

DOI: 10.7667/PSPC161753

基于鲁棒能量模型 LS-TSVM 和 DGA 的变压器故障诊断

陈欢, 彭辉, 舒乃秋, 李自品, 龙嘉文

(武汉大学电气工程学院, 湖北 武汉 430072)

摘要: 鲁棒能量模型最小二乘双支持向量机作为最小二乘双支持向量机(LS-TSVM)的改进算法, 训练速度快、鲁棒性好且泛化能力强。将其引入到变压器故障诊断中, 并提出一种鸡群算法优化鲁棒能量模型 LS-TSVM 的变压器故障诊断模型。在该模型中, 结合二叉树和鲁棒能量模型 LS-TSVM 构造多类分类器用于变压器故障类型识别, 并采用搜索性能较强的鸡群算法对鲁棒能量模型 LS-TSVM 的参数进行优化, 以使模型的诊断性能达到最佳。基于 DGA 的变压器故障诊断实例表明, 该方法故障诊断模型精度高, 诊断效果优于 PSO-SVM 模型。

关键词: 最小二乘双支持向量机(LS-TSVM); 鲁棒能量模型最小二乘双支持向量机(RELS-TSVM); 鸡群算法(CSO); 变压器; 故障诊断

Fault diagnosis of power transformer based on RELS-TSVM and DGA

CHEN Huan, PENG Hui, SHU Naiqiu, LI Zipin, LONG Jiawen

(School of Electrical Engineering, Wuhan University, Wuhan 430072, China)

Abstract: As an improved algorithm of LS-TSVM, RELS-TSVM has a high training speed, good robustness and strong generalization ability. This paper introduces it to the fault diagnosis of transformer and proposes a fault diagnosis model based on RELS-TSVM optimized by CSO algorithm. In the model, it constructs a multi-class classifier for transformer fault type identification by combining binary tree and RELS-TSVM, and uses CSO that has strong search performance to optimize the parameters of RELS-TSVM, which would upgrade the performance of the model to the best state. The example of transformer fault diagnosis based on DGA shows that the fault diagnosis model in this paper is of high accuracy and works better than PSO-SVM model.

This work is supported by National Natural Science Foundation of China (No. 51477121).

Key words: least squares twin support vector machines (LS-TSVM); robust energy-based least squares twin support vector machines (RELS-TSVM); chicken swarm optimization (CSO); transformer; fault diagnosis

0 引言

电力设备的安全性能是电网安全运行的第一道防线^[1], 是电力系统安全运行的决定因素。变压器作为电力系统的核心设备, 其健康水平和运行状况更是直接决定了电网整体的安全和供电可靠性, 一旦发生故障, 不仅会引起大面积电力停运, 造成经济损失, 还会严重影响消费者的日常生活和工作。变压器内部电晕、局部放电、电弧放电和过热等异常现象都会促进故障的形成^[2], 因此, 如何准确诊断变压器内部潜在异常状态和降低变压器故障率一直都是亟待电力部门解决的问题。

目前, 变压器故障诊断主要基于油中溶解气体分析法(DGA)来实现, 并在此基础上形成了很多方法, 比较典型的有 IEC 三比值法^[3]和罗杰斯比值法^[4], 然而这些方法诊断精度低且局限性较强。近年来, 人们基于人工智能方法对变压器故障诊断方法进行了广泛的研究, 取得了重大的进展, 并形成了支持向量机^[5-6]、神经网络^[2,7-8]、贝叶斯网络^[9-10]和免疫算法^[11-12]等人工智能诊断方法。这些人工智能方法相比传统方法, 在变压器的故障诊断中体现出了巨大的优势。但是这些方法普遍对训练样本集比较敏感, 一旦训练样本集中出现错误数据或噪声, 其诊断精度会大幅度下降。

最小二乘双支持向量机(LS-TSVM)是 M.Arun kumar 和 M.Gopal^[13]在双支持向量机(TSVM)的基础

上提出的一种二分类算法, 作为 TSVM 的最小二乘版本, 它通过一个平方损失函数将 TSVM 中的凸二次规划问题转换为凸线性问题^[14], 更加简化和加快了二分类器的训练过程。但是, LS-TSVM 依然对噪声和离群点比较敏感, 这限制了它对复杂数据的分类性能。为了进一步改善 LS-TSVM 的分类性能, Mohammad Tanveer^[15]等提出了鲁棒能量模型最小二乘双支持向量机(RELS-TSVM)。RELS-TSVM 在训练分类双超平面时, 基于间隔最大化理念在每个目标函数中加入了一个正则化项, 实现了结构风险最小化原则。同时, RELS-TSVM 还为每一个超平面引入了一个能量参数, 大大减小了分类过程中噪声和离群点的不利影响。所以, RELS-TSVM 不仅继承了 LS-TSVM 的训练速度快的特点, 鲁棒性和泛化能力也得到了显著的提高。

鉴于 RELS-TSVM 很好的鲁棒性和泛化能力, 本文将引入到变压器故障诊断中, 提出一种基于鸡群算法优化 RELS-TSVM 的变压器故障诊断模型, 并将该模型与 PSO-SVM 模型的故障诊断效果进行了比较。

1 RELS-TSVM 基本理论

在二分类问题中, 假设正类样本集记为矩阵 $A \in R^{m \times n}$, 负类样本集记为 $B \in R^{m \times n}$, 非线性 RELS-TSVM 通过构造如下两个非线性超平面实现分类。

$$K(\mathbf{x}^T, \mathbf{C}^T)\omega_1 + \mathbf{b}_1 = 0, K(\mathbf{x}^T, \mathbf{C}^T)\omega_2 + \mathbf{b}_2 = 0 \quad (1)$$

式中: $\mathbf{C} = [A; B]$; K 代表核函数, 一般采用分类能力强和参数少的高斯径向基核函数^[16]。

两个非线性超平面可以通过求解如下一组最小化问题得到。

$$\begin{aligned} \min_{(\mathbf{w}_1, \mathbf{b}_1) \in R^{m+1}} & \frac{1}{2} \|K(A, \mathbf{C}^T)\mathbf{w}_1 + \mathbf{e}\mathbf{b}_1\|^2 + \frac{c_1}{2} \xi_1^T \xi_1 + \frac{c_3}{2} \left\| \begin{bmatrix} \mathbf{w}_1 \\ \mathbf{b}_1 \end{bmatrix} \right\|^2 \\ \text{s.t.} & -(K(B, \mathbf{C}^T)\mathbf{w}_1 + \mathbf{e}\mathbf{b}_1) + \xi_1 = E_1 \end{aligned} \quad (2)$$

$$\begin{aligned} \min_{(\mathbf{w}_2, \mathbf{b}_2) \in R^{m+1}} & \frac{1}{2} \|K(B, \mathbf{C}^T)\mathbf{w}_2 + \mathbf{e}\mathbf{b}_2\|^2 + \frac{c_2}{2} \xi_2^T \xi_2 + \frac{c_4}{2} \left\| \begin{bmatrix} \mathbf{w}_2 \\ \mathbf{b}_2 \end{bmatrix} \right\|^2 \\ \text{s.t.} & -(K(A, \mathbf{C}^T)\mathbf{w}_2 + \mathbf{e}\mathbf{b}_2) + \xi_2 = E_2 \end{aligned} \quad (3)$$

式中: $K(A, \mathbf{C}^T)$ 、 $K(B, \mathbf{C}^T)$ 分别为 $m_1 \times m$ 维和 $m_2 \times m$ 维的核矩阵; ξ_1 、 ξ_2 为松弛变量; c_1 、 c_2 、 c_3 、 c_4 为大于零的惩罚参数; E_1 、 E_2 分别为两个超平面的能量参数。

令 $\mathbf{z}_1 = [\mathbf{w}_1; \mathbf{b}_1]$ 、 $\mathbf{z}_2 = [\mathbf{w}_2; \mathbf{b}_2]$, 求解这组最小化问题可得:

$$\mathbf{z}_1 = -(c_1 N^T N + M^T M + c_3 I)^{-1} c_1 N^T E_1 \quad (4)$$

$$\mathbf{z}_2 = (c_2 M^T M + N^T N + c_4 I)^{-1} c_2 M^T E_2 \quad (5)$$

其中: $N = [K(B, \mathbf{C}^T) \ \mathbf{e}]$; $M = [K(A, \mathbf{C}^T) \ \mathbf{e}]$ 。 \mathbf{z}_1 和 \mathbf{z}_2 表达式中 $c_1 N^T N + M^T M + c_3 I$ 和 $c_2 M^T M + N^T N + c_4 I$ 都是正定矩阵, 在求解的过程中不会出现病态解。

根据式(4)和式(5)求解 \mathbf{z}_1 和 \mathbf{z}_2 , 需要求解两次 $(m+1) \times (m+1)$ 维矩阵的逆, 为了减小计算量, 根据舍曼—墨里森—伍德公式, 式(4)和式(5)可以近似为

$$\mathbf{z}_1 = -(S - SN^T (\frac{I}{c_1} + NSN^T)^{-1} NS) \times c_1 N^T E_1 \quad (6)$$

$$\mathbf{z}_2 = (T - TM^T (\frac{I}{c_2} + MTM^T)^{-1} MT) \times c_2 M^T E_2 \quad (7)$$

式中: $S = (M^T M + c_3 I)^{-1}$; $T = (N^T N + c_4 I)^{-1}$ 。根据求得两个向量 \mathbf{z}_1 、 \mathbf{z}_2 即可构造一组非线性超平面。对于待测样本 \mathbf{x}_i , 根据以下决策函数进行分类:

$$f(\mathbf{x}_i) = \begin{cases} +1, & \left| \frac{K(\mathbf{x}_i, \mathbf{C}^T)\omega_1 + \mathbf{e}\mathbf{b}_1}{K(\mathbf{x}_i, \mathbf{C}^T)\omega_2 + \mathbf{e}\mathbf{b}_2} \right| \leq 1 \\ -1, & \left| \frac{K(\mathbf{x}_i, \mathbf{C}^T)\omega_1 + \mathbf{e}\mathbf{b}_1}{K(\mathbf{x}_i, \mathbf{C}^T)\omega_2 + \mathbf{e}\mathbf{b}_2} \right| > 1 \end{cases} \quad (8)$$

2 鸡群算法

鸡群算法(CSO)^[17]是一种生物启发式随机优化算法, 通过模拟鸡群的等级秩序和鸡群的行为实现最优解的搜索过程。与 PSO 算法、遗传算法和蝙蝠算法等算法相比, 它不仅吸收了这些算法的共性, 还很好地规避了这些算法易陷入局部最优的缺陷。

在鸡群算法中, 鸡群被分为包含一只公鸡、若干母鸡和小鸡的子群, 搜索过程中子群中不同的鸡运动规律不同。等级制度在鸡群活动中发挥着重要作用^[18], 在一定的等级制度下, 较高等级的鸡支配较低等级的鸡。优势母鸡往往聚集在领头公鸡附近, 并且离领头公鸡越近的地方优势母鸡的数量越多, 而被支配的公鸡和母鸡则处于边缘。

鸡群算法的数学模型中鸡群的觅食行为遵守以下规则。

1) 鸡群由若干子群组成, 每个子群包含一只处于支配地位的公鸡以及一些被支配的母鸡和小鸡。

2) 鸡群中个体的适应值决定了鸡群的等级制度。最优适应值对应的个体作为支配一个子群的公

鸡，最差适应值对应的个体作为小鸡，其他的个体则作为母鸡。

3) 鸡群的等级制度、支配关系以及母子关系建立之后只有在数次迭代之后才会更新，而在这期间保持不变。

4) 包含有 N 个个体的鸡群被分成公鸡、母鸡、小鸡和母代母鸡， RN 、 HN 、 CN 和 MN 分别是这 4 类个体的数目。鸡群中每个个体的位置表示为 $x_{i,j}$ ($i \in [1, \dots, N], j \in [1, \dots, D]$)。

在搜索最优解时，鸡群中 3 种类型的鸡个体按照不同的公式更新位置。作为适应值最佳的个体，公鸡觅食能力最强，寻找食物过程中比其他觅食能力较差的鸡更具有优势^[19]，搜索范围更广，其位置变化表达式为

$$x_{i,j}^{t+1} = x_{i,j}^t \cdot (1 + \text{rand}(0, \sigma^2)) \quad (9)$$

$$\sigma^2 = \begin{cases} 1, & \text{if } f_i \leq f_k, k \in [1, N], k \neq i \\ e^{\frac{f_k - f_i}{|f_i| + \varepsilon}}, & \text{其他} \end{cases} \quad (10)$$

式中： $\text{rand}(0, \sigma^2)$ 为服从正态分布 $N(0, \sigma^2)$ 的一个随机数； ε 是一个非常小的正数； f_i 为鸡群中第 i 个公鸡个体的适应值； f_k 为除公鸡 i 外随机选择的一个公鸡个体的适应值。

鸡群中母鸡跟随它们的领头公鸡搜索食物，也会与其他的个体争夺好的食物，在与其他个体竞争食物的过程中，处于支配地位的母鸡往往更占优势。母鸡搜索过程中位置变化表达式为

$$x_{i,j}^{t+1} = x_{i,j}^t + S_1 \cdot \text{rand} \cdot (x_{r_1,j}^t - x_{i,j}^t) + \quad (11)$$

$$S_2 \cdot \text{rand} \cdot (x_{r_2,j}^t - x_{i,j}^t)$$

$$S_1 = \exp((f_i - f_{r_1}) / (|f_i| + \varepsilon)) \quad (12)$$

$$S_2 = \exp(f_{r_2} - f_i) \quad (13)$$

式中： $\text{rand} \in [0, 1]$ ，是一个随机数； $r_1 \in [1, N]$ ，代表该母鸡所在子群的公鸡； $r_2 \in [1, N]$ ，代表除该母鸡外整个鸡群中随机选取的公鸡或母鸡。

小鸡跟随母鸡觅食，其位置变化表达式为

$$x_{i,j}^{t+1} = x_{i,j}^t + FL \cdot (x_{m,j}^t - x_{i,j}^t) \quad (14)$$

式中： FL 表示小鸡跟随母鸡的速度系数，取值范围为 $[0, 2]$ ； $x_{m,j}^t$ 为小鸡 i 所跟随母鸡个体的位置， $m \in [1, N]$ 。

作为一种先天的多群算法，鸡群之间的不同运动规律以及相互协作的关系赋予了鸡群算法高效的搜索性能，非常适合于目标优化问题的求解。

3 基于 RELS-TSVM 的变压器故障诊断

3.1 确定输入和输出

变压器油色谱数据不仅能准确反映变压器的运行状态，还容易在线获取，因此本文选取变压器油色谱中 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 5 种特征气体的含量作为故障诊断模型的输入量。直接采用 5 种气体的含量进行故障诊断会引起较大的误差，因此需要对其进行归一化，输入量归一化公式为

$$x = \left\{ \frac{x_1}{\sum_{i=1}^5 x_i}, \frac{x_2}{\sum_{i=2}^5 x_i}, \frac{x_3}{\sum_{i=2}^5 x_i}, \frac{x_4}{\sum_{i=2}^5 x_i}, \frac{x_5}{\sum_{i=2}^5 x_i} \right\} \quad (15)$$

式中， x_1, x_2, x_3, x_4, x_5 分别为 5 种特征气体的含量原始值。

根据变压器实际运行资料，变压器运行过程中不仅会出现中低温过热(T_{12})、高温过热(T_3)、局部放电(PD)、低能放电(D_1)和高能放电(D_2)5 种单一故障类型，还会出现放电兼过热(DT)复合型故障。因此本文主要考虑变压器的这 6 种故障状态，将这 6 种故障类型作为故障诊断模型的输出。

3.2 构建多分类故障诊断模型

RELS-TSVM 作为两分类算法，针对变压器故障诊断中的多分类问题，需要结合多分类方法构建多类分类器。采用二叉树方法将 RELS-TSVM 推广为多类分类算法时，需要构造的二分类器最少，相应的训练速度和识别速度最快，因此本文结合 RELS-TSVM 和二叉树构建故障诊断模型，如图 1 所示。图中 C_1, C_2, C_3, C_4, C_5 分别为对应的 RELS-TSVM 分类器。

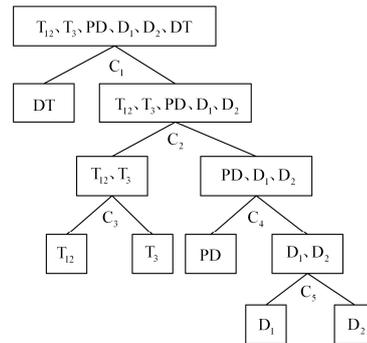


图 1 二叉树 RELS-TSVM 故障诊断模型

Fig. 1 Binary tree RELS-TSVM fault diagnosis model

3.3 RELS-TSVM 参数优化

与 SVM 类似，RELS-TSVM 中高斯核参数 σ 和 $c_1, c_2, c_3, c_4, E_1, E_2$ 参数直接影响着其分类性能。为了使故障诊断模型中每个 RELS-TSVM 分类器的性能达到最优，采用鸡群算法对参数 $\sigma, c_1, c_2, c_3,$

c_4 、 E_1 、 E_2 (一般设置 $c_1 = c_2$, $c_3 = c_4$) 进行寻优, 具体的参数优化过程如下:

1) 选取样本数据构造训练集和测试集。

2) 设置相关参数并初始化鸡群各个个体的位置。相关参数包括鸡群大小 N , 鸡群中公鸡、母鸡、小鸡和母代母鸡的数目 RN 、 HN 、 CN 、 MN , 迭代次数 $Maxgen$ 。鸡群个体的位置为 5×1 的向量, 其每一维属性依次代表 σ 、 c_1 、 c_3 、 E_1 、 E_2 参数。

3) 计算鸡群中各个个体的适应值, 并初始化个体最优位置和全局最优位置。此时迭代次数 $t = 1$ 。

4) 如果 $t \% G = 1$, 对鸡群的适应值进行排序, 根据排序结果将鸡群分为若干个子群并建立鸡群的等级制度。

5) 更新公鸡、母鸡和小鸡的位置, 并计算当前各个个体所对应的适应值。

6) 更新各个个体的最优位置和全局最优位置。

7) 如果 $t \leq Maxgen$, 继续迭代, 转到步骤(4)。

否则停止迭代, 优化过程结束。

3.4 基于 RELS-TSVM 的变压器故障诊断流程

基于 RELS-TSVM 的变压器故障诊断流程主要包括 3 部分, 如图 2 所示。

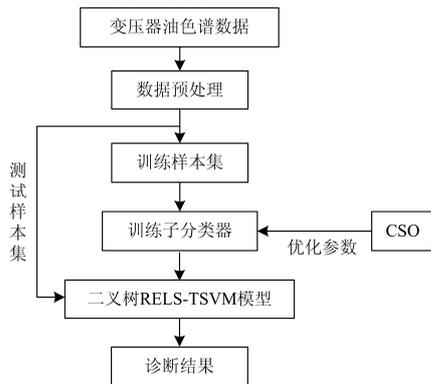


图 2 变压器故障诊断流程

Fig. 2 Fault diagnosis flow of transformer

1) 构造样本集: 采集变压器油色谱数据, 经过数据清洗和归一化处理后, 构造训练集和测试集。

2) 构建故障诊断模型: 结合 RELS-TSVM 和二叉树建立多分类模型, 利用训练集中的样本数据训练多分类二叉树模型中对应的子分类器, 并结合鸡群算法对子分类器的参数进行优化。

3) 诊断: 根据所建立的多分类故障诊断模型, 对待测样本分类, 确定其故障类型。

4 实际案例

4.1 样本数据选取

本文从贵州电科院和佛山供电公司选取了多台

主变并从其在线监测系统中提取了总共 328 组油色谱数据, 采用本文的方法进行故障诊断。从样本数据中挑选 99 组数据作为训练样本集, 剩下的 229 组数据作为测试集。各类样本统计结果如表 1 所示。各子分类器训练样本数如表 2 所示。

表 1 各类样本统计表

Table 1 Statistical table of all kinds of samples

类型	T ₁₂	T ₃	D ₁	D ₂	PD	DT	合计
训练集	20	20	20	20	9	10	99
测试集	55	64	31	59	9	11	229
总样本	75	84	51	79	18	21	328

表 2 各子分类器训练样本数

Table 2 Number of training samples of each sub classifier

分类器	C ₁	C ₂	C ₃	C ₄	C ₅
训练样本数	99	89	40	49	40

4.2 子分类器训练及其参数优化

利用各个子分类器的训练样本分别训练 RELS-TSVM 分类器, 训练过程中, 使用鸡群算法对 RELS-TSVM 的参数进行寻优。优化算法程序中相关参数设置如下: 种群规模 $N = 30$, 搜索空间维数 $dim = 5$, 最大迭代次数 $Maxgen = 250$, 公鸡比例 $R_{percent} = 20\%$, 母鸡比例 $H_{percent} = 60\%$, 母代母鸡比例 $M_{percent} = 10\%$, σ 、 c_1 、 $c_3 \in [2^{-10}, 2^{10}]$, E_1 、 $E_2 \in [0.6, 1]$ 。参数 G 决定了鸡群等级制度的更新频率, 根据经验取为 10。鸡群算法优化参数过程中适应度变化曲线如图 3 所示。各个子分类器的参数优化结果如表 3 所示。

从图 3 和表 3 中可以看出, CSO 算法优化 RELS-TSVM 参数时, 拟合度较好, 很快收敛到最优解, 并且经过优化之后, 各个子分类器均达到了很高的训练精度, 说明 CSO 算法在优化 RELS-TSVM 分类器的参数中具有很好的效果。

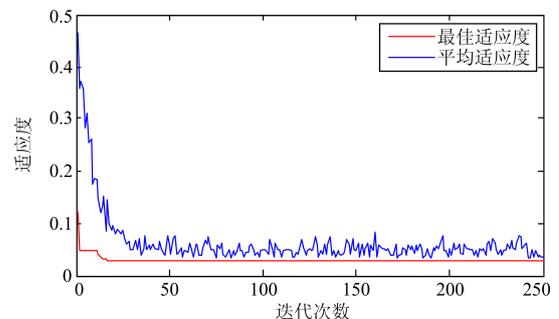


图 3 CSO 寻优过程

Fig. 3 Optimization process of CSO

表3 子分类器参数优化结果

Table 3 Optimization results of sub classifier parameter

分类器	C ₁	C ₂	C ₃	C ₄	C ₅
σ	0.0785	1.1631	0.8982	0.3156	8.7729
c_1	0.0100	12.0114	0.7879	1.8890	6.6407
c_3	0.0100	0.0100	0.0100	3.6617	0.5291
E_1	0.6000	0.7947	0.8336	0.9273	0.7173
E_2	0.9657	0.8950	0.9788	0.7090	0.9090
精度/%	97.82	97.25	95.80	97.98	96.67

4.3 故障诊断模型验证及结果对比

以各个子分类器的最优参数建立故障诊断模型,对测试样本集进行故障诊断,并将诊断结果与粒子群优化支持向量机(PSO-SVM)模型的诊断结果进行比较。在 PSO-SVM 模型中,仍采用本文中的多分类二叉树模型。两种故障诊断模型的结果比较如表 4 所示。

表4 故障诊断结果对比

Table 4 Comparison of fault diagnosis results

类型	测试集	PSO-SVM		本文方法	
		正判数	准确率/%	正判数	准确率/%
T ₁₂	55	52	94.55	52	94.55
T ₃	64	57	89.06	59	92.19
D1	31	26	83.87	27	87.10
D2	59	52	88.14	55	93.22
PD	9	7	77.78	8	88.89
DT	11	10	90.91	10	90.91
总计	229	204	89.08	211	92.14

从表 4 中可以看出,本文方法对于变压器各种典型故障类型的诊断均取得了较高的准确率,且与 PSO-SVM 方法相比,本文方法在高温过热、低能放电、高能放电和局部放电这 4 种故障类型的诊断精度上优于 PSO-SVM 方法,说明将本文方法应用于变压器故障诊断中可以取得更好的效果。

5 结论

1) 作为 LS-TSVM 的改进算法,RELS-TSVM 不仅训练速度快,鲁棒性和泛化能力也得到了很大程度的改善。本文将其应用于变压器故障诊断中,并结合多分类二叉树思想构建了基于 RELS-TSVM 的变压器多分类故障诊断模型。

2) 鸡群算法作为先天的多群算法,搜索能力较强,本文利用鸡群算法对多分类故障诊断模型中 RELS-TSVM 分类器的参数进行选取,从而建立性能最优的故障诊断模型。

3) 仿真实例表明,本文的故障诊断模型精度较高,诊断效果优于 PSO-SVM 模型,说明本文的方

法能更好地解决变压器故障诊断问题,具有更好的实用价值。

参考文献

- [1] YANG Zhiqiang. Power transformer fault diagnosis based on the SOM network combined with the BP neural network[J]. Revista Tecnica de la Facultad de Ingenieria Universidad del Zulia, 2016, 39(3): 319-326.
- [2] AZIL I H, CHAI X R. Hybrid modified evolutionary particle swarm optimization-time varying acceleration coefficient-artificial neural network for power transformer fault diagnosis[J]. Measurement: Journal of the International Measurement Confederation, 2016, 90: 94-102.
- [3] 董明, 赵文彬, 严璋. 油气分析诊断变压器故障方法的改进[J]. 高电压技术, 2002, 28(4): 66-70.
DONG Ming, ZHAO Wenbin, YAN Zhang. An improved method for transformer fault diagnosis based on DGA[J]. High Voltage Engineering, 2002, 28(4): 66-70.
- [4] ROGERS R R. IEEE and IEC codes to interpret incipient faults in transformers, using gas in oil analysis[J]. IEEE Transactions on Electrical Insulation, 1978, 13(5): 349-354.
- [5] 薛浩然, 张珂珩, 李斌, 等. 基于布谷鸟算法和支持向量机的变压器故障诊断[J]. 电力系统保护与控制, 2015, 43(8): 8-13.
XUE Haoran, ZHANG Keheng, LI Bin, et al. Fault diagnosis of transformer based on the cuckoo search and support vector machine[J]. Power System Protection and Control, 2015, 43(8): 8-13.
- [6] LI Jinzhong, ZHANG Qiaogen, WANG Ke, et al. Optimal dissolved gas ratios selected by genetic algorithm for power transformer fault diagnosis based on support vector machine[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2016, 23(2): 1198-1206.
- [7] 张珂斐, 郭江, 聂德鑫, 等. 基于化学反应优化神经网络与融合 DGA 算法的油浸式变压器模型研究[J]. 高电压技术, 2016, 42(4): 1275-1281.
ZHANG Kefei, GUO Jiang, NIE Dexin, et al. Diagnosis model for transformer fault based on CRO-BP neural network and fusion DGA method[J]. High Voltage Engineering, 2016, 42(4): 1275-1281.
- [8] 施恂山, 马宏忠, 张琳, 等. PSO 改进 RBPNN 在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2016, 44(17): 39-44.
SHI Xunshan, MA Hongzhong, ZHANG Lin, et al. Application of RBPNN improved by PSO in fault diagnosis of transformers[J]. Power System Protection and Control, 2016, 44(17): 39-44.

- [9] 白翠粉, 高文胜, 金雷, 等. 基于 3 层贝叶斯网络的变压器综合故障诊断[J]. 高电压技术, 2013, 39(2): 330-335.
BAI Cuifen, GAO Wensheng, JIN Lei, et al. Integrated diagnosis of transformer faults based on three layers Bayesian network[J]. High Voltage Engineering, 2013, 39(2): 330-335.
- [10] 吕启深, 曾辉雄, 姚森敬, 等. 基于贝叶斯网络和粗糙集约简的变压器故障诊断[J]. 中国电力, 2013, 46(9): 75-79.
LÜ Qishen, ZENG Huixiong, YAO Senjing, et al. Transformer fault diagnosis method based on Bayesian network and rough set reduction theory[J]. Electric Power, 2013, 46(9): 75-79.
- [11] 郑蕊蕊, 赵继印, 赵婷婷, 等. 基于遗传支持向量机和灰色人工免疫算法的电力变压器故障诊断[J]. 中国电机工程学报, 2011, 31(7): 56-63.
ZHENG Ruirui, ZHAO Jiyin, ZHAO Tingting, et al. Power transformer fault diagnosis based on genetic support vector machine and gray artificial immune algorithm[J]. Proceedings of the CSEE, 2011, 31(7): 56-63.
- [12] 苑津莎, 张利伟, 李中, 等. 基于互补免疫算法的变压器故障诊断[J]. 电工技术学报, 2015, 30(24): 67-75.
YUAN Jinsha, ZHANG Liwei, LI Zhong, et al. Fault diagnosis of transformers based on complementary immune algorithm[J]. Transactions of China Electrotechnical Society, 2015, 30(24): 67-75.
- [13] KUMAR M A, GOPAL M. Least squares twin support vector machines for pattern classification[J]. Expert Systems with Applications, 2009, 36(4): 7535-7543.
- [14] NASIRI J A, CHARKARIN N M, MOZAFARI K. Energy-based model of least squares twin support vector machines for human action recognition[J]. Signal Processing, 2014, 104(6): 248-257.
- [15] TANVEER M, KHAN M A, HO S S. Robust energy-based least squares twin support vector machines[J]. Applied Intelligence, 2016, 45(1): 174-186.
- [16] 刘尚旺, 段德全, 崔艳萌, 等. 二次定位车牌分割及识别方法[J]. 河南师范大学学报(自然科学版), 2016, 44(4): 151-156.
LIU Shangwang, DUAN Dequan, CUI Yanmeng, et al. Vehicle license plate segmentation and recognition method based on two times locations[J]. Journal of Henan Normal University (Natural Science Edition), 2016, 44(4): 151-156.
- [17] MENG X, LIU Y, GAO X, et al. A new bio-inspired algorithm: chicken swarm optimization[J]. Springer International Publishing, 2014, 8794: 86-94.
- [18] IBRAHEM H A. An innovative approach for feature selection based on chicken swarm optimization[C] // Proceedings of the 2015 7th International Conference of Soft Computing and Pattern Recognition, 2015, 75(2): 269-279.
- [19] 许仪勋, 李旺, 李东东, 等. 基于改进鸡群算法的非侵入式家电负荷分解[J]. 电力系统保护与控制, 2016, 44(13): 27-32.
XU Yixun, LI Wang, LI Dongdong, et al. Disaggregation for non-invasive domestic appliances based on the improved chicken swarm optimization algorithm[J]. Power System Protection and Control, 2016, 44(13): 27-32.

收稿日期: 2016-10-20; 修回日期: 2017-01-03

作者简介:

陈欢(1992—), 男, 硕士, 研究方向为输变电设备故障诊断; E-mail: 1554682589@qq.com

彭辉(1975—), 男, 通信作者, 博士研究生, 副教授, 主要研究方向为电气设备在线监测与故障诊断。E-mail: hpeng@whu.edu.cn

(编辑 葛艳娜)