

# 基于邻域粗糙集与 AMPOS-ELM 的 变压器 DGA 故障诊断

周 秀<sup>1</sup>, 怡 恺<sup>2</sup>, 李 刚<sup>2</sup>, 田 天<sup>1</sup>, 杨 鑫<sup>3</sup>

(1. 国网宁夏电力有限公司电力科学研究院, 宁夏 银川 750002; 2. 宁夏电力能源科技有限公司, 宁夏 银川 750002;  
3. 长沙理工大学电气与信息工程学院, 湖南 长沙 410114)

**摘 要:**基于 DGA 数据的智能变压器故障诊断方法准确率易受输入特征影响以及极限学习机参数选择困难的问题, 提出基于邻域粗糙集与自适应变异粒子群极限学习机算法的变压器故障诊断方法。首先, 结合各 DGA 故障诊断标准建立变压器故障初始特征集, 采用邻域粗糙集分析后获得属性重要度高的关键特征指标; 其次, 针对粒子群算法优化极限学习机参数时容易早熟、陷入局部最优的缺陷, 提出带有早熟自检变异机制的改进粒子群算法优化极限学习机; 最后, 通过变压器 DGA 数据实例诊断, 将之与 IEC 三比值法以及不同组合的极限学习机诊断性能进行比较, 表明所提方法诊断精度更高。

**关 键 词:**变压器故障诊断; 邻域粗糙集; 改进粒子群算法; 极限学习机

DOI:10.19781/j.issn.1673-9140.2022.03.019 中图分类号:TM863 文章编号:1673-9140(2022)03-0157-08

## A transformer DGA fault diagnosis approach based on neighborhood rough set and AMPPO-ELM

ZHOU Xiu<sup>1</sup>, YI Kai<sup>2</sup>, LI Gang<sup>2</sup>, TIAN Tian<sup>1</sup>, YANG Xin<sup>3</sup>

(1. Electric Power Science Research Institute, State Grid Ningxia Electric Power Co., Ltd., Yinchuan 750002, China;  
2. Ningxia Electric Power Energy Technology Co., Ltd., Yinchuan 750002, China; 3. School of Electrical &  
Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

**Abstract:** The accuracy of the intelligent transformer fault diagnosis method based on the DGA data is easily affected by the input characteristics, and the parameters of the extreme learning machine model is difficult to select. Thus, a transformer fault diagnosis method based on the neighborhood rough set and the adaptive mutation particle swarm extreme learning machine algorithm is proposed. Firstly, the initial feature set of transformer faults is established based on the various DGA fault diagnosis standards, and the key feature indicators with higher importance according to the neighborhood rough set analysis. Secondly, when optimizing the parameters of the extreme learning machine on the basis of the particle swarm algorithm, it is easy to be premature and fall into the local maximum. Hence, an improved particle swarm optimization algorithm with premature self-check mutation mechanism is proposed. Finally, through a

收稿日期:2020-10-13; 修回日期:2020-11-23

基金项目:国网宁夏电力有限公司电力科学研究院创新创效项目(SGNXDK00PJJS2000161)

通信作者:杨 鑫(1983-),男,博士,副教授,主要从事电力设备状态检测和故障识别、低温高压绝缘技术研究;E-mail:yan\_19830713@163.com

case study, the proposed method is compared with the IEC three-ratio method and the different combinations of extreme learning machines, which verifies that the better diagnosis accuracy of the proposed method.

**Key words:** transformer fault diagnosis; neighborhood rough set; improved particle swarm algorithm; extreme learning machine

电力变压器是电力系统中不可或缺的重要设备之一,由于其构造器件众多,结构复杂,一旦发生故障,无法及时查明故障类型,给后续维修造成很大不便。而目前由于 IEC 三比值法<sup>[1]</sup>其设置边界条件比较苛刻,从而易导致漏判、误判等情况的发生,可能造成变压器带故障长期运行,给电力系统的正常运行埋下了潜在风险。因此,需要提出新的故障诊断方法,从而提高诊断的可靠性<sup>[2]</sup>。

目前智能算法在变压器故障诊断领域的研究已经取得了长足的进展<sup>[3]</sup>,主要包括:人工神经网络法(artificial neural network, ANN)<sup>[4]</sup>、支持向量机法(support vector machine, SVM)<sup>[5]</sup>、极限学习机(extreme learning machine, ELM)<sup>[6]</sup>等。然而以上方法也存在一些不足。

1)特征量选取方面。通常以溶解气体体积分数作为智能算法特征输入,在一定程度上提升了判断准确率<sup>[7-8]</sup>。但溶解气体体积分数可能会因故障程度以及故障发生位置等多种因素出现波动,从而影响变压器故障诊断的准确性<sup>[9]</sup>。此外,采用智能分类算法进行建模时,输入特征的选取对分类结果有很大影响。选择的输入特征维数过高,造成引入过多非必要变量,不仅会造成预测准确性降低,还使参与训练的模型过于复杂;选择的输入特征较少时,又难以获得足够的信息表征输出特性<sup>[10]</sup>。

2)算法方面。ANN 有极强的非线性映射能力和容错率,但其收敛速度慢和容易过拟合<sup>[11]</sup>。SVM 有较强的泛化能力,能更好的处理局部极小值,但惩罚因子和核参数的选取限制了 SVM 的分类性能,并且若选取的参数不合适,将会出现诊断结果误差较大等问题。ELM 以其学习速度快、泛化能力优良、分类准确率高等特点,在变压器故障诊断领域运用广泛,但由于 ELM 分类结果受初始随机生成参数的影响,若缺少合适的优化算法对其参数进行优化,易导致损失函数较大、鲁棒性较差<sup>[12]</sup>。目前诊

断效果较好的算法为粒子群算法(particle swarm optimization, PSO),但是仍然存在易陷入局部最优的缺陷<sup>[13]</sup>,所以仍需进一步优化。

本文针对以上问题,采用邻域粗糙集<sup>[14]</sup>进行 DGA 特征量优选以及改进粒子群算法优化 ELM 的变压器故障诊断方法,来弥补目前智能算法诊断结果可靠性不高等问题。本文首先结合 DGA 故障诊断标准建立变压器故障初始特征集,经邻域粗糙集分析后获得属性重要度高的关键属性;然后,针对 PSO 算法容易早熟、陷入局部最优的缺陷,提出带有早熟自检变异机制的自适应粒子群(adaptive mutation particle swarm, AMP SO)算法来优化 ELM 的参数,从而构建 AMP SO-ELM 模型;最后,将邻域粗糙集筛选出的关键特征量作为 AMP SO-ELM 网络模型的输入,进行变压器故障识别。为了验证所提方法的可靠性,本文采用与目前已有的故障诊断方法进行对比分析。

## 1 基于邻域粗糙集的变压器故障特征量优选

在数据挖掘的角度来看,变压器故障诊断本质上为对相应数据集进行学习分类的过程。为了更便利地分析,该分类任务可描述为一个决策系统  $I_S = \langle U, A, V, f \rangle$  的形式。其中,  $U = \{X_1, X_2, \dots, X_g\}$  为变压器故障数据集中所有样本  $X_g (g=1, 2, \dots, G)$  的集合;  $A = \{a_1, a_2, \dots, a_{22}\}$  为样本的 DGA 特征集合,也称作条件属性,其中  $a_n$  对应表 1 中的第  $n$  条特征;  $V$  为代表样本的变压器故障类型,为样本的标签属性;  $f$  为一个信息函数,用来指定样本在相应特征属性下的取值,记样本  $X_g$  在特征  $a$  下的取值为  $f(X_g, a)$ 。

由于变压器故障特征的构建与专家经验相关,因此在构建完初始故障特征集后,通常可以对其作

进一步的压缩或约简,提取关键特征<sup>[15]</sup>。因此,本文对初始变压器故障特征集引入邻域粗糙集来进行筛选,找出变压器故障关键特征指标。

对于变压器故障诊断的分类任务  $I_s = \langle U, A, V, f \rangle$ ,  $A$  为对应的各样本初始特征集合,其中  $U$  为变压器故障样本集合,  $B \subseteq A$ ,  $V$  为对应的变压器故障类型。对于任意的  $X_g \in U$ , 条件属性子集  $B \subseteq A$ , 则定义  $X_g$  的邻域为

$$\delta_B(X_i) = \{X_j | X_j \in U, \Delta_B(X_i, X_j) \leq \delta\} \quad (1)$$

式中  $\delta_B(X_i)$  为  $B$  产生的邻域信息粒;  $\delta$  为邻域半径;  $\Delta_B(X_i, X_j)$  为样本  $X_i$  和样本  $X_j$  在  $B$  下的相似度,其值越大则表示在特征空间  $B$  下  $X_i$  和  $X_j$  这 2 个样本的相似性越低,式(1)表示在特征集合  $B$  下,所有和样本  $X_i$  具有相似特征值的样本集合。

进一步,给定一邻域决策系统  $N_{DT} = \langle U, A \cup U, N, f \rangle$ ,  $\forall B \subseteq A \forall B \subseteq A, V$  将  $U$  划分为  $N$  个等价子集  $(Y_1, Y_2, \dots, Y_N)$ , 则定义  $D$  关于  $B$  的下近似为

$$\underline{N}_B V = \bigcup_{j=1}^N \underline{N}_B Y_j \quad (2)$$

其中,  $\underline{N}_B X_j = \{X_i | \delta_B(X_i) \subseteq Y_j, X_i \in U\}$ 。

则决策属性  $V$  关于  $B$  的下近似可记为  $P_{OS-B}(V)$ , 也称作决策正域。各类在给定的属性集合中的可分离程度决定了决策正域的数值大小。即正域越大,正域内的样本越多,说明故障特征集合  $B$  的可分性越好<sup>[16]</sup>。因此可以将  $V$  对  $B$  的依赖度定义为

$$\gamma_B(V) = \frac{|P_{OS-B}(V)|}{|U|} \quad (3)$$

如果条件属性  $a \in B$ ,  $a$  对决策属性  $V$  的重要度为

$$\text{sig}(a, B, V) = \gamma_B(V) - \gamma_{B-\{a\}}(V) \quad (4)$$

## 2 基于 AMPSO 算法的 ELM 参数优化法

### 2.1 标准 PSO 算法

标准 PSO 算法是源于模拟鸟群觅食行为的启发式优化算法,其核心公式为速度和空间位置的更

新公式<sup>[17]</sup>,分别为

$$v_{ij}^{k+1} = \omega v_{ij}^k + c_1 r_1 (p_{best-ij}^k - x_{ij}^k) + c_2 r_2 (g_{best-ij}^k - x_{ij}^k) \quad (5)$$

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} \quad (6)$$

式(5)、(6)中  $k$  为迭代次数;  $\omega$  为惯性权重;  $c_1$ 、 $c_2$  为粒子学习因子;  $r_1, r_2 \in \text{rand}[0, 1]$ ;  $v_{ij}^k$ 、 $x_{ij}^k$ 、 $p_{best-ij}^k$ 、 $g_{best-ij}^k$  分别为第  $k$  次迭代时超参数  $i$  的第  $j$  维变量的速度、位置、个体最优位置和全局最优位置。

### 2.2 AMPSO 算法

#### 2.2.1 粒子位置加权策略

针对传统 PSO 算法只考虑最佳位置的局限性,本文将每个粒子的最佳位置  $P_{best-i}$  都赋予相应的权重系数,权重系数大则各粒子重要性越高,全局最佳位置  $g_{best}$  就可以用各个粒子与其权重的乘积之和来不断修正。

定义  $\alpha_i$  为粒子  $i$  的权重系数,其中  $i = 1, 2, \dots, M$ ,  $M$  为种群规模,则有全局最佳位置为

$$\begin{cases} g_{best} = \sum_{i=1}^M \alpha_i p_{best-i} \\ \alpha_i = \frac{p_{best-i}}{\sum_{i=1}^M p_{best-i}} \end{cases} \quad (7)$$

对整个粒子群中的粒子依据其适应度的大小赋予不同的权重值,权重越大则表示其对整个粒子群的影响更大。此外,权重系数的引入,使得每一个粒子都得以兼顾,对提高算法的全局寻优能力具有一定的作用。

#### 2.2.2 早熟自检变异机制

PSO 算法虽然简单易用但在优化过程中,粒子趋向于去找已处于最优位置的粒子,因而容易出现粒子高度聚集现象,致使种群多样性降低,算法早熟而陷入局部最优。为解决这问题,本文采用“早熟”自检变异准则。该准则主要是通过计算粒子群的平均适应值偏离度  $\Delta$ , 以此来评估粒子群的离散程度。设  $f_i$  为粒子  $i$  的适应度,  $f_{avg}$  为当前群体的平均适应度,  $\Delta$  可以定义为

$$\Delta = \sqrt{\frac{1}{M} \sum_{i=1}^M (f_i - f_{avg})^2} \quad (8)$$

由式(8)可知,本文将平均适应值偏离度  $\Delta$  定义为粒子当前适应度与平均适应度之间的标准差。 $\Delta$  可以反映种群中粒子聚集程度,其值随迭代次数的增加而越来越小,当  $\Delta$  小于某一个给定的阈值时,认为粒子较密集的存在一个区域,可判断此时算法陷入“早熟”。

本文提供一种“早熟”自检变异策略,当检测到算法早熟时,使粒子在变异半径内随机开始变异操作,来提高种群的多样性,让种群继续搜索解空间的其他区域,增加搜索到全局最优解的概率。在式(6)的基础上引入逃逸策略后,粒子位移公式为

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} + z^k(2r - 1) \quad (9)$$

式中  $r \in [0, 1]$  上的均匀随机数;  $z^k$  为逃逸控制因子,算法未检测到早熟时为 0,检测到早熟时代表粒子变异的半径,即

$$z^k = \begin{cases} R \frac{k_{\max} - k}{k_{\max}}, & k \geq k_{\Delta p \min} \\ 0, & \text{otherwise} \end{cases} \quad (10)$$

式中  $R$  为半径控制因子,控制粒子变异的半径,本文设为 1;  $k_{\max}$  为算法最大的迭代次数;  $k_{\Delta p \min}$  为  $\Delta$  小于给定阈值时对应的最小迭代次数。

由式(10)可知,算法未早熟时粒子位置按式(6)变化。检测到早熟时,粒子逃逸前期,  $z^k$  为较大值,逃逸半径较大,可以增强算法全局寻优能力,提高粒子多样性。进化后期  $z^k$  为较小值,有利于算法收敛。

### 3 基于邻域粗糙集与 AMPSO-ELM 的变压器故障诊断

基于邻域粗糙集与 AMPSO-ELM 算法的诊断步骤分为 3 步:初始故障特征集构造;筛选关键特征指标;ELM 参数优化及故障诊断。

#### 3.1 初始故障特征集构造

本文采用某电科院提供的共 417 组已确认变压器故障类型样本,根据相关规程诊断结果可划分为 7 种状态:正常状态(N);局部放电(PD);低能放电状态( $D_1$ );高能放电状态( $D_2$ );高温过热状态( $T_3$ );放电兼过热(TD);中低温过热状态( $T_{12}$ )。样本分

布如表 1 所示,共 417 组样本,从中随机选取 317 组作为训练集,剩余 100 组为测试集。

表 1 变压器故障样本

Table 1 Transformer fault samples

N	$D_1$	$D_2$	PD	$T_{12}$	$T_3$	TD
51	108	66	96	21	44	31

目前常用  $CH_4$ 、 $C_2H_2$ 、 $C_2H_4$ 、 $C_2H_6$ 、 $H_2$  的体积分数检测变压器是否发生故障,但利用其对故障状态与性质进行更明确判断时却依旧存在较大程度偏差。而 IEC 三比值法、Duval 三角形法、无编码比值法等一系列比值法则常用于判定具体的故障类型。此外,文献[18]表明与 DGA 全部数据相比,DGA 气体中 2 种气体的相对比值和变压器运行状态联系更紧密。为此,以上述 5 种气体为典型故障特征气体,并参照相关比值法构造故障特征的规则,选取关键气体的相关比率以及气体之间的总体占比作为初始故障特征集,如表 2 所示,其中 CH 为总烃含量。

表 2 初始故障特征集

Table 2 Candidate input features

特征编号	故障特征	特征编号	故障特征
1	$CH_4$	12	$C_2H_4/CH_4$
2	$C_2H_2$	13	$C_2H_4/H_2$
3	$C_2H_4$	14	$C_2H_6/CH_4$
4	$C_2H_6$	15	$C_2H_6/H_2$
5	$H_2$	16	$CH_4/H_2$
6	CH	17	$C_2H_2/CH$
7	$C_2H_2/H_2$	18	$H_2/CH+H_2$
8	$C_2H_2/C_2H_4$	19	$C_2H_4/CH$
9	$C_2H_6/C_2H_2$	20	$CH_4/CH$
10	$C_2H_2/CH_4$	21	$C_2H_6/CH$
11	$C_2H_4/C_2H_6$	22	$CH_4+C_2H_4/CH$

#### 3.2 筛选关键属性特征

本文采用邻域粗糙集进行故障类型与 DGA 数据间映射关系的深层挖掘。算法基本步骤如下。

1)以表 1 为决策属性、表 2 为条件信息,建立决策信息表,确立重要度下限及邻域半径集合。输入决策系统  $N_{DT} = \{U, A \cup V\}$ 、邻域半径  $\delta$  集合、重要度下限,进行各属性重要度对比,为得到更准确输入特征量,设定重要度下限为 0.2。

- 2) 初始化约简集合  $r_{ed} = \phi$ , 样本  $s_{mp} = U$ 。
- 3) 对任意  $a_h \in (A - r_{ed})$  利用式(2)计算正域  $P_{OS, r_{ed}+a_h}^S(V)$ 。
- 4) 选择  $a_h$  使正域  $P_{OS, a_h}$  最大。
- 5) 利用式(4)计算属性重要度  $sig(a_h, r_{ed}, D)$ 。
- 6) 如果  $sig(a_h, r_{ed}, D)$  大于设定的下限值, 则输出约简结果  $r_{ed}$ , 否则记录  $h$  值, 令  $r_{ed} = r_{ed} + a_h$ ,  $S = S - P_{OS, a_h}$  返回步骤 3 并循环上述步骤, 直至输出结果。

### 3.3 ELM 参数优化及故障诊断

本文利用 AMPISO 算法的全局搜索能力选取 ELM 的最优初始输入权值和隐层阈值, 以此来解决 ELM 算法的隐层阈值  $b_i$  和输入权重  $\omega_i$  这 2 个参数随机确定的问题, 训练过程如图 1 所示, 具体步骤如下。

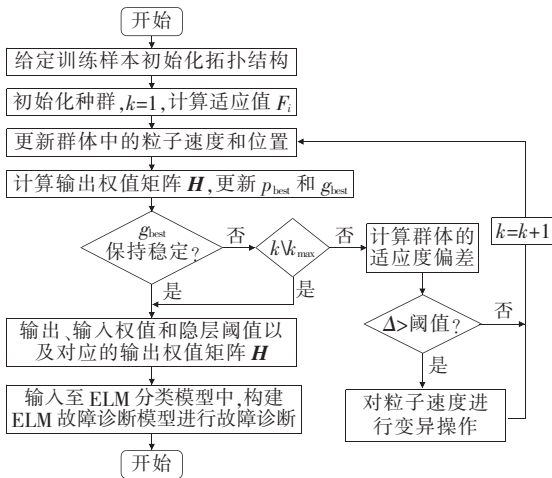


图 1 AMPISO-ELM 算法流程

Figure 1 AMPISO-ELM algorithm flow chart

- 1) 确定 ELM 拓扑结构以及训练样本, 初始化粒子群, 选取合适的  $c_{max}$  与  $c_{min}$ 、 $k_{max}$ 、 $\omega$ 、 $M$ 。
- 2) 设 PSO 算法当前的适应度  $F_i = \sigma$ 。将每个粒子的适应度值与该粒子所经历过的最优位置  $p_{best}$  进行比较, 如果  $F_i < p_{best}$ , 则用  $P_{best}$  代替  $F_i$ , 否则维持现状。
- 3) 比较  $F_i$  与  $g_{best}$  的大小, 如果优于前者, 则将其作为当前的  $g_{best}$  成为最新的全局最佳位置。
- 4) 按式(7)更新粒子权重  $\alpha_i$ , 同时根据式(8)判断粒子群是否早熟, 若早熟则对粒子按式(9)给予逃逸操作, 否则根据式(5)、(6)更新粒子速度和位置。循环上述步骤, 运行次数达到  $k_{max} = 160$  最大迭代

次数或  $g_{best}$  达到稳定时, 退出程序, 并返回当前最优个体及其适应度。

- 5) 输出最优适应度所对应的输入权值和隐层阈值, 计算最优输出权值矩阵  $H$ 。
- 6) 根据最优参数, 建立基于 ELM 的变压器故障诊断模型。
- 7) 将测试样本集输入步骤 6 建立的模型进行变压器故障诊断。

## 4 算例计算与分析

### 4.1 DGA 特征量优选结果分析

利用 317 条训练数据建立决策表, 基于邻域粗糙集算法对其进行属性约简, 获得最终最小故障特征集及相关重要度如表 3 所示。

表 3 关键属性特征集及属性重要度

Table 3 Key attribute feature set and attribute importance

特征编号	故障特征	属性重要度
11	$C_2H_4/C_2H_6$	0.837 9
8	$C_2H_2/C_2H_4$	0.759 4
22	$(CH_4 + C_2H_4)/(CH)$	0.721 6
16	$CH_4/H_2$	0.647 1
18	$H_2/(H_2 + CH)$	0.501 4
9	$C_2H_6/C_2H_2$	0.432 8
3	$C_2H_4$	0.379 1
14	$C_2H_6/CH_4$	0.362 5
5	$H_2$	0.334 5
2	$C_2H_2$	0.327 9

由表 3 可知, 区分变压器是否故障,  $H_2$ 、 $C_2H_2$ 、 $C_2H_4$  依旧为主要的参考特征量, 从 DGA 优选结果来看, 关键特征指标排序的前几个特征包括:  $CH_4/H_2$ 、 $C_2H_4/C_2H_6$ 、 $C_2H_2/C_2H_4$ , 即 IEC 导则推荐的三比值特征量, 与传统诊断特征量的选取基本一致。

将 AMPISO-ELM 的输入特征量分为 4 类, 以此来验证邻域粗糙集 DGA 特征优选对变压器故障诊断准确率提升的有效性。

- 1) 邻域粗糙集筛选出的关键特征指标。
- 2) DGA 全数据包括:  $H_2$ 、 $CH_4$ 、 $C_2H_2$ 、 $C_2H_4$ 、 $C_2H_6$ 。

3) IEC 三比值特征量,由  $CH_4/H_2$ 、 $C_2H_4/C_2H_6$ 、 $C_2H_2/C_2H_4$  3 种气体比值组成。

4)Dornenburg 比值,由  $CH_4/H_2$ 、 $C_2H_2/C_2H_4$ 、 $C_2H_2/CH_4$ 、 $C_2H_6/C_2H_2$  组成。

基于 4 种特征量 AMPSO-ELM 训练样本和测试样本的故障诊断准确率如图 2 所示。




图 2 不同特征量诊断准确率

Figure 2 Diagnosis accuracy of different methods

由图 2 可知 DGA 全数据、三比值特征量与 Dornenburg 比值特征量测试样本故障诊断正确率分别为 62%、69%、73%,Dornenburg 比值、三比值特征量的准确率较接近,但要高于 DGA 全数据的准确率,说明相对于 DGA 全数据,DGA 气体中 2 种气体的相对比值和变压器运行状态联系更紧密,但因特征量个数有限,不利于变压器故障模式差异化特征提取。新 DGA 特征组合的诊断准确率为 89%,相比 DGA 全数据高了 27%,相比三比值特征量高了 20%,说明新 DGA 特征组合能明显提高变压器故障诊断准确率。同时,新 DGA 特征组合的训练样本准确率为 91.3%,测试样本准确率为 89%,两者仅相差 2.3%,这体现新 DGA 特征组合

用于故障诊断时具有较高的稳定性。

### 4.2 不同诊断方法比较

当输入特征为文 4.1 节获得的关键属性特征时,AMPSO-ELM、QPSO-ELM 与 PSO-ELM 参数寻优过程中平均适应度变化曲线(对训练集进行 5 折交叉验证)如图 3 所示,其中 AMPSO 对 ELM 参数优化效果最佳,当迭代次数为 140 次时,适应度高达 0.942。QPSO 在迭代次数为 50 次时,适应度达到最大,跳出局部最优能力略差于 AMPSO。而 PSO 在第 30 次迭代时适应度已达最大值为 0.79,均小于 AMPSO 和 QPSO,此即为标准 PSO 算法的早熟缺陷。综合上述分析可知,对粒子最佳位置引入权重系数以及“早熟”自检变异操作之后的 PSO 算法,能在有限迭代次数内多次跳出局部最优区域,寻优效果最好。

针对相同的样本训练集与测试集,分别采用 IEC 三比值法、ELM 以及不同组合的 ELM 诊断方法进行故障诊断识别,具体结果如表 4 所示。

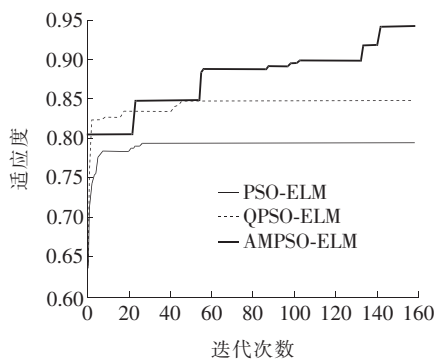


图 3 适应度迭代次数的变化曲线

Figure 3 Curve of fitness variation with iterations

表 4 不同识别方法准确率比较

Table 4 Comparison of accuracy of different recognition methods

故障类型	测试样本数	IEC 三比值		ELM		PSO-ELM		QPSO-ELM		AMPSO-ELM	
		判正台数	正确率/%	判正台数	正确率/%	判正台数	正确率/%	判正台数	正确率/%	判正台数	正确率/%
N	15	8	53.3	7	46.7	10	66.7	12	80.0	15	100.0
D <sub>1</sub>	11	6	72.7	8	72.7	8	72.7	9	81.8	9	81.8
D <sub>2</sub>	18	12	54.5	14	77.8	14	77.8	15	83.3	17	94.4
PD	16	13	81.2	13	81.3	14	87.5	15	93.7	16	100.0
T <sub>12</sub>	9	5	55.6	6	55.6	6	66.7	7	77.8	7	77.8
T <sub>3</sub>	21	14	66.7	15	66.7	15	71.4	16	76.1	17	80.9
TD	10	4	40.0	5	50.0	7	70.0	7	70.0	8	80.0
合计	100	62	62.0	68	68.0	74	74.0	81	81.0	89	89.0

由表 4 可知,当输入特征为关键特征指标组合时,AMPSO-ELM 模型的测试准确率最高为 89%,高于 IEC 三比值法 27%,并且分别高于 QPSO-ELM、PSO-ELM、ELM 方法的 8%、15%、21%。由于 IEC 比值分类边界过于绝对,但所选参数较少又不能准确反映故障类型与表现特征之间的关联关系,导致故障诊断效果相对较差。因此本文提出 AMPSO-ELM 诊断模型具有较高可靠性。

## 5 结语

本文针对基于 DGA 数据的智能变压器故障诊断方法准确率易受输入特征影响以及极限学习机参数选择困难的问题,提出基于邻域粗糙集与自适应变异粒子群极限学习机算法的变压器故障诊断方法,主要结论如下:

1)以邻域粗糙集算法筛选的关键特征指标集作为 AMPSO-ELM 的输入时,故障诊断正确率最高可达到 89%,相比传统智能故障诊断方法 DGA 特征优选步骤可进一步提高故障诊断准确率;

2)通过对比不同模型寻优适应度曲线变化可知,引入早熟自检准则以及对粒子位置加权处理,可进一步提高 PSO 算法的全局寻优能力;

3)所提方法故障识别准确率为 89%,明显高于 IEC 比值法和其他极限学习机的故障诊断准确率,证明基于邻域粗糙集与 AMPSO-ELM 算法的变压器故障诊断方法相比传统的智能诊断方法具有更高的可靠性。

## 参考文献:

- [1] 梁文武,朱维钧,李辉等.基于粗糙集的智能变电站保护设备仿生故障诊断方法[J].电力系统保护与控制,2021,49(21):132-140.  
LIANG Wenwu, ZHU Weijun, LI Hui, et al. A rough set-based bio-inspired fault diagnosis method for smart substation protection equipment[J]. Power System Protection and Control, 2021, 49 (21): 132-140.
- [2] 夏玉剑,李敏,向天堂,等.基于 SOM 的变压器绕组和铁芯故障诊断[J].电力科学与技术学报,2018,33(2):129-134.  
XIA Yujian, LI Min, XIANG Tiantang, et al. Fault diag-

nosis of transformer winding and core based on SOM [J]. Journal of Electric Power Science and Technology, 2018, 33(2): 129-134.

- [3] 党东升,张树永,葛鹏江,等.基于改进量子粒子群优化支持向量机的变压器故障诊断方法[J].电力科学与技术学报,2019,34(3):108-113.  
DANG Dongsheng, ZHANG Shuyong, GE Pengjiang, et al. Transformer fault diagnosis method based on support vector machine optimized by improved quantum-behaved particle swarm optimization[J]. Journal of Electric Power Science and Technology, 2019, 34(3): 108-113.
- [4] YANG F M, LIU C, SUN Y, et al. Fault prediction based on dissolved gas concentration from insulating oil in power transformer using neural network[J]. Applied Mechanics and Materials, 2012, 441: 312-317.
- [5] 黄新波,王亨,田毅,等.基于 PSO-ELM 融合动态加权 AdaBoost 的变压器故障诊断方法[J].高压电器,2020,56(5):39-46.  
HUANG Xinbo, WANG Xiang, TIAN Yi, et al. Transformer fault diagnosis algorithm based on PSO-ELM fusion dynamically weighted adaBoost[J]. High Voltage Apparatus, 2020, 56(5): 39-46.
- [6] MALIK H, MISHRA S. Extreme Learning Machine Based Fault Diagnosis of Power Transformer Using IEC TC10 And Its Related Data[C]//2015 Annual IEEE India Conference (INDICON), New Delhi, India: IEEE, 2015, 1-5.
- [7] 王学磊,李庆民,杨芮,等.基于油色谱分析的变压器复合绝缘缺陷多指标综合权重评估方法[J].高电压技术,2015,41(11):3836-3842.  
WANG Xuelei, LI Qingmin, YANG Rui, et al. Multi-index and comprehensive weighted assessment method for transformer compound insulation defects based on dissolved gases analysis [J]. High Voltage Engineering, 2015, 41(11): 3836-3842.
- [8] 黄新波,李文君子,宋桐,等.采用遗传算法优化装袋分类回归树组合算法的变压器故障诊断[J].高电压技术,2016,42(5):1617-1623.  
HUANG Xinbo, LI Wenjunzi, SONG Tong, et al. Application of bagging-CART algorithm optimized by genetic algorithm in transformer fault diagnosis[J]. High Voltage Engineering, 2016, 42(5): 1617-1623.
- [9] 王雪,韩韬.基于贝叶斯优化随机森林的变压器故障诊

- 断[J]. 电测与仪表, 2021, 58(6):167-173.
- WANG Xue, HAN Tao. Transformer fault diagnosis based on Bayesian optimized random forest[J]. *Electrical Measurement & Instrumentation*, 2021, 58(6):167-173.
- [10] 梁智, 孙国强, 卫志农, 等. 基于变量选择与高斯过程回归的短期负荷预测[J]. 电力建设, 2017, 38(2):122-128.
- LIANG Zhi, SUN Guoqiang, WEI Zhinong, et al. Short-term load forecasting based on variable selection and gaussian process regression[J]. *Electric Power Construction*, 2017, 38(2):122-128.
- [11] 陈小青, 刘觉民, 黄英伟, 等. 采用改进人工鱼群优化粗糙集算法的变压器故障诊断[J]. 高电压技术, 2012, 38(6):1403-1409.
- CHEN Xiaoqing, LIU Juemin, HUANG Yingwei, et al. Transformer fault diagnosis using improved artificial fish swarm with rough set algorithm[J]. *High Voltage Engineering*, 2012, 38(6):1403-1409.
- [12] 刘胜军, 孙志鹏, 沈辰, 等. 基于振动频谱分析和总谐波畸变率的电力变压器故障诊断方法研究[J]. 电网与清洁能源, 2021, 37(3):86-91.
- LIU Shengjun, SUN Zhipeng, SHEN Chen, et al. Research on fault diagnosis of power transformers based on spectral analysis of vibration signals and total harmonic distortion[J]. *Power System and Clean Energy*, 2021, 37(3):86-91.
- [13] 周光宇, 马松龄. 基于机器学习与 DGA 的变压器故障诊断及定位研究[J]. 高压电器, 2020, 56(6):262-268.
- ZHOU Guangyu, MA Songling. Study of transformer fault diagnosis and location based on machine learning and DGA[J]. *High Voltage Apparatus*, 2020, 56(6):262-268.
- [14] HU Q, YU D, XIE Z. Neighborhood classifiers[J]. *Expert Systems with Applications*, 2008, 34(2):866-876.
- [15] 周艳真, 查显煜, 兰健, 等. 基于数据增强和深度残差网络的电力系统暂态稳定预测[J]. 中国电力, 2020, 53(1):22-31.
- ZHOU Yanzhen, CHA Xanyu, LAN Jian, et al. Transient stability prediction of power systems based on deep residual network and data augmentation[J]. *Electric Power*, 2020, 53(1):22-31.
- [16] 蔡国伟, 张启蒙, 杨德友, 等. 基于改进深度置信网络的电力系统暂态稳定评估研究[J]. 智慧电力, 2020, 48(3):61-68.
- CAI Guowei, ZHANG Qimeng, YANG Deyou, et al. Research on power system transient stability assessment based on improved deep belief network[J]. *Smart Power*, 2020, 48(3):61-68.
- [17] CHENG R, JIN Y. A social learning particle swarm optimization algorithm for scalable optimization[J]. *Information sciences*, 2015, 291:43-60.
- [18] KIM S W, KIM S J, SEO H D, et al. New methods of DGA diagnosis using IEC TC 10 and related databases part 1: application of gas-ratio combinations[J]. *IEEE Transactions on Dielectrics & Electrical Insulation*, 2013, 20(2):685-690.