and Control, 2020, 48(15):156-163.
- [16] ZHANG Y, GUO J, ZHOU Q, et al. Research on damage identification of hull girder based on probabilistic neural network (PNN) [J]. Ocean Engineering, 2021, 238: 109737.
- [17] 覃星福, 龚仁喜. 基于广义 S 变换与 PSO-PNN 的电能质量扰动识别[J]. 电力系统保护与控制, 2016, 44(15):10-17.  
QIN X F, GONG R X. Power quality disturbance identification based on generalized s-transform and PSO-PNN [J]. Power System Protection and Control, 2016, 44(15):10-17.
- [18] 宋玉琴, 张建. IFA-PNN 在电力变压器故障诊断中的应用[J]. 测控技术, 2018, 37(12):46-50.  
SONG Y Q, ZHANG J. Application of IFA-PNN in power transformer fault diagnosis [J]. Measurement and Control Technology, 2018, 5(12): 46-50.
- [19] MOHAMED A A A, HASSAN S A, HEMEIDA A M, et al. Parasitism-predation algorithm (PPA): A novel approach for feature selection[J]. Ain Shams Engineering Journal, 2020, 11(2):293-308.
- [20] 张静, 高尚. 基于轮盘赌反向选择机制的果蝇优化算法[J]. 计算机与数字工程, 2020, 48(7): 1595-1600, 1742.  
ZHANG J, GAO SH. Fruit fly optimization algorithm based on roulette reverse selection mechanism [J]. Computer and Digital Engineering, 2020, 48(7): 1595-1600, 1742.
- [21] 范千, 陈振健, 夏樟华. 一种基于折射反向学习机制与自适应控制因子的改进樽海鞘群算法[J]. 哈尔滨工业大学学报, 2020, 52(10):183-191.  
FAN Q, CHEN ZH J, XIA ZH H. An improved Salp population algorithm based on refraction reverse learning mechanism and adaptive control factor [J]. Journal of Harbin Institute of Technology, 2020, 52(10):183-191.

## 作者简介



**徐耀松**, 2004 年于辽宁工程技术大学获得硕士学位, 2012 年于天津大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为智能测控系统设计。

E-mail: 38158183@qq.com

**Xu Yaosong** received his M. Sc. degree from Liaoning Technical University in 2004, Ph. D. degree from Tianjin University in 2012. Now he is an associate professor in Liaoning Technical University. His research interests include intelligent measurement and control system design.



**包力铭** (通信作者), 2020 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为电气信息检测技术与故障诊断。

E-mail: 953680515@qq.com

**Bao Liming** (Corresponding author) received his B. Sc. degree from Liaoning Technical University in 2020. Now he is a M. Sc. candidate of Liaoning Technical University. His research interests include electrical information detection technology and fault diagnosis.



**管智峰**, 现为辽宁工程技术大学硕士研究生, 主要研究方向为电气信息检测技术与故障诊断。

E-mail: 874595963@qq.com

**Guan Zhifeng** is a M. Sc. candidate of Liaoning Technical University. His research interests include electrical information detection technology and fault diagnosis.