

doi: 10.16112/j.cnki.53-1223/n.2019.05.009

# 基于混沌粒子群优化支持向量机的变压器故障诊断

谭贵生<sup>1</sup>, 石宜金<sup>1</sup>, 刘丹丹<sup>2</sup>, 李留文<sup>2</sup>

(1. 云南大学 旅游文化学院, 云南 丽江 674100; 2. 云南电网有限责任公司丽江供电局, 云南 丽江 674100)

**摘要:** 为了提高电力变压器故障诊断的准确性, 也要克服人工神经网络(ANN)中存在的收敛速度慢、容易陷入局部极值等缺陷, 提出一种混沌的粒子群优化支持向量机的变压器诊断方法, 该方法不仅具有很强的全局搜索能力, 而且适用于支持向量机(SVM)参数优化, 提高算法的鲁棒性。首先利用混沌的粒子群算法优化支持向量机的参数, 把气体的特征参数代入优化的支持向量机分类模型中进行诊断, 能够准确地分类变压器故障, 从而达到故障诊断的目的。实验结果与常规方法比较, 该方法简单有效, 诊断速度快, 诊断正确率高。

**关键词:** 变压器; 故障诊断; 粒子群优化; 支持向量机; 参数优化

中图分类号: TM41 文献标志码: A 文章编号: 1007-855X(2019)05-0054-08

## Fault Diagnosis of Transformers Based on Support Vector Machine with Improved Particle Swarm Optimization

TAN Guisheng<sup>1</sup>, SHI Yijin<sup>1</sup>, LIU Dandan<sup>2</sup>, LI Liuwen<sup>2</sup>

(1. Tourism and Culture College, Yunnan University, Lijiang 674100, China

2. Lijiang Power Supply Bureau of Yunnan Power Grid Corporation, Lijiang 674100, China)

**Abstract:** In order to improve the accuracy of fault diagnosis of power transformer and solve the problem of local optimal solution and low convergence rate existed in artificial neural networks (ANN), we presented a method based on support vector machine (SVM) with chaos particle swarm optimization (CPSO) for fault diagnosis of transformer. The method not only has strong global search capability and robustness, but also is very easy to implement. First, the chaos particle swarm optimization is suitable to determine free parameters of SVM. Second, the CPSO-SVM classifiers with the dissolved gas analysis can achieve diagnostic accuracy. Finally, fault diagnosis of power transformer was realized. The experimental results indicate that the method is simpler, faster and more accurate compared with the traditional algorithm.

**Key words:** transformer; fault diagnosis; chaos particle swarm optimization (CPSO); support vector machine (SVM); parameter optimization

## 0 引言

电力变压器是电力系统输变电的枢纽设备, 如果不能及时发现电力变压器的潜在故障, 就会逐渐导致局部乃至大面积停电, 造成经济损失, 所以变压器故障诊断是必要的。目前, 变压器故障诊断主要为在线检测和离线检测, 在线检测的方法有油中气体分析(dissolved gas analysis, DGA)、局部监测等; 离线检测方法有油中气体分析、纸板特性分析等; 在线或离线分析变压器故障, 气体分析比较全面, 相应的指标参数比较

收稿日期: 2018-10-29. 基金项目: 云南电网有限责任公司基金项目(YNKJXM20180306); 云南省教育厅基金项目(2016ZDX261); 云南大学旅游文化学院基金项目(2017XY19)。

作者简介: 谭贵生(1986-), 男, 硕士, 讲师. 主要研究方向: 电力设备故障诊断. E-mail: tgs\_jl@163.com

全面.另外,DGA实测数据比较直观,检测的操作方便,该方法应用比较广泛.DGA主要检测变压器油中的气体成分和含量,如:CH<sub>4</sub>,C<sub>2</sub>H<sub>2</sub>,C<sub>2</sub>H<sub>4</sub>,C<sub>2</sub>H<sub>6</sub>,CO,CO<sub>2</sub>,H<sub>2</sub>等,对气体特征参数进行故障分析的有IEC、DL/T722-2014等<sup>[2]</sup>,传统的诊断是IEC,后期很多学者对IEC进行改进,在实际应用中,诊断的正确率不是太高,出现诊断误差.

近年来,随着人工智能(artificial intelligence, AI)新技术的发展,很多的方法应用在变压器故障中,可以弥补传统三比值方法不足之处.例如:专家系统<sup>[3]</sup>、人工神经网络(ANN)<sup>[4]</sup>、BP神经网络(BPNN)<sup>[5]</sup>、支持向量机(support vector machine, SVM)<sup>[6]</sup>、粒子群算法和免疫算法<sup>[7-8]</sup>等,它们在一定程度上提高故障的准确率,在实际工程中取得一定成效,但都存在一些不足,如人工神经网络在结构复杂以及大样本时,容易出现“过学习”或者低泛化能力;应用支持向量机处理的数据量较大时,冗余信息存在使得SVM的训练时间过长、速度变慢,其只适合小样本,但支持向量机参数的选取很困难,影响其实用性;粒子群优化算法是一种智能群体优化方法,该方法简单通用,几乎不用调整参数,容易实现,非常适用于优化问题求解,但易陷入局部最优、进化后期收敛速度慢等,出现所谓的早熟收敛现象<sup>[9]</sup>;还有一些模糊神经专家系统在变压器的诊断,都很难克服算法本身存在的局限性,不能准确解决变压器故障诊断问题.

针对上述问题,根据混沌运动具有随机性、遍历性、对初始条件的敏感性等特点<sup>[10-11]</sup>,可以解决收敛速度和陷入局部极值的问题.本文提出一种混沌粒子群优化支持向量机的变压器故障诊断方法,用混沌的粒子群算法优化支持向量机的参数,把气体的特征参数代入优化的支持向量机分类模型中进行诊断,能够提高变压器分类故障,从而达到故障诊断的目的,所以,该方法实现智能算法的有效互补,有效弥补单一算法的不足,提高了故障诊断的准确度.

## 1 支持向量机及其参数

### 1.1 支持向量机原理

支持向量机是基于结构风险最小化的原则的统计学习理论,通过最优超平面的构造使泛化误差的上限最小化;支持向量机是基于统计学理论的学习方法,通过最优超平面,能够找到极值的最优解,使得测试集的误差较小.其基本思想是通过非线性映射把数据样本从原空间映射到高维的特征空间中,然后在特征空间中求出最优分类面,从而解决了低维空间不易区分的难题<sup>[12]</sup>.

对于给定大小为  $l$  训练数据样本集:

$$\begin{cases} D = \{ (x_1, y_1), \dots, (x_l, y_l) \} \\ x = (x_1, x_2, \dots, x_l) \subset R \\ y_i \in \{ +1, -1 \}, i = 1, 2, \dots, l \end{cases} \quad (1)$$

在分类面两边的样本对应线性、非线性两种不同的类别,对于线性的超平面表达式为:

$$wx + b = 0 \quad (2)$$

线性分类面的判别函数的一般形式为:

$$f(x, w) = \text{sign}(w \cdot x + b) \quad (3)$$

对于非线性超平面需要一个非线性映射  $\Phi(x)$  将它从输入空间映射到高维特征空间,非线性的超平面表达式为:

$$w\Phi(x) + b = 0 \quad (4)$$

式中:  $w$  为高维特征空间向量;  $b$  是分类阈值;  $\Phi(x)$  为映射函数表达式,都是待确定的变量.

在最优超平面上要求  $2/\|w\|$  为最大,才得到正确分类,这就可以转化为一个二次规划问题,需要引入松弛变量  $\xi$  和一个大于零的惩罚参数  $C$ :

$$\min_{w, b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (5)$$

$$\text{s. t. } y_i(w x_i + b) \geq 1 - \xi_i \quad (6)$$

$$\xi_i \geq 0, i = 1, 2, \dots, l$$

将式(5)与(6)以拉格朗日乘子算法化为对偶形式:

$$L(\|w\|, b, \mu_i, \eta_i) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l a_i (y_i (w\Phi(x_i) + b) - 1 + \xi_i) - \sum_{i=1}^l \eta_i \xi_i \quad (7)$$

式中:  $a_i, \eta_i$  是 Lagrange 乘子.

根据  $K-T$  条件, 将式(7)问题转化对偶问题:

$$\max \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l a_i a_j y_i y_j \Phi(x_i) * \Phi(x_j) \quad \text{s.t. } 0 \leq a_i \leq C, \sum_{i=1}^l a_i y_i = 0 \quad (8)$$

通过求解二次规划问题可得  $a_i > 0$  称对应的  $x_i$  为支持向量, 求出  $b$ , 从而得到相应的最优判别函数:

$$y = \text{sign} \left( \sum_{SV} a_i y_i [\Phi(x_i) \Phi(y_i)] + b \right) \quad (9)$$

式中:  $SV$  为支持向量;  $(\Phi(x_i) \Phi(y_i))$  为核函数, 且  $K(x_i, y_i) = (\Phi(x_i) \Phi(y_i))$

## 1.2 支持向量机参数

对于支持向量机参数的选择, 通常选取以下三种核函数<sup>[8]</sup>:

(1) 多项式核函数:

$$K(x_i, y_i) = [(x_i y_i) + c]^d \quad (10)$$

$c, d$  为参数.

(2) 高斯核函数:

$$K(x_i, y_i) = \exp\left(-\frac{\|x_i - y_i\|^2}{\delta^2}\right) \quad (11)$$

$\delta$  为参数.

(3) Sigmoid 函数

$$K(x_i, y_i) = \tan[a(x_i y_i) + c]; c, \mu \in \mathbf{R} \quad (12)$$

参数的大小影响其学习能力和泛化能力, 为了求得参数的最优解, 从式(11)可知, 径向基函数(RBF)中只需确定一个参数(即参数  $\delta$ ), 从而有利于参数的优化; 多项式核函数与 Sigmoid 函数分别需要确定两个参数, 对于两个参数的确定就会带来困难, 所以本文选取径向基函数.

## 2 混沌粒子群的支持向量机参数优化

### 2.1 粒子群优化算法

粒子群优化(Particle Swarm Optimization, PSO)算法由 Kennedy 与 Eberhart 在 1995 年提出的一种基于群体智能的进化计算技术, 它利用群体中的粒子之间协作与竞争产生的一种优化搜索方法, 能实现多维空间中最优解的搜索<sup>[13]</sup>.

粒子群算法的数学描述为: 设粒子群规模为  $N$ , 其中每个粒子在  $D$  维空间中位置表示为:

$$x_i = (x_{i1}, x_{i2}, \dots, x_{id}, \dots, x_{iD}) \quad (13)$$

每个粒子在  $D$  维空间的速度表示为:

$$v_i = (v_{i1}, v_{i2}, \dots, v_{id}, \dots, v_{iD}) \quad (14)$$

每次迭代, 粒子通过动态跟踪两个极值来更新速度和位置. 如粒子在第  $d$  ( $d = 1, 2, \dots, D$ ) 维子空间的分行速度根据式(15)进行调整:

$$x_{id} = v_{id} + c_1 \text{rand}_1() (p_{id} - x_{id}) + c_2 \text{rand}_2() (p_{gd} - x_{id}), \text{其中} \begin{cases} v_{id} = v_{\max} & \text{if } v_{id} > v_{\max} \\ v_{id} = -v_{\max} & \text{if } v_{id} < -v_{\max} \end{cases} \quad (15)$$

式中:  $c_1, c_2$  为加速常数;  $\text{rand}_1, \text{rand}_2$  为随机数;  $p_{gd}$  是粒子群的历史最优位置;  $p_{id}$  是当前粒子的最优位置.

另外, 粒子可通过式(16)调整自身的位置:

$$x_{id} = x_{id} + v_{id} \quad (16)$$

根据式(15)与(16)能够用于各种搜索寻优问题的求解过程.

可以得出不同粒子位置和速度, 表达式为:

$$\begin{cases} x_{id}^d = wv_{id}^d + c_1 \text{rand}_1() (p_{id}^d - x_{id}^d) + c_2 \text{rand}_2() (p_{gd}^d - x_{id}^d) \\ x_{id}^d = x_{id}^d + v_{id}^d \end{cases} \quad (17)$$

式中:  $p_{gd}^d$  是粒子群的历史最优位置;  $p_{id}^d$  是当前粒子的最优位置;  $w$  为惯性权重;  $c_1$   $c_2$  为加速常数,一般取值 1.5 ~ 2.0 之间;  $v_{id}^d$  是当前粒子的速度.

## 2.2 混沌粒子群优化算法

粒子群算法具有较慢的收敛速度,局部的搜索能力较弱,容易陷入局部极值点,不能较好地得出准确的结果.由于混沌运动具有随机性、遍历性、对初始条件的敏感性等特点,本文提出一种基于混沌的粒子群优化算法(Chaos Particle Swarm Optimization, CPSO),可以提高粒子群的搜索能力,也可以避免局部极值点,提高其收敛的精度和速度.

本文采用经典的 Logistic 方程构成混沌序列:

$$x_{n+1} = \mu x_n (1 - x_n) \quad i = 1, 2, \dots, n \quad (18)$$

式中:  $\mu$  为控制参量,  $n$  为优化变量的个数,当  $0 \leq x_n \leq 1$   $\mu = 4$  时,系统完全成为混沌状态,混沌变量的任意初值  $x_0$  赋值给式(18)得出相应的混沌变量.

混沌粒子群算法能有效提高算法的收敛性,可以避免算法后期振荡,混沌粒子群算法的具体思想为以下四个部分:

### (1) 惯性权重

为了保证算法能够快速收敛,避免出现局部最优,使得算法有效平衡全局和局部的搜索能力,引用  $w$  惯性权重  $\mu$  对 CPSO 的收敛起到重要作用.对  $w$  进行调整:

$$w(t+1) = 4.0w(t)(1-w(t)) \quad (19)$$

$$w(t) = w_{\min} + (w_{\max} - w_{\min})w(t) \quad (20)$$

式中:  $[w_{\min}, w_{\max}]$  是权重系数的取值范围,一般为 0.4 ~ 0.9.

### (2) 随机数

为了保证效率的高度,对随机数进行处理,更新公式如下:

$$\text{rand}_z(t+1) = 4.0\text{rand}_z(t)(1-\text{rand}_z(t)) \quad (21)$$

式中  $\text{rand}_z$  取值范围为 0 ~ 1  $z = 1, 2$ .

### (3) 加速常数

加速常数是保证算法的收敛速度,更新公式如下:

$$c_z(t+1) = 4.0c_z(t)(1-c_z(t)) \quad (22)$$

$$c_z(t) = c_{\min} + (c_{\max} - c_{\min})c_i(t) \quad (23)$$

式中:  $z = 1, 2$ ,  $[c_{\min}, c_{\max}]$  是加速常数取值范围,一般为 1.5 ~ 2.0.

### (4) 早熟处理

因为粒子群算法后期收敛速度较慢,容易陷入局部极值点,使得粒子群出现早收敛,即早熟,粒子都会出现“聚集”现象.粒子的位置决定粒子群的适应度,通过适应度来判断早熟的情况,采用粒子群方差  $\delta^2$  作为判断条件.

$$\delta^2 = \sum_{i=1}^n \frac{F_i - F_{avg}}{F} \quad (24)$$

式中:  $F_i$  为粒子群中粒子的适应度;  $F_{avg}$  为粒子群中粒子的适应度的平均值.

如果  $\delta^2$  小于  $G$  给定值,认为粒子已经进去早熟,陷入早熟的粒子,需要重新给定速度和位置,让其跳出局部最优值.

混沌粒子群优化算法的基本思想:对初始化的粒子的位置和速度,代入混沌序列使其呈现混沌状态,从而获得新的位置;引入混沌序列的搜索算法,进行迭代,至到满足粒子的个体极值和全局极值的最优解,迭代才终止.

## 2.3 混沌粒子群的支持向量机参数优化

SVM 参数  $C$ 、 $\delta$  对故障诊断的准确度影响很大,所以确定  $C$ 、 $\delta$  参数很重要<sup>[14]</sup>,本文采用混沌粒子群优

化算法优化 SVM 分类器的  $C, \delta$  参数.

基于混沌粒子群的支持向量机参数优化过程如图 1 所示, 优化步骤如下:

1) 初始化设置混沌粒子群算法参数, 如:  $w$  惯性权重,  $C_1, C_2$  为加速常数,  $G$  给定值, 支持向量机中的  $C, \delta$  参数.

2) 将每个粒的位置和速度进行初始设置, 确定粒子的最优位置.

3) 分别计算每个粒子当前的位置, 通过公式(24)判断粒子的误差值, 再与给定值  $G$  进行判断是否满足适应度条件, 如果满足, 可以找到最优的位置和速度; 不满足条件, 跳出局部最优值, 重新找到新的最优参数.

4) 由 3) 找到最优参数与支持向量机, 求得对于最优参数的  $C, \delta$  参数, 提高支持向量机分类器的准确率.

通过 CPSO 算法对 SVM 的核函数的优化, 就得出优化后的 SVM 分类器.

### 3 变压器故障诊断的应用实例

在电力系统中, 通常变压器的故障诊断主要手段应用油中溶解气体方法. 该方法具有强针对性、直观性, 能尽可能全面的找出故障特性与故障类型的关系. 当变压器发生故障时, 就会产生特征气体, 如  $H_2, CH_4, C_2H_2, C_2H_4, C_2H_6, CO, CO_2$  以及烃类混合物. 根据故障特征气体的体积分数与故障类型的关系, 找出其映射关系, 但相同的故障特征气体对应的故障类型不是单一的. 本文首先应用混沌粒子群优化算法获取支持向量机的最优参数; 其次, 以故障特征气体为依据, 为训练样本, 把训练样本作为支持向量机的输入, 由支持向量机的分类器诊断故障, 最终实现电力变压器故障诊断.

#### 3.1 特征参数提取

选取样本原始数据时, 尽量使各类别数据体积分数比相近, 可以避免造成数据集倾斜问题. 本文选取 5 种故障特征气体  $CH_4, C_2H_2, C_2H_4, C_2H_6$  和  $H_2$  的体积分数作为输入条件, 为了保证支持向量机的训练, 将 5 种气体进行归一化处理:

$$w_s = \frac{z_s}{\max_{i=1}^s(z_s)} \quad (25)$$

式中:  $w_s$  为归一化值;  $z_s (s = 1, 2, \dots, 5)$  为 5 种气体的体积分数.

#### 3.2 SVM 分类模型的构建

由于 SVM 是二类分类器, 而变压器故障是多个故障类型, 所以需要构建多类分类器, 如图 2 所示. 解决多类分类问题本文应用“one - versus - rest”算法. 该方法思想为: 一个两类分类器将每一类与其他类别区分开, 得到  $k$  个分类函数, 第  $i$  个分类器的训练样本作为正类, 其余的样本为负值<sup>[15]</sup>.

由一对多(one - versus - rest) SVM 分类器的结构原理可知, 给定训练集  $(x_1, y_1), \dots, (x_l, y_l), y_i \in \{1, \dots, k\}, i = 1, \dots, l, y_i$  为  $x_i$  的类别标号, 第  $i$  个分类器是求解如下问题:

$$\begin{aligned} \min & \frac{1}{2} \|w^i\|^2 + c^i \sum_{j=1}^n \xi_j^i \\ w^j \cdot \varphi(x_j) + b^j & \geq 1 - \xi_j^i, y_j = i \\ w^j \cdot \varphi(x_j) + b^j & \leq 1 - \xi_j^i, y_j \neq i \\ \xi_j^i & \geq 0, j = 1, \dots, l \end{aligned} \quad (26)$$

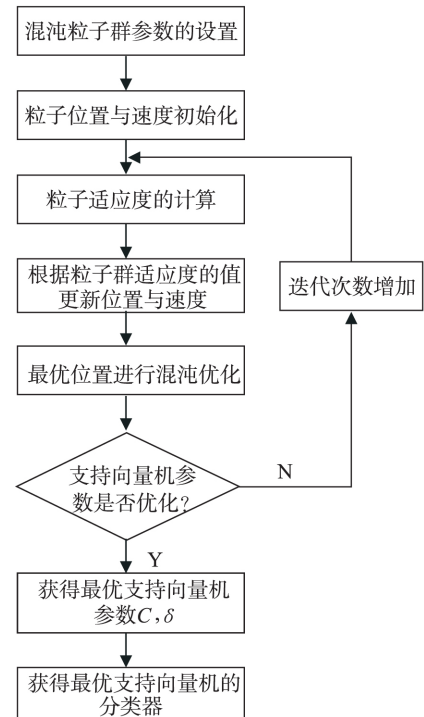


图 1 基于 CPSO 的 SVM 的优化过程  
Fig. 1 Process of optimizing the SVM parameters with chaos particle swarm optimization

求解  $k$  个这样问题, 可以得到  $k$  个决策函数:

$$f_1(x) = \text{sgn}(w^1 \cdot \varphi(x)) + b^1$$

$$\dots\dots$$

$$f_k(x) = \text{sgn}(w^k \cdot \varphi(x)) + b^k \tag{27}$$

当测试样本时, 将测试样本分别通过式 (27) 中的每个判别函数, 具有最大函数值的分类器对应的类别为该样本的类别. 函数表达式如下:

$$\text{class}(x) = \arg \max_{i=1, \dots, k} (f_i(x)) \tag{28}$$

以  $\text{CH}_4$ 、 $\text{C}_2\text{H}_2$ 、 $\text{C}_2\text{H}_4$ 、 $\text{C}_2\text{H}_6$ 、 $\text{H}_2$  等 5 种特征气体体积分数为基础, 建立 5 维的输入向量  $x$ , 由相关的分类器进行分类计算, 得到诊断结果 (如图 2 所示). 变压器的故障类型很多, 本文选择常见的 4 种故障, 包括电弧放电 (D2)、低能放电 (D1)、高温过热 (T3) 和中低温过热 (T12).

### 3.3 基于 CPSO 的 SVM 参数优化

选取不同的核函数将生成不同的 SVM, 而对诊断结果有很大的影响. 本文采用 RBF 核函数, 对于未知数据时 RBF 核函数优于其他的函数, 还有精度和训练速度也有很明显的效果. 另外, 惩罚因子  $C$  对 SVM 的性能也有很大影响, 所以通过训练, 适当调整惩罚因子  $C$  与径向核函数  $\delta$  的宽度, 使得 SVM 的正确率达到最高.

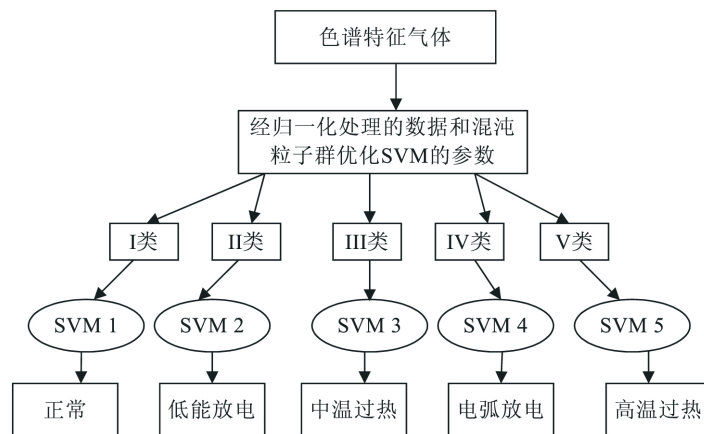


图 2 变压器故障诊断分类模型

Fig. 2 Classification model of transformer failure diagnosis

验证 CPSO-SVM 分类器的准确性, 采用粒子群中的带惯性权重优化支持向量机的惩罚因子  $C$  与径向核函数  $\delta$  的宽度, 对文献 [16] 中的 107 组数据筛选出训练样本和测试样本, 固定  $\delta$  的宽度和惩罚因子  $C$ , 确定 CPSO-SVM 分类中的参数以及各支持向量机的正确率, 如表 1 所示.

表 1 分类器正确率及参数选择结果

Tab. 1 Result of the accuracy and parameters of classifiers

分类器	训练个数	测试个数	参数 $C$	参数 $\delta$	正确率 / %
CPSO-SVM1	100	50	176.81	0.523	100
CPSO-SVM2	90	40	29.78	1.103	97.2
CPSO-SVM3	80	30	35.12	0.458	98.5
CPSO-SVM4	60	20	123.68	0.659	96.7
CPSO-SVM5	30	10	153.35	1.692	90.2

用优化的分类器进一步验证变压器故障的准确性, 把测试样本数据进行测试, 分别把相应的特征气体作为输入量, 用 CPSO-SVM 分类器进行故障诊断, 诊断正确率能达到 92.5% 如表 2 所示.

表2 CPSO-SVM 诊断正确率

Tab.2 Result of the accuracy of CPSO-SVM classifiers

分类器	参数 $C$	参数 $\delta$	分类器正确率/%	诊断正确率/%
CPSO-SVM1	176.81	0.523	100	92.5
CPSO-SVM2	29.78	1.103	97.2	92.5
CPSO-SVM3	35.12	0.458	98.5	92.5
CPSO-SVM4	123.68	0.659	96.7	92.5
CPSO-SVM5	153.35	1.692	90.2	92.5

### 3.4 对比分析

为了有效的对比,分别与传统的 IEC 三值法、ANN、SVM、PSO-SVM 和本文方法针对相同的原始样本集进行对比,分析结果如表3、表4所示,其中表3给出部分变压器具体实例故障诊断结果.

表3 变压器故障诊断结果

Tab.3 Result of fault diagnosis of power transform

序号	气体含量 $\times 10^{-6}$					故障类型				本文方法	实际故障
	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	IEC	ANN	SVM	PSO-SVM		
1	145.88	40.65	9.37	34.02	59.71	D2	D2	D2	D2	D2	D2
2	6.8	17.9	37.8	143.6	1.9	T3	D1	T12	T3	T12	T12
3	33	29	9	12	0	T3	T3	T3	T3	T3	T3
4	80	20	6	20	62	D1	D1	D2	D2	D2	D2
5	13.1	44.7	91.5	213.3	4.2	T3	T3	T3	T3	T3	T3
6	66	76	15	100	24	T12	T12	D1	T12	T12	T12
7	46.7	8.2	1.8	5.1	4.1	D2	D1	D2	D2	D1	D1
8	45.1	96.7	39.0	24.1	0	T12	T3	T12	T3	T3	T12

注: D1 - 低能放电、D2 - 电弧放电、T12 - 中低温过热、T3 - 高温过热.

表4 各类算法的结果

Tab.4 Result of different algorithms

诊断方法	IEC	ANN	AVM	PSO-SVM	CPSO-SVM
正确率/%	62.3	78.5	87.9	90.4	92.5

1) 如应用 ANN 模型对变压器故障诊断,该模型选择3层BP网络,输入层节点20,输出层5个节点,隐含层选24个节点,最终总平均分类正确率为78.5%;

2) 直接支持向量机(SVM),对原始数据进行故障分析,得到相应的故障诊断结果,其正确率约为87.9%;

3) 基于粒子群优化算法的支持向量机(PSO-SVM)的故障诊断的正确率为90.4%,但经过混沌粒子群优化个体极值与局部、全局的极值优化的SVM多类分类器,训练时间比没有避免全局极值的粒子群优化算法的时间短,正确率也提高;

4) 从表3可知,由5种不同算法对CH<sub>4</sub>、C<sub>2</sub>H<sub>2</sub>、C<sub>2</sub>H<sub>4</sub>、C<sub>2</sub>H<sub>6</sub>、H<sub>2</sub>5种特征气体体积分数进行故障诊断,得出不同的故障类型,与实际故障类型对比,本方法的故障正确率是最高的.

通过以上的方法比较,混沌粒子群优化的支持向量机的训练速度快,诊断结果正确率高.

## 4 结论

本文提出一种混沌粒子群优化算法与支持向量机相结合的变压器故障诊断方法,通过对比分析诊断结果,得到如下结论:

1) 由于普通支持向量机的参数选择的困难,还有粒子群优化算法的局限性,为了保证故障诊断的正确率,提出基于混沌的粒子群优化支持向量机的故障诊断,实验结果表明,该方法能较快地判断故障类型和正确率。

2) 本文使用混沌粒子群优化算法与支持向量机相结合的变压器故障诊断方法,可以弥补单一智能算法的不足,能优化 SVM 分类器的惩罚因子  $C$  与径向核函数  $\delta$  的宽度,提高分类器故障诊断的分类精度。

3) 通过实验结果与 IEC、ANN、SVN、PSO-SVM 四种方法进行比较,CPSO-SVM 方法比其他故障诊断方法准确率高,说明该方法可行、有效和实用。

#### 参考文献:

- [1] 袁海满,雷帆,陈宇,等.基于 DGA 的粒子群相关向量机变压器故障诊断[J].高压电器,2017,53(2):108-112.
- [2] ABU-SIADA A, HMOOD S. A new fuzzy logic approach to identify power transformer criticality using dissolved gas-in-oil analysis[J]. International Journal of Electrical Power and Energy Systems, 2015, 67(1): 401-408.
- [3] 何湘宁,石巍,李武华,等.基于大数据的大容量电力电子系统可靠性研究[J].中国电机工程学报,2017,37(1):209-221.
- [4] Wang X, Li Q, Li C, et al. Reliability assessment of the fault diagnosis methodologies for transformers and a new diagnostic scheme based on fault info integration[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2013, 20(6): 2292-2298.
- [5] Rajaraman P, Sundaravaradan N A, Mallikarjuna B, et al. Robust fault analysis in transmission lines using Synchrophasor measurements[J]. Protection and Control of Modern Power Systems, 2018, 3(1): 1-14.
- [6] 何恰刚,陈铭,张大波,等.基于古林法和层次可拓的变压器状态评估[J].电力系统保护与控制,2018,46(21):38-44.
- [7] 杨毅,邵欣洋.智能变电站无线监测网络群优化算法研究[J].昆明理工大学学报(自然科学版),2018,43(4):65-70.
- [8] 朱超岩,姚晓东.基于遗传算法优化的支持向量机在变压器故障诊断中的应用[J].仪表技术,2019(3):21-24.
- [9] 闵亚琪,马鑫,翟振刚,等.用于变压器 DGA 故障诊断的改进 PSO 优化 SVM 算法的研究[J].现代电子技术,2018,41(15):124-128.
- [10] Hu Y Q, Juan L, Tan X. Digital modulation recognition based on instantaneous information[J]. The Journal of China Universities of Posts and Telecommunications, 2010, 17(3): 52-90.
- [11] 吕锋,彭一,赵亮宇,等.电压型 Boost 变换器的混沌分岔现象及其控制[J].昆明理工大学学报(自然科学版),2018,43(1):55-60.
- [12] 陈金猛,李屹.基于故障树的变压器质量缺陷分类方法研究[J].变压器,2017,54(9):43-46.
- [13] PAWLAK Z. Rough sets[J]. International Journal of Computer and Information Sciences, 1982, 11(5): 341-356.
- [14] 郑含博,王伟,李晓纲,等.基于多分类最小二乘支持向量机和改进粒子群优化算法的电力变压器故障诊断方法[J].高电压技术,2014,40(11):3424-3429.
- [15] 林晓宁,蔡金锭.基于粗糙集理论的变压器油纸绝缘状态评估[J].电力系统保护与控制,2019,47(7):22-29.
- [16] 刘晓津.基于支持向量机和油中溶解气体分析的变压器故障诊断[D].天津:天津大学,2007.