

基于改进粒子群优化 T-S ANFIS 算法的 诊断油浸式变压器故障研究

乐效鹏, 史兵, 李嘉诚

(常州大学 机械与轨道交通学院, 江苏 常州 213164)

摘要: 为了有效提升油浸式变压器故障诊断的精度与速度, 提出一种基于改进粒子群算法 (IPSO) 优化 T-S 型自适应模糊神经网络 (T-S ANFIS) 的油浸式变压器故障诊断模型; 引入动态惯性权重和学习因子线性调整策略, 并利用收敛域和欧式距离判别雷同粒子, 以克服粒子群算法易早熟、后期易陷入局部最优的问题; 接着通过 IPSO 对 T-S ANFIS 的前提参数进行优化, 提高网络的收敛速度; 最后通过仿真实验验证基于 IPSO 优化 T-S ANFIS 的变压器故障诊断模型效果, 结果表明所构建模型的故障诊断最优准确率约为 98%, 与 ANFIS 及 PSO-ANFIS 模型相比具有较高的故障诊断精度及效率。

关键词: 油浸式变压器; 改进粒子群; 自适应模糊神经网络; 故障诊断; 算法优化

Research on Fault Diagnosis of Oil Immersed Transformer Based on Improved Particle Swarm Optimization T-S ANFIS Algorithm

YUE Xiaopeng, SHI Bing, LI Jiacheng

(College of Mechanical and Rail Transportation, Changzhou University, Changzhou 213164, China)

Abstract: In order to effectively improve the accuracy and efficiency of fault diagnosis for oil-immersed transformers, An oil-immersed transformer fault diagnosis model based on improved particle swarm optimization (IPSO) optimized T-S adaptive neuro fuzzy inference system (T-S ANFIS) is proposed. The dynamic inertia weight and linear learning factor adjustment strategy are introduced, the convergence domain and Euclidean distance are utilized to distinguish identical particles, and overcome the problems of premature convergence and local optima in particle swarm optimization. Furthermore, IPSO is used to optimize the T-S ANFIS's premise parameters and improve the network's convergence speed. Finally, through the simulation experiments, the effectiveness of the IPSO-optimized T-S ANFIS fault diagnosis model is verified, the results show the optimal fault diagnosis accuracy of the proposed model reaches about 98%, compared with ANFIS and PSO-ANFIS models, the proposed model has a high accuracy and efficiency in fault diagnosis.

Keywords: oil immersed transformer; improved particle swarm optimization; adaptive fuzzy neural network; fault diagnosis; algorithm optimization

0 引言

油浸式变压器是电力系统中常用的重要设备, 其安全运行对于电网稳定具有至关重要的作用^[1-2]。然而, 由于长期使用和各种外部因素的影响, 油浸式变压器容易出现各种故障, 如低能放电、高温过热、绕组短路等^[3-5], 这些故障若得不到及时准确的诊断, 将导致设备失效或严重事故。

文献 [6] 通过在线实时监测和分析油色谱, 成功实现了对油浸式变压器内部故障的诊断和运行状态的评估。文献 [7] 提出了一种反向传播 (BP, back propagation) 神经网络综合蜂群算法的方式, 并构建了基于 BP 的变压器故障诊断模型, 有效提高了故障诊断的精确度。文献 [8] 应用多层动态自适应优化参数法对最小二乘支持向量机 (LSS-

VM, least squares support vector machine) 进行参数优化, 并将其用于油浸式变压器故障诊断中, 成功证明了该算法的有效性。文献 [9] 将 BP 神经网络与改进的自适应提升算法相结合, 构建了变压器故障的串联诊断模型, 并通过实验证明该模型对变压器故障诊断的准确性有较好的提高。文献 [10] 采用 Pearson 相关系数对特征气体集进行滤波和优化, 结合 Lasso 回归建立特征的多维线性模型, 并通过实例验证了动态模型对变压器故障诊断的可行性。文献 [11] 使用 Rdpid Miner 服务器构建数据挖掘分析工具并与光谱技术结合, 通过连续迭代以确定变压器故障诊断准确性的最佳吸收波长组合。文献 [12] 利用飞蛾火焰优化算法 (MFO, moth flame optimizer) 对概率神经网络的平滑因子

收稿日期: 2023-05-06; 修回日期: 2023-05-22。

基金项目: 江苏省研究生实践创新计划项目 (SJCX22_1414)。

作者简介: 乐效鹏 (1997-), 男, 硕士研究生。

通讯作者: 史兵 (1976-), 男, 博士, 副教授, 硕士生导师。

引用格式: 乐效鹏, 史兵, 李嘉诚. 基于改进粒子群优化 T-SANFIS 算法的诊断油浸式变压器故障研究 [J]. 计算机测量与控制, 2023, 31(10): 33-39.

进行优化,通过实验数据仿真,证明了模型对变压器故障诊断的准确率有较好提升。文献 [13] 采用 KPCA 算法对数据进行降维处理,并利用 DBSO 算法对 CatBoost 模型进行优化和故障诊断,实验证明优化后的模型与其他预处理方法相比,在变压器故障诊断的准确性及效率方面都有显著的提高。文献 [14] 使用公共向量方法对变压器油中溶解气体进行数据分析,通过电气测试实验证明了其在诊断精度和运行时间方面的优越性能。文献 [15] 先采用粗糙集理论对故障数据进行优化处理,再利用天牛须算法优化 BP 神经网络模型进行诊断研究,经实验证明了方法的可行性和有效性。文献 [16] 提出了一种基于改进天鹰算法 (MAO, modified aquila optimizer) 优化核极限学习机 (KELM, Kernel based extreme learning machine) 的诊断方法,有效提升了故障诊断的收敛速度。文献 [17] 提出用 MPC 优化贝叶斯网络的变压器故障诊断方法,实验表明改进方法后的故障诊断正确率更高。

综上所述,现阶段国内外均已研究出多种油浸式变压器的故障诊断模型,提升故障诊断的精度及效率仍是目前研究的重点方向。基于此,本文提出了一种改进的粒子群算法,它能够有效地解决自适应模糊神经网络参数寻优能力较弱、收敛速度较慢以及粒子群后期容易陷入局部最优等问题。改进算法应用收敛域和欧式距离判别雷同粒子以一定的概率重新随机初始化粒子,使粒子后期能够跳出潜在的局部最优位置,提高算法找到更优解的可能性。此外,动态惯性权重和学习因子线性调整策略的引入进一步增强了算法的全局搜索能力和收敛速度。利用改进粒子群算法 (IPSO, improved particle swarm optimization) 优化 T-S 型自适应模糊神经网络 (T-S ANFIS, T-S adaptive neuro fuzzy inference system) 的故障诊断模型对变压器的稳定运行有重要的现实意义,同时也为其它相关领域提供了新的优化思路。

1 粒子群算法及其改进

1.1 粒子群算法

粒子群算法 (PSO, particle swarm optimization) 基于对鸟群的集体智能行为进行研究,是一种重要的优化方法^[18]。PSO 算法将优化问题抽象为一组粒子在搜索空间中的运动,通过随机赋值位置和速度来初始化种群。在探索空间深处时,粒子依靠经历和周围环境的变化来调整位置和行进速率。粒子通过跟踪个体极值 (P_{best} , particle best) 和全局极值 (G_{best} , global best) 来更新自身状态,从而更好地掌握最优解的位置。该算法具有出色的全局搜索性、高效的收敛性以及简单的实施方式,已经广泛应用于图像处理、机器学习和参数优化等多个领域^[19]。

设一个 D 维搜索空间,由 n 个粒子组成种群 $X = (X_1, X_2, \dots, X_n)$ 。种群中第 i 个粒子位置 $X_i = (X_{i1}, X_{i2}, \dots, X_{id})$,通过目标函数计算每个粒子对应的适应度值。种群中第 i 个粒子速度 $V_i = (V_{i1}, V_{i2}, \dots, V_{id})$,粒子的最优位置为 $P_i = (P_{i1}, P_{i2}, \dots, P_{id})$,整个种群的历史

最优位置为 $G_i = (G_{i1}, G_{i2}, \dots, G_{id})$ 。标准粒子群算法中,粒子速度和位置的更新是关键,其更新公式如下:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (G_{id}^k - X_{id}^k) \quad (1)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (2)$$

式中, $d=1, 2, \dots, D$; $i=1, 2, \dots, n$; V_{id} 为粒子速度; ω 为惯性权重; c_1, c_2 为区间范围 $[0, 2]$ 内的加速度常数; r_1, r_2 为区间范围 $[0, 1]$ 内的随机数。

粒子群算法的性能受粒子行为和参数设置的影响。不当的参数设置可能使粒子速度过快或过慢,导致搜索效果变差。调节参数虽简单,但却对算法性能至关重要。参数包括:种群规模 n , 惯性权重 ω , 加速度常数 c_1 和 c_2 , 最大迭代次数 T 。合理的参数设置可以平衡全局和局部搜索,从而提高算法性能。

1.2 改进粒子群算法

粒子群算法因易于理解和调节参数较少等优点被广泛应用,但该算法也存在一些缺点。在优化过程中,算法响应速度快且有效,但当粒子接近最优点时,粒子的速度会变得很小,导致群体呈现出“趋同性”,使得算法易于陷入局部最优解。此外,个体容易受到全局影响而离开当前搜索区域,从而影响之前的局部搜索结果,降低搜索精度^[20]。此外,由于迭代公式的简单,所以参数的调整对算法的收敛过程有着重要的影响。为了改善基本粒子群算法存在的问题,本文提出一种改进粒子群算法,该算法引入动态惯性权重 ω 和学习因子 c_1, c_2 的线性变化公式,以及后期收敛域和雷同粒子判别,以提高种群的多样性和算法的寻优能力,避免陷入局部最优解。

1.2.1 惯性权重 ω 的动态调整

在标准粒子群算法中,惯性权重 ω 通常为固定值 1,不易于迭代后期的局部收敛。然而,动态调整惯性权重可以避免在搜索初期和搜索后期惯性权重取值单一不当的问题。在探索初期采用较大的惯性权重,强化全局搜索能力,提高算法的收敛速度和搜索范围;在搜索后期逐渐减小惯性权重,强化局部搜索能力。采用动态非线性减小的方法可以更加精准地调节惯性权重,避免算法过早陷入局部最优解,提高算法的收敛精度。惯性权重 ω 的动态改进公式如下:

$$\omega(t) = \begin{cases} \omega_{\min} \times Rand + \frac{F_{\text{avg}} - F_{\min}}{F_i - F_{\min}} \times (\omega_{\max} - \omega_{\min}) \times (1 - K), & F_i \geq F_{\text{avg}} \\ \omega_{\min} + (\omega_{\max} - \omega_{\min}) \times (1 - K), & F_i < F_{\text{avg}} \end{cases} \quad (3)$$

式中, ω_{\max} 为惯性权重的最大值, ω_{\min} 为惯性权重的最小值; F_i 为粒子 i 的适应度值, F_{avg} 为当前所有粒子的平均适应度值, F_{\min} 为当前所有粒子的最小适应度值; $Rand$ 为 $(0, 1)$ 间的随机数, K 为粒子在第 t 次迭代时与粒子总迭代次数 T 的比值: $K=t/T$ 。

1.2.2 学习因子 c_1, c_2 的线性变化

在标准粒子群算法中,固定学习因子 c_1 和 c_2 可能导致

全局搜索和局部搜索能力的平衡存在问题, 使得收敛速度过快或过慢。而随着迭代次数的增加, 线性调整学习因子 c_1 和 c_2 可以较好地解决这一问题。初试迭代阶段, 较大的 c_1 和较小的 c_2 有助于全局搜索和加快搜索速度。随着迭代次数的增加, 较小的 c_1 和较大的 c_2 有利于避免陷入局部极值点。学习因子 c_1 、 c_2 的线性改进公式为:

$$c_1 = 1 + \cos\left(\frac{\pi}{2} \cdot K\right) \quad (4)$$

$$c_2 = 1 + \sin\left(\frac{\pi}{2} \cdot K\right) \quad (5)$$

式中, c_1 为自我学习因子, c_2 为群体学习因子; K 为粒子在第 t 次迭代时与粒子总迭代次数 T 的比值: $K=t/T$ 。

1.2.3 收敛域及雷同粒子判别

为了保证粒子种群的丰富性, 并防止在后期出现局部优化, 将粒子的个体最优位置与种群的全局最优位置进行比较, 当满足式 (5) 时即判定部分粒子进入全局最优的收敛域; 此时, 未进入收敛域内且适应度函数值处于种群前 5% 的粒子的参数取种群后 20% 粒子参数的平均值。在收敛域内, 若其他粒子与最优粒子间的欧式距离小于 1 则被认定为雷同粒子, 赋予雷同粒子随机参数跳出收敛域, 以保证种群的多样性和后期跳出局部最优。

$$\frac{\|G_{best} - P_{best}\|}{\|G_{best}\|} \leq 0.1 \quad (6)$$

式中, G_{best} 为种群的全局最优位置, P_{best} 为粒子的个体最优位置。

2 T-S 型自适应模糊神经网络

T-S 型自适应模糊神经网络是一种将 T-S 模糊推理系统和神经网络结合的自适应推理网络。该网络能够将输入空间划分成多个模糊子集, 并对每个子集进行建模, 最终得到一个整体的模糊推理结果^[21-22]。其学习算法包括前向传播和反向传播两个部分, 通过调整样本量和网络参数, 可以实现前向传播并获取准确的输出结果。在 T-S 型自适应模糊神经网络中, 每个隶属度函数都由若干个参数决定, 这些参数需要通过学习来确定。采用梯度下降法虽然可以有效地减小误差函数, 但由于它不具有凸性, 因此很容易导致局部最优解的出现^[23-24]。为了解决这一挑战, 研究人员提出了许多相关的解决方案, 例如采用粒子群算法以达到更好的结果。

T-S 型自适应模糊神经网络是一种集成了传统神经网络优势的改良型结构, 分为前件网络和后件网络两部分, 结构如图 1 所示。

系统的前件网络由四层架构组成, 包括输入层、模糊层、规则层以及去模糊层, 这些层的结合使前件网络能够有效地运行。

第一层为输入层, 用于处理输入向量 $\mathbf{X} = (X_1, X_2, \dots, X_n)$, 并将其传递到下一层。本文系统的输入层的节点个数为 5, 分别对应油浸式变压器内部五种气体含量: 氢气、甲烷、乙烷、乙烯和乙炔。

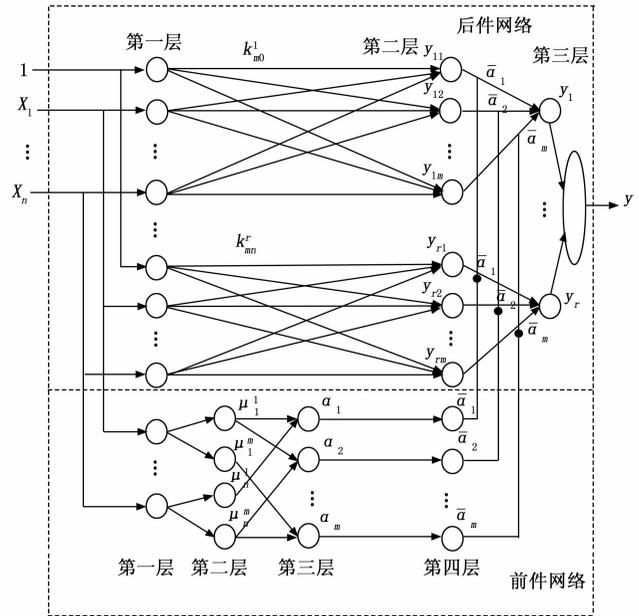


图 1 T-S 型自适应模糊神经网络结构

第二层为模糊层, 用于对输入数据进行模糊化, 并计算不同输入分量属于各语言变量值模糊集合的隶属度 μ^m 。根据实验需求和仿真经验, 采用高斯函数作为隶属度函数, 通过改进粒子群算法对高斯函数中的参数 c_{mm} 和 b_{mm} 进行优化。根据油浸式变压器故障分类需求, 将模糊分割数设定为 7, 则本层对应的节点数量为 35。

$$\mu^m = \exp[-(X_n - c_{mm})^2 / b_{mm}^2] \quad (7)$$

式中, μ^m 表示 X_n 在第 m 个语言变量的隶属度, $m=1, 2, \dots, 7$; $n=1, 2, \dots, 5$; c_{mm} 和 b_{mm} 分别表示高斯函数的中心和宽度。

第三层为规则层, 将各节点的隶属度进行模糊计算, 并采用加权法求得每个规则的适应度。在模糊网络中, 只有在靠近输入点的语言变量值才具有较高的隶属度值, 因此只有少数节点会产生较高的输出值, 这点类似于局部逼近网络。

第四层为去模糊化层, 用于求得各个节点的输出 $\bar{\alpha}_m$ 。

$$\bar{\alpha}_m = \alpha_m / \sum_{m=1}^7 \alpha_m \quad (8)$$

系统的后件网络由 r 个具有相同结构的子网络构成, 网络间通过交互作用实现数据传输。

子网络的第一层为输入层, 其中第 0 个节点 X_0 的输入值为 1, 用于在模糊规则后件中提供常数项。

子网络的第二层共有 m 个结点, 每个节点代表一条规则, 该层的作用是计算每一条规则的后件, 规则推理结果由 y_m 来表示:

$$y_m = k_{m0}^r + k_{m1}^r X_1 + \dots + k_{mm}^r X_n \quad (9)$$

式中, $X_0=1$; k_{mr}^r 表示网络的权重系数, $r=1, 2, \dots, 7$ 。

子网络第三层为输出层, y_r 是各规则后件的加权和,

前件网络的输出 $\bar{\alpha}_m$ 用作后件网络的加权系数。

$$y_r = \sum_{m=1}^7 \bar{\alpha}_m y_{rm} \quad (10)$$

比较推理结果中的最大值作为整个系统的输出，即为油浸式变压器故障类型对应编号。

3 基于 IPSO 优化 T-S ANFIS 的变压器故障诊断模型

3.1 基于 IPSO 优化 T-S ANFIS 的网络训练过程

在 T-S ANFIS 网络中，改进粒子群算法被应用于网络的参数优化。通过初始化种群粒子的参数集，并设定粒子的位置和速度，以及规定种群规模和迭代次数等参数，粒子群适应度值可以被计算出来。通过比较当前位置和历史最佳位置的适应度值，可以找到全局最佳位置。最后，利用改进方法更新粒子群的位置和速度，循环迭代至满足算法的终止条件。改进算法可以有效地提高 ANFIS 网络的训练效率，以便更好地对变压器进行故障诊断。基于 IPSO 优化 T-S ANFIS 网络的算法流程如图 2 所示，网络训练的具体过程步骤如下。

步骤 1：粒子群初始化。将 ANFIS 网络中高斯函数的参数 c_{mm} 、 b_{mm} 和权重系数 k'_{mm} 作为种群粒子的参数集，初始化种群粒子的位置 X_{id}^k 和速度 V_{id}^k ；确定种群规模及迭代次数，设定惯性权重动态调整公式，学习因子 c_1 和 c_2 的线性变化公式以及雷同粒子和收敛域判定公式。

步骤 2：粒子适应度值计算。将 ANFIS 网络不正确分类的样本数作改进为粒子群的适应度函数，计算初始化粒子的适应度值，从中寻找个体极值 P_{best} 和 G_{best} 群体极值。

步骤 3：粒子评价。对于每个粒子，比较其当前位置的适应度值和其历史最佳位置的适应度值，如果当前位置更优，则更新其历史最佳位置。将所有粒子的历史最佳位置进行比较，找到适应度函数值最小的位置，并将其设为全局最佳位置。

步骤 4：粒子群位置和速度更新。利用式 (1) 和式 (2) 为每个粒子计算新的位置 X_{id}^{k+1} 和速度 V_{id}^{k+1} 。其中，利用惯性权重动态调整公式 (3) 和学习因子线性变化公式 (4)、公式 (5) 对速度进行更新，并引入收敛域和欧式距离判别雷同粒子以一定的概率重新随机初始化粒子，避免种群后期陷入局部最优。

步骤 5：终止条件判断。当达到预设的最大迭代次数或最小误差要求时，停止迭代，输出最优解作为网络模型的前提参数，否则跳转到步骤 2。

步骤 6：将粒子群优化的前提参数代入 T-S ANFIS 进行模型训练。训练完成后，输入测试样本对模型的故障诊断准确度及速度进行实验。

3.2 数据预处理

通过数据预处理，可以有效地剔除不必要的信息，并且通过优化来提高原始数据的准确性。通过这种方式，可以消除外部因素和测量过程中的不确定性，从而提升数据的准确性和可靠性。本系统选取油浸式变压器中的 5 种主

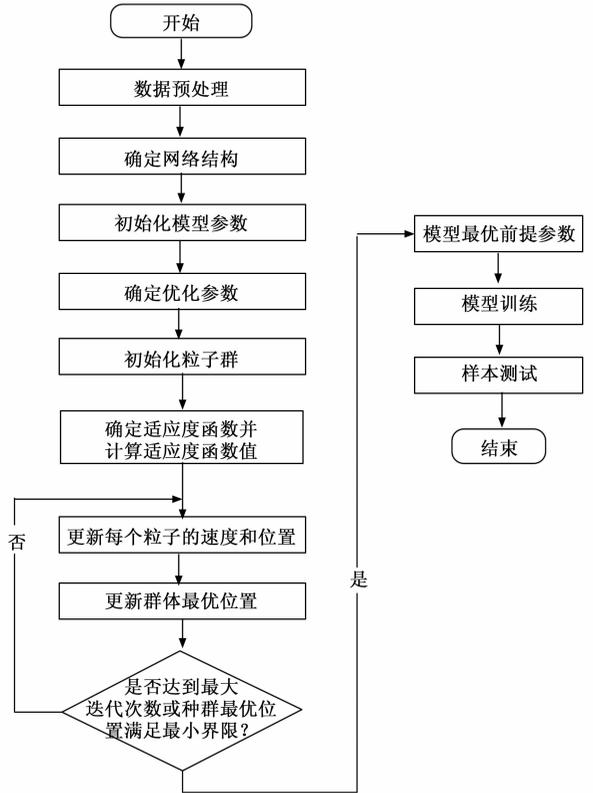


图 2 基于 IPSO 优化 T-S ANFIS 网络的算法流程图

要特征气体：氢气、甲烷、乙烷、乙烯和乙炔作为实验数据，并利用式 (11) 对特征气体数据进行归一化处理，以此来提取出有助于变压器故障诊断的有效参数。选取 7 组典型的油浸式变压器故障测试样本气体归一化体积分数数据见表 1。

$$X_n = Q_n / \sum_{n=1}^5 Q_n \quad (11)$$

式中， X_n 表示归一化后的变压器故障气体含量， $n=1, 2, \dots, 5$ ； Q_n 表示变压器故障的特征气体原始含量， Q_1 到 Q_5 依次表示特征气体中的氢气、甲烷、乙烷、乙烯和乙炔。

表 1 故障特征气体归一化体积分数

编号	氢气	甲烷	乙烷	乙烯	乙炔	诊断类型
1	0.461	0.116	0.331	0.085	0.006	正常
2	0.580	0.189	0.046	0.087	0.099	低能放电
3	0.569	0.105	0.013	0.136	0.177	高能放电
4	0.081	0.349	0.357	0.208	0.005	低温过热
5	0.113	0.218	0.113	0.531	0.025	高温过热
6	0.403	0.251	0.161	0.186	0	中温过热
7	0.159	0.300	0.049	0.487	0.003	中低温过热

3.3 模型评价标准

基于上述实现方式，归一化的数据输入粒子群优化后的模糊神经网络进行故障诊断，输出诊断的变压器故障类型，并对模型诊断结果进行评估。本文选取平均绝对误差 (MAE) 作为算法优化诊断模型的评价指标，误差表达

式为:

$$MAE = \frac{1}{n} \sum_{k=1}^n |E_k - R_k| \quad (12)$$

式中, E_k 和 R_k 分别表示故障诊断类型编号和实际诊断类型编号; 若 E_k 与 R_k 的编号值一致, 则两者差值记为 0, 否则记为 1; n 表示测试样本的数量。

4 仿真实验分析

本文使用 IPSO 优化构建 T-S ANFIS 神经网络模型, 选取了油浸式变压器中油色谱数据 5 种主要特征气体: 氢气、甲烷、乙烷、乙烯、乙炔。气体数据经过归一化处理, 作为神经网络的特征输入量。神经网络的特征输出为 7 种变压器诊断类型, 分别为: 正常 (输出 1)、低能放电 (输出 2)、高能放电 (输出 3)、低温过热 (输出 4)、高温过热 (输出 5)、中温过热 (输出 6) 和中低温过热 (输出 7)。

从变压器研究资料中收集 500 组油色谱数据, 其中正常 52 组, 占 10.4%; 低能放电 82 组, 占 16.3%; 高能放电 134 组, 占 26.9%; 低温过热 17 组, 占 3.4%; 高温过热 153 组, 占 30.7%; 中温过热 13 组, 占 2.5%; 中低温过热 49 组, 占 9.8%; 按比例选取 400 组作为训练样本, 100 组作为测试样本。实验中粒子群规模设置为 50, 最大迭代次数设置为 500; 惯性权重按公式 (3) 动态调整, 其中惯性权重的最大值和最小值分别设置为 0.9 和 0.1; 学习因子 c_1 、 c_2 按式 (4)、式 (5) 线性变化, 并引入收敛域和欧式距离判别雷同粒子以一定的概率重新随机初始化粒子, 使用 Matlab 进行仿真测试。当达到最大迭代次数 500 次或误差达到预设阈值 0.01 时, 输出全局最优位置作为对应的 T-S ANFIS 网络的前提参数。

在输入、输出相同的情况下, 对改进粒子群算法的策略进行消融实验。对惯性权重动态调整公式、学习因子线性调整公式以及算法引入的收敛域和欧式距离判别雷同粒子进行改进算法的控制变量实验, 控制粒子群改进策略优化 ANFIS 进行故障诊断的结果对比如表 2 所示。在测试条件相同的情况下, IPSO 算法优化的故障样本诊断最优率约为 98%, 高于标准 ANFIS 网络和标准 PSO 优化的 ANFIS 网络, 具体故障样本诊断结果如表 3 所示; 基于 IPSO 优化 T-S 型 ANFIS 网络、标准 PSO 优化 T-S 型 ANFIS 网络、标准 T-S 型 ANFIS 网络对 100 组测试样本的故障诊断最优结果对比如表 4 所示; 三种方法的仿真耗时如图 3 所示, 最优故障诊断分类分别如图 4~6 所示。

表 2 改进粒子群策略消融实验结果对比

模型	迭代次数	最优迭代次数	平均绝对误差/%	最优耗时/s
IPSO 优化模型	500	97	2.0	81
去除惯性权重优化模型	500	236	3.5	104
去除学习因子优化模型	500	214	3.4	116
去除雷同粒子优化模型	500	162	3.7	93

表 3 IPSO 优化算法训练故障样本诊断最优结果

诊断类型	正确数/样本数	正确率/%
正常	10/10	100
低能放电	16/16	100
高能放电	26/27	96.3
低温过热	4/4	100
高温过热	30/31	96.8
中温过热	3/3	100
中低温过热	9/9	100

表 4 IPSO-ANFIS、PSO-ANFIS、ANFIS 故障诊断最优结果对比

模型	迭代次数	最优迭代次数	平均绝对误差/%	最优耗时/s
IPSO-ANFIS	500	97	2.0	81
PSO-ANFIS	500	316	4.1	127
ANFIS	500	402	9.3	114

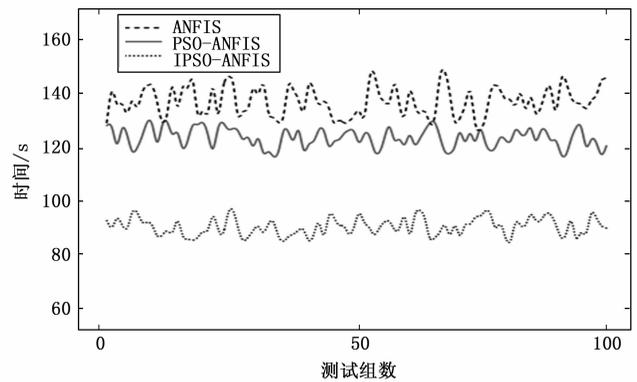


图 3 网络仿真耗时对比图

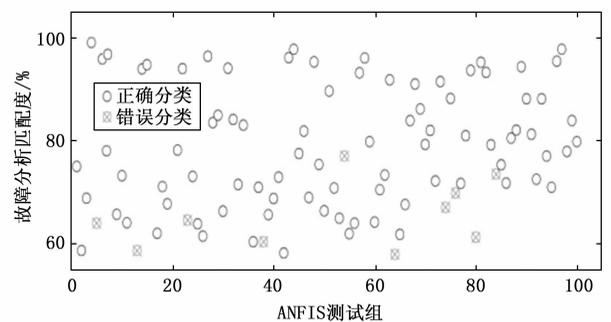


图 4 ANFIS 最优故障诊断分类图

综合以上仿真结果, 可作如下分析:

1) 根据表 2 的数据可知, IPSO 算法引入收敛域和欧式距离判别雷同粒子, 对雷同粒子赋予随机参数, 使粒子后期跳出可局部最优位置, 增强了种群的多样性, 降低了故障诊断的误差率, 同时提高算法找到更优解的可能性。为了提高算法的收敛性和精度, 迭代过程中对惯性权重进行动态调整, 并令学习因子进行线性变化, 这样粒子在迭代

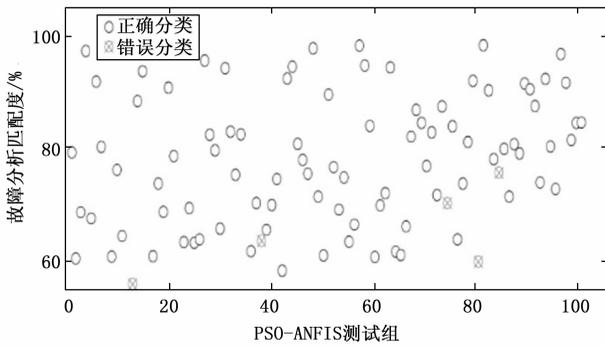


图 5 PSO-ANFIS 最优故障诊断分类图

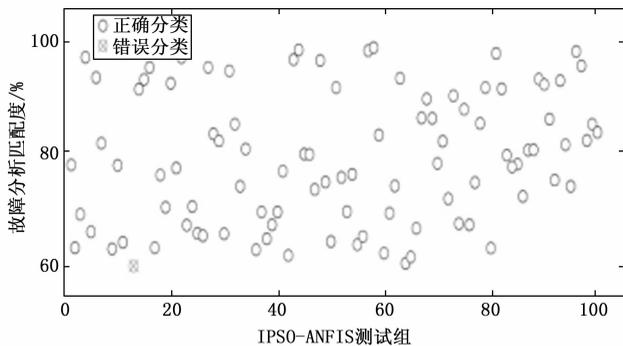


图 6 IPSO-ANFIS 最优故障诊断分类图

初期能进行较好的全局搜索，而到迭代后期则能更加精确的进行局部搜索。对惯性权重和学习因子的公式改进，减少了模型诊断的耗时，提高了算法的搜索能力。

2) 根据表 3 和表 4 的数据可知，在优化 ANFIS 网络的前提参数时，需要结合理论依据和人工经验，经过反复测试，才能找出合适的参数值。标准 PSO 算法虽然在一定程度上解决了最优前提参数匹配的问题，但其存在迭代效率低和易于陷入局部最优的缺点。而 IPSO 优化网络参数训练故障样本诊断的最优正确率约为 98%，优化网络的耗时较短，诊断的故障分析匹配度高于另外两种标准网络。

3) IPSO 算法在最优故障诊断分类的识别效果明显优于标准 PSO，所以在油浸式变压器故障诊断方面，基于 IPSO 优化 T-S 型 ANFIS 网络诊断故障样本具有较好地运行效率与精度。

5 结束语

本文提出了一种改进的粒子群算法，它能够有效地解决自适应模糊神经网络参数寻优能力较弱、收敛速度较慢以及粒子群后期容易陷入局部最优等问题，该算法结合了动态惯性权重和学习因子线性调整策略，并引入收敛域和欧式距离判别雷同粒子，以增加种群的多样性，让粒子群可以更快地跳出局部最优，从而较好地提高了算法的全局搜索能力与收敛速度。采取参数调整，可以有效避免陷入局部最优，提高了变压器故障诊断的精度及效率，对变压器及电力系统的安全稳定运行有重要的现实意义，同时也

为其它相关领域提供了一种新的优化方法和思路。因此，IPSO 算法在 ANFIS 网络参数优化方面具有明显优势，特别是在故障样本诊断方面的应用效果非常显著。然而，要注意 IPSO 算法中的参数设置问题和不同问题领域中的适用性问题。未来研究可以探索更先进的优化算法，进一步提高网络的诊断准确性和鲁棒性。

参考文献:

- [1] 谭祖雁. 电力变压器在线状态监测技术研究 [J]. 大众用电, 2022, 37 (3): 37-39.
- [2] 曹淑睿, 李 目, 耿召里. 油浸式变压器故障诊断方法研究 [J]. 现代制造技术与装备, 2022, 58 (9): 29-31.
- [3] 范晓丹, 付炜平, 赵智龙, 等. 基于长短时记忆网络油浸式变压器故障诊断研究 [J]. 变压器, 2021, 58 (9): 27-32.
- [4] 白忠雄, 张启龙. 油浸式变压器故障类型与故障诊断技术研究 [J]. 电子制作, 2021 (12): 19-22.
- [5] 刘长宏. 油浸式变压器的运行检查维护及其故障处理 [J]. 中国盐业, 2021 (2): 50-53.
- [6] 张歆扬. 基于油色谱分析的变压器内部故障诊断探讨 [J]. 电工技术, 2020 (5): 123-125.
- [7] 刘 畅, 吴艳娟, 高雅琦. 基于 BP 神经网络及蜂群算法的变压器故障诊断 [J]. 新型工业化, 2020, 10 (4): 7-12.
- [8] 杨春玲, 王晓波, 郑安豫, 等. 优化 LS-SVM 在油浸式变压器故障诊断中的应用 [J]. 长春师范大学学报, 2020, 39 (4): 71-74.
- [9] YAN C, LI M, LIU W. Transformer fault diagnosis based on BP-Adaboost and PNN series connection [J]. Mathematical Problems in Engineering, 2019: 1019845-1019855.
- [10] JIANG J, CHEN R, ZHANG C, et al. Dynamic fault prediction of power transformers based on lasso regression and change point detection by dissolved gas analysis [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2020, 27 (6): 2130-2137.
- [11] FAUZI N A, ALI N H N, KER P J, et al. Fault prediction for power transformer using optical spectrum of transformer oil and data mining analysis [J]. IEEE Access, 2020, 8: 136374-136381.
- [12] ZHOU Y, TAO L, YANG X, et al. Novel probabilistic neural network models combined with dissolved gas analysis for fault diagnosis of oil-immersed power transformers [J]. ACS Omega, 2021, 6 (28): 18084-18098.
- [13] ZHANG M, CHEN W, ZHANG Y, et al. Fault diagnosis of oil-immersed power transformer based on difference-mutation brain storm optimized catboost model [J]. IEEE Access, 2021, 9: 168767-168782.
- [14] KIRKBAS A, DEMIRCALI A, KORUGLU S, et al. Fault diagnosis of oil-immersed power transformers using common vector approach [J]. Electric Power Systems Research, 2020, 184: 106346.
- [15] 边 莉, 刘程杨, 何 辉, 等. 天牛须算法在油浸式变压器

- 故障诊断中的应用 [J]. 计算机应用研究, 2020, 37 (S1): 155-156.
- [16] 易灵芝, 龙 娇, 王雅慧, 等. 基于改进天鹰算法优化核极限学习机的油浸式变压器故障诊断研究 [J]. 湖南电力, 2022, 42 (6): 7-14.
- [17] 仝兆景, 乔征瑞, 李金香, 等. 基于 MPC 算法优化的贝叶斯网络变压器故障诊断 [J]. 电子测量技术, 2021, 44 (17): 41-45.
- [18] PERVAIZ S, BANGYAL W H, ASHRAF A, et al. Comparative research directions of population initialization techniques using PSO algorithm [J]. Intelligent Automation & Soft Computing, 2022, 32 (3): 1427-1444.
- [19] MENG Z, ZHONG Y, MAO G, et al. PSO-sono: A novel PSO variant for single-objective numerical optimization [J]. Information Sciences, 2022, 586: 176-191.
- [20] 杨 燃, 张 艳. 改进粒子群算法的配电网多目标无功优化 [J]. 安徽工程大学学报, 2022, 37 (6): 42-50.
- [21] 侯国安, 田舟祺, 何国辉. 基于模糊神经网络的旋转机械振动故障诊断研究与应用 [J]. 化学工程与装备, 2022 (5): 15-17.
- [22] 董巧玲. 基于改进神经网络的抽油机故障智能诊断研究 [J]. 西安石油大学学报 (自然科学版), 2022, 37 (6): 124-132.
- [23] 游 溢, 赵普志, 刘 冬, 等. 基于优化模糊推理系统的电力变压器故障检测方法 [J]. 济南大学学报 (自然科学版), 2023, 37 (1): 71-76, 83.
- [24] 金爱娟, 邵飞旋, 严紫光. 基于自适应模糊神经网络的感应电机矢量控制 [J]. 电子科技, 2022, 35 (9): 65-73.
- ***
- (上接第 5 页)
- [14] MOORTHY P, BHARATHY S S. An efficient test pattern generator for high fault coverage in built-in-self-test applications [C] //International Conference on Computing, IEEE Computer Society, 2013: 1-4.
- [15] 王大为, 邵志江, 张 健, 等. 一种基于改进 SA-DPSO 的装备测试性优化设计方法 [J]. 空天防御, 2023, 6 (1): 45-48.
- [16] 曲东才, 周胜明, 卢建华. 机内自检和综合诊断技术及其在现代军用飞机上的应用 [J]. 国外电子测量技术, 2000 (2): 17-19.
- [17] 谢永成, 董今朝, 李光升, 等. 机内测试技术综述 [J]. 计算机测量与控制, 2013, 21 (3): 880-885.
- [18] 王 勇. 机内测试技术的发展与应用 [J]. 飞航导弹, 2011 (2): 24-27.
- [19] 温熙森, 徐永成, 易晓山. 智能机内测试理论与应用 [M]. 北京: 国防工业出版社, 2002.
- [20] 田 仲, 石君友. 系统测试性设计分析与验证 [M]. 北京: 航空航天大学出版社, 2003.
- [21] NEWMAN W T, EMMERT G. Common BIT test station agile development approach [C] // IEEE Autotestcon, IEEE, 2015.
- [22] MAURICE S, WIENS R C, BERNARDI P, et al. The supercam instrument suite on the mars 2020 rover: science objectives and mast-unit description [J]. Space Science Reviews, 2021, 217 (3): 1-108.
- [23] STEINMETZ M J. Built-in-test instrumentation and 21 rules of thumb [J]. Instrumentation & Measurement Magazine IEEE, 2002, 5 (3): 30-38.
- [24] 蒋超利, 吴旭升, 高 崑, 等. 机内测试技术与虚警抑制策略研究综述 [J]. 计算机测量与控制, 2018, 26 (11): 1-6, 29.
- [25] MUTHAMMAL R, JOSEPH K O. Low power efficient built in self test [C] //IEEE International Conference on Microwaves, IEEE, 2011.
- [26] BUBNA M, ROY K, GOEL A. HBIST: An approach towards zero external test cost [C] //Vlsi Test Symposium, IEEE, 2012.
- [27] AGRAWAL M, CHAKRABARTY K, EKLOW B. A distributed, reconfigurable, and reusable BIST infrastructure for 3D-stacked ICs [C] //2014 IEEE International Test Conference (ITC), Seattle, Washington USA. : Institute of Electrical and Electronics Engineers, 2014: 1-10.
- [28] 赵志傲. 系统级 BIT 防虚警技术研究 [D]. 长沙: 国防科学技术大学, 2012.
- [29] 杨 光. 机电产品 BIT 系统传感层虚警抑制的理论与技术研究 [D]. 长沙: 国防科学技术大学, 2003.
- [30] 王新峰. 机电系统 BIT 特征层虚警抑制技术研究 [D]. 长沙: 国防科学技术大学, 2005.
- [31] 邱 静, 刘冠军, 吕克洪. 机电系统机内测试虚警抑制技术 [M]. 北京: 科学出版社, 2009.
- [32] DREES R, YOUNG N. Role of BIT in support system maintenance and availability [J]. Aerospace & Electronic Systems Magazine IEEE, 2004, 19 (8): 3-7.
- [33] VAN CLEVE D P, MONK W R. Missile test method for testing the operability of a missile from a launch site [P]. US: US5721680 A, 1998.
- [34] MA X F, HUANG W H, ZHANG J Z. Built-in test system for submarine-launched missile model [C] // First International Conference on Pervasive Computing, Signal Processing and Applications, 2010.
- [35] 刘仁浩, 李 然. 战术导弹控制系统 BIT 设计方法 [J]. 计算机测量与控制, 2022, 30 (1): 135-140.
- [36] 边 维, 邓 凯. 面向弹载计算机的 BIT 技术研究 [J]. 计算机工程与应用, 2018, 54 (17): 231-237.
- [37] 杨 漫, 张明远. 机载嵌入式计算机通用化 BIT 架构设计技术 [J]. 航空电子技术, 2021, 52 (1): 32-35.
- [38] 权 赫, 张 鹏. 运载火箭电气系统 BIT 设计流程及方法研究 [J]. 电子测量技术, 2016, 39 (1): 61-64.
- [39] 廖 欣, 朱建华, 卞付国, 等. 利用“三再”方法提升导弹武器装备可靠性的研究与实践 [J]. 空天防御, 2023, 6 (1): 11-16.