

DOI: 10.19666/j.rlfed.202208175

绝缘油 ISMA-SVM 法含气监测应用

杨 昭, 刘 冲, 杨嘉蕾, 张 灏, 寇 林
(西安热工研究院有限公司, 陕西 西安 710054)

[摘 要] 对于变压器绝缘油含气 (DGA) 故障诊断识别准确率低问题, 利用反向学习策略对黏菌算法 (SMA) 改进形成 ISMA 算法, 提升全局寻优能力, 并优化支持向量机 (SVM), 建立 ISMA-SVM 优化故障诊断模型, 用样本集进行学习训练。将诊断识别结果与灰狼算法 GWO-SVM 和粒子群算法 PSO-SVM 优化模型进行对比, ISMA-SVM 故障诊断识别准确率为 93.3%, 相比 GWO-SVM、PSO-SVM 分别提高了 6.66 百分点、10.66 百分点。

[关 键 词] 绝缘油; 含气故障; 黏菌算法; 支持向量机; 诊断识别

[引用本文格式] 杨昭, 刘冲, 杨嘉蕾, 等. 绝缘油 ISMA-SVM 法含气监测应用[J]. 热力发电, 2023, 52(1): 165-169. YANG Zhao, LIU Chong, YANG Jialei, et al. Application of ISMA-SVM method in monitoring of gas content in insulating oil[J]. Thermal Power Generation, 2023, 52(1): 165-169.

Application of ISMA-SVM method in monitoring of gas content in insulating oil

YANG Zhao, LIU Chong, YANG Jialei, ZHANG Hao, KOU Lin
(Xi'an Thermal Power Research Institute Co., Ltd., Xi'an 710054, China)

Abstract: To solve the problem of low recognition accuracy of transformer insulation oil gas fault diagnosis, the slime mold algorithm (SMA) is improved by the reverse learning strategy to form the improved slime mold algorithm (ISMA), thus to improve the global optimization ability and optimize the support vector machine (SVM). An ISMA-SVM optimized fault diagnosis model is established, and the sample set is used for learning and training. The diagnosis and recognition results are compared with that of the greywolf algorithm (GWO-SVM) and the particle swarm optimization (PSO-SVM), it shows that the accuracy of the ISMA-SVM fault diagnosis and recognition is 93.3%, which is 6.66 and 10.66 percentage points higher than that of the GWO-SVM and PSO-SVM, respectively.

Key words: insulating oil; gas fault; slime mold algorithm; support vector machine; diagnostic identification

变压器油在运行中会产生各种气体, 其在油液中的溶解量及状态直接关系到变压器安全运行。因气体分析取样方便, 检测易行, 且不受外界电磁场的影响, 已成为绝缘油含气故障监测通用手段^[1]。油中气体分析 (dissolved gas analysis, DGA) 故障诊断要考虑多种气体相互作用, 与之对应各种变压器故障状态。多采用三比值法、改良三比值法、关键气体法等进行判断, 但故障特征分类效果并不理想^[2]。油中各种气体含量为故障源, 各种故障形式为故障果。源与果对应历史数据构成故障起因识别样本, 对机器识别系统进行学习训练, 可提升故障监测识别准确率和自动化程度。

常见机器识别系统如模糊聚类^[3-4]、神经网络^[5-6]、支持向量机^[7-8]、极限学习机^[9]、贝叶斯网络^[10-11]等, 与 DGA 相结合的诊断模型虽能够提升变压器故障诊断准确率, 但也存在一些缺陷, 精度提高空间有限。比如神经网络算法即使有很强的学习能力, 但其在模型训练时需要很大的训练样本, 训练速度也比较慢; 贝叶斯网络训练属于不确定多项式, 在解决复杂问题时相当困难; 模糊聚类算法中隶属函数的构建设没有确定的标准, 降低了其实用性; 极限学习机等传统智能算法通常在寻优过程中也容易陷入局部最优点。

绝缘油含气故障机器识别工作起步较晚, 样本

收稿日期: 2022-08-12 网络首发日期: 2023-01-02

基金项目: 中国华能集团有限公司总部科技项目 (HNKJ22-H36)

Supported by: Science and Technology Project of China Huaneng Group Co., Ltd. (HNKJ22-H36)

第一作者简介: 杨昭 (1996), 男, 硕士, 主要研究方向为大型火电机组启动调试和故障分析, 1986560740@qq.com。

数量有限,通常采用支持向量机(support vector machine, SVM)监督式学习方法进行训练,通过核函数间接实现非线性分类和函数逻辑回归,解决小样本分类问题。SVM性能取决于核函数参数和惩罚因子,可由智能算法实现优化。已有采用灰狼(greywolf optimizer, GWO)算法优化成 GWO-SVM,和粒子群(particelswarm optimization, PSO)算法优化 PSO-SVM,对小样本分类问题取得了一定效果。黏菌算法^[12-13](slime mould algorithm, SMA)为元启发算法,收敛速度快、寻优能力强,有望避免陷入局部最优困境。本文将 SMA 优化成 ISMA(improved slime mould algorithm),构成 ISMA-SVM,以历史样本集进行学习训练,并与 GWO-SVM 和 PSO-SVM 对比,探究其诊断准确性。

1 SMA 及 SVM 算法

1.1 SMA

SMA 根据黏菌个体的振荡捕食行为提出,可根据空气中食物气味的浓度来接近食物,在各种食物间构成静脉网络。食物浓度高,静脉振荡强,网络宽,黏菌群体聚集;浓度低,网络窄,则转向其他方向探索。黏菌接近食物模型为:

$$X(t+1) = \begin{cases} X_b(t) + v_b \cdot (W \cdot X_A(t) - X_B(t)), & r < p \\ v_c \cdot X(t) & , r \geq p \end{cases} \quad (1)$$

$$W(SI_{(i)}) = \begin{cases} 1 + r \times \lg((bF - S_{(i)} / bF - wf) + 1), & i = C \\ 1 - r \times \lg((bF - S_{(i)} / bF - wf) + 1), & i = O \end{cases} \quad (2)$$

式中: t 为当前迭代次数; $X_b(t)$ 为最优个体位置; $X_A(t)$ 、 $X_B(t)$ 为第 t 次迭代时随机两个个体位置; W 为适应度权重; v_b 、 v_c 为控制参数; $r \in \text{rand}[0,1]$ 可任意方向搜索,在解空间内探求最优解; bF 和 wf 为当前迭代最优、最差适应度; $i=C$ 为适应度较优个体, $i=O$ 代表其余个体; $SI_{(i)}$ 为适应度排序,以浓度指数表征。

其中, $v_b \in [-a, a]$ 为 v_c 从 1 下降到 0, $r \in \text{rand}[0,1]$ 。控制变量 p 和参数 a 模型为:

$$p = \tan h |S_{(i)} - DF| \quad (3)$$

$$a = \arctan h(-(t/t_{\max})+1)$$

式中: $i \in 1, 2, 3, \dots, n$; $S_{(i)}$ 为当前个体适应度值; DF 为最佳适应度值; t_{\max} 为最大迭代次数。

黏菌算法具有不满足性,即使在浓度较高食物源位置聚集后,依然会分离个体,去探求更高浓度的食物源。黏菌种群位置更新可表述为:

$$X(t+1) = \begin{cases} \text{rand} \cdot (\text{UB} - \text{LB}) + \text{LB} & , \text{rand} < z \\ X_b(t) + v_b \cdot (W \cdot X_A(t) - X_B(t)), & r < p \\ v_c \cdot X(t) & , r \geq p \end{cases} \quad (4)$$

式中: UB 和 LB 为搜索域上下界; rand 为 $[0,1]$ 之间随机数; z 为自定义参数,这里设为 0.03。

反向学习^[14](opposition based learning, OBL)可拓宽搜索空间,采用概率优化筛选,避免陷入局部优弊端。即在寻优过程中,从当前群体中生成反向个体,通过适应度值对比,以更优个体进行下次迭代,丰富种群多样性,加速收敛,提升跳出局部能力。生成反向个体位置 X_{ij} 可表示为:

$$X_{ij}^*(t) = k_1(a_j(t) + k_2 b_j(t)) - X_{ij}(t) \quad (5)$$

$$a_j(t) = \min(X_{ij}(t)), b_j(t) = \max(X_{ij}(t))$$

式中: k_1 、 $k_2 \in \text{rand}(0,1)$ 为更优个体相对原种群位置。

1.2 SVM 算法

标准 SVM 算法为二分线性模型,以构建最优超平面实现分类。变压器故障诊断分类属于非线性多分类,不宜用线性 SVM 算法处理,需用核函数将低维空间数据变换为高维空间后,再对低维空间进行线性化,寻找最优分类面^[15-16]。

采用一对一多分类 SVM 法对变压器油含气故障进行诊断,模式简单,故障类别少,有望在不增大运算量前提下,保证分类准确性。

SVM 核函数变换非线性变化,目标函数可表述为:

$$\min \phi(w) = \frac{1}{2} \|w\|^2 = \frac{1}{2} \langle w \cdot w \rangle + c \sum_{i=1}^n \xi_i^2 \quad (6)$$

$$\text{s.t. } y_i [\langle w \cdot x_i \rangle + b] - 1 + \xi_i \geq 0 \quad (7)$$

式中: w 为权重向量; c 为惩罚因子; ξ 为偏置误差; x_i 为样本向量; b 为偏置量。

引入核函数 $K(x_i, x_j)$ 后,转化成:

$$\min Q(\alpha) = \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^n \alpha_i \quad (8)$$

$$\text{s.t. } \alpha_i \geq 0 \quad i = 1, 2, \dots, n$$

$$\sum_{i=1}^n y_i \alpha_i = 0$$

其中,分类函数可表述为:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^n \alpha_i^* y_i K(x_i, x) + b^* \right\} \quad (9)$$

径向基函数(radial basis function, RBF)为局部核函数,体现数据间半径,有效筛除干扰,具有明显分类优势。当用 RBF 为 SVM 核函数时,其表达式为:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (10)$$

式中： γ 为 RBF 核函数比例参数，决定其作用径向范围。

2 ISMA-SVM 故障诊断模型

2.1 ISMA-SVM

SVM 分类性能取决于惩罚因子 c 和核参数 γ ，本文通过 ISMA 对 c 和 γ 寻优，其故障诊断模型建立流程如图 1 所示。

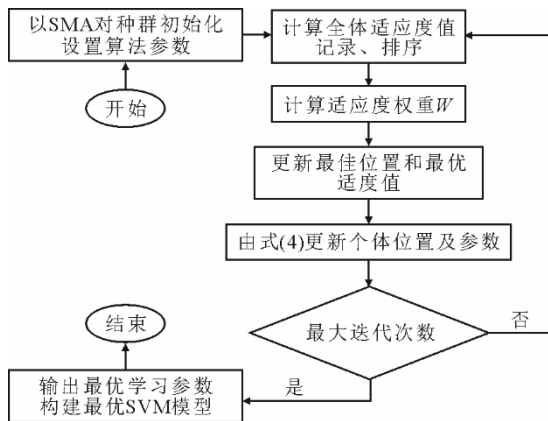


图 1 故障诊断流程
Fig.1 Flow chart of fault diagnosis

ISMA-SVM 算法步骤如下：

- 1) 设置算法，种群规模 N ，迭代次数 T_{max} ；
- 2) 位置初始化，生成黏菌，及其参数 c 和 γ ；
- 3) 获取黏菌个体适应度值，记录并排序，筛选最优及最差个体；
- 4) 通过式(2)计算适应度权重 W ；
- 5) 更新黏菌最优位置及适应度，形成新黏菌；
- 6) 通过式(4)更新黏菌个体位置及参数；
- 7) 判断是否达到 T_{max} ：达到，确认最佳位置；未达到，跳至 3) 继续迭代；
- 8) 输出最佳黏菌位置及最优适应度；
- 9) 提取最优 c 和 γ ，构建 SVM 诊断模型；
- 10) 对故障特征样本进行分类诊断。

2.2 故障特征提取和量化

变压器运行过程中会产生多种气体，不同运行状态下各气体成分含量存在差异。考虑故障诊断模型简单及高效可行，这里仅选取 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 为 5 种代表性气体，所反映为正常、低能放电、高能放电、中低温过热、高温过热 5 种故障状态类型，用 0—4 编号表示，故障数据见表 1。由表 1 可见，不同故障类型所溶解各种气体体积分

数数量等级不同。为使故障模型更加精确，在输入模型前，需对数据归一化处理。

表 1 油中溶解气体部分故障数据
Tab.1 Fault data of the dissolved gas in oil

序号	特征气体体积分数/($\mu L \cdot L^{-1}$)					故障类型
	H_2	CH_4	C_2H_6	C_2H_4	C_2H_2	
1	2.0	1.5	0.6	0.7	0.5	正常 (0)
2	49.0	12.0	0.3	4.0	4.8	低能放电 (1)
3	128.0	106.5	11.5	153.0	223.0	高能放电 (2)
4	21.5	135.7	140.1	310.3	0	中低温过热 (3)
5	279.0	487.0	109.0	708.0	4.4	高温过热 (4)

3 ISMA-SVM 的变压器故障诊断

3.1 故障样本选择

参考国家电网下属某西北电网提供数据，以及文献^[17]中所采用数据，舍弃部分奇异样本，构成由 200 组溶解气体与故障对应的样本库，其中 125 组作为训练集，75 组作为验证测试集，样本数据分配见表 2。

表 2 数据集分配
Tab.2 The data set allocation

故障类型	训练集	测试集	总数据
正常	25	15	40
低能放电	25	15	40
高能放电	25	15	40
中低温过热	25	15	40
高温过热	25	15	40

3.2 基于 ISMA-SVM 模型的故障诊断

将经归一化处理后的数据输入 ISMA-SVM 故障诊断模型，设黏菌种群数量 $N=20$ ，最大迭代次数 $T_{max}=100$ ，惩罚因子 c 和核参数 γ 取值区间为 0.01~100，诊断结果如图 2 所示。由图 2 可知，经 SVM 模型的参数寻优后，故障诊断准确率达到了 93.3%，具有很好的故障诊断性能。

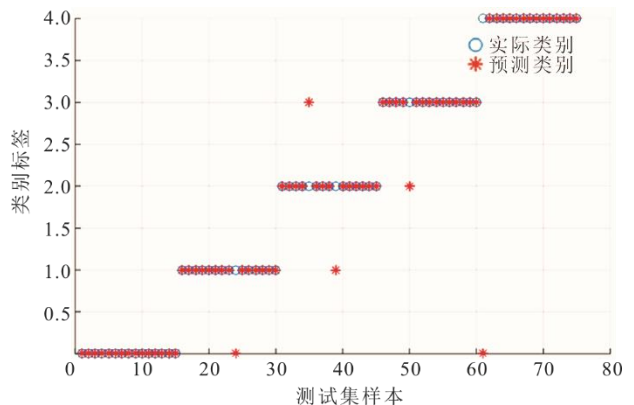


图 2 ISMA-SVM 故障诊断结果
Fig.2 Fault diagnosis results of the ISMA-SVM

3.3 多模型诊断结果对比

为验证用 ISMA 算法训练 SVM 优势, 这里与 GWO 优化 SVM 和 PSO 优化 SVM 故障诊断模型进行对比, 其结果如图 3、图 4 所示。

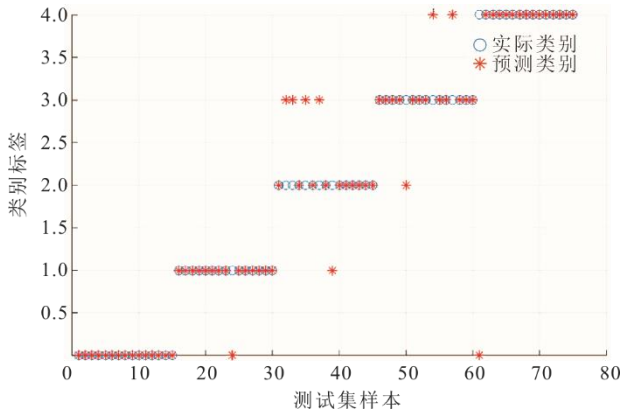


图 3 GWO-SVM 故障诊断结果
Fig.3 Fault diagnosis results of the ISMA-SVM




图 4 PSO-SVM 故障诊断结果
Fig.4 Fault diagnosis results of the PSO-SVM

由图 2、图 3 和图 4 可见, 对于同故障样本集, 故障分类诊断错误个数存在不同, PSO-SVM 为 13 个, GWO-SVM 为 10 个, ISMA-SVM 仅为 5 个, 明显失误率较低。各模型算法所对应各种故障分类正确率, 对比数据见表 3。

表 3 各模型故障分类对比 单位: %
Tab.3 Comparison of fault classification of each model

故障类型	正确率		
	PSO-SVM	GWO-SVM	ISMA-SVM
正常	100.00	100.00	100.00
低能放电	80.00	93.33	93.33
高能放电	73.33	73.33	86.67
中低温过热	80.00	80.00	93.33
高温过热	80.00	93.33	93.33
总正确率	82.67	86.67	93.33

由表 3 可见: 对于正常状态诊断识别准确率, 3 种模型均为 100%, 但对于高能放电, ISMA-SVM 模型准确率比 PSO-SVM 和 GWO-SVM 提高 13.34 百分点。

由于 ISMA 算法全局寻优得以提升, 整体故障识别诊断准确率比 PSO 算法提高 10.66 百分点, 比 GWO 算法提高 6.66 百分点, 可见 ISMA-SVM 模型诊断识别性能具有明显优势。

4 结 论

本文采用 ISMA-SVM 对变压器油含气故障诊断模型进行优化, 得出以下结论。

1) ISMA-SVM 与 GWO-SVM 和 PSO-SVM 相比, 对比 GWO-SVM 诊断率为 86.67%, PSO-SVM 的诊断率为 82.67%, ISMA-SVM 诊断率达到 93.33%, 在收敛更快的同时, 能够有效提高变压器故障诊断准确率。

2) ISMA-SVM 诊断模型具有很强泛化性, 不限于变压器油含气故障监测诊断, 也可用于其他领域故障分类, 具有一定工程实际意义。

[参 考 文 献]

[1] 沙伟燕, 李秀广, 何宁辉, 等. 基于油色谱时频域信息和残差注意网络的变压器故障诊断方法[J]. 电网与清洁能源, 2022, 38(1): 66-75.
SHA Weiyan, LI Xiuguang, HE Ninghui, et al. Transformer fault diagnosis method based on oil chromatography time-frequency domain information and residual attention network[J]. Power System and Clean Energy, 2022, 38(1): 66-75.

[2] 荣智海, 齐波, 李成榕, 等. 面向变压器油中溶解气体分析的组合 DBN 诊断方法[J]. 电网技术, 2019, 43(10): 3800-3808.
RONG Zhihai, QI Bo, LI Chengrong, et al. Combined DBN diagnostic method for dissolved gas analysis of power transformer oil[J]. Power System Technology, 2019, 43(10): 3800-3808.

[3] 李恩文, 王力农, 宋斌, 等. 基于混沌序列的变压器油色谱数据并行聚类分析[J]. 电工技术学报, 2019, 34(24): 5104-5114.
LI Enwen, WANG Linong, SONG Bin, et al. Parallel cluster analysis of dissolved of gas analysis data based on chaotic sequence[J]. Journal of Electrotechnical Technology, 2019, 34(24): 5104-5114.

[4] 史丽萍, 宋朝鹏, 李明泽, 等. 基于 SAAFSA 优化加权模糊聚类算法的变压器故障诊断[J]. 电测与仪表, 2018, 55(11): 12-18.
SHI Liping, SONG Chaopeng, LI Mingze, et al. Transformer fault diagnosis based on weighted fuzzy clustering algorithm improved by SAAFSA[J]. Electrical Measurement & Instrumentation, 2018, 55(11): 12-18.

[5] 何宁辉, 沙伟燕, 胡伟, 等. 基于 QIA-BP 神经网络算法的变压器故障诊断[J]. 变压器, 2021, 58(3): 50-56.

- HE Ninghui, SHA Weiyang, HU Wei, et al. Transformer fault diagnosis based on QIA-BP neural network algorithm[J]. Transformers, 2021, 58(3): 50-56.
- [6] 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 Lingling, WANG Qunjing, CHEN Quan, et al. Transformer fault diagnosis based on IBBOA optimal BP neural network[J]. New Technology of Electrical Engineering, 2021, 40(9): 39-46.
- [7] 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 Huangman, ZHANG Yong, ZHANG Yao. Study of transformer fault diagnosis based on improved sparrow-W search algorithm optimized support vector machine[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(3): 123-129.
- [8] 单亚峰, 段金凤, 付华, 等. 基于 SSA-Ada Boost-SVM 的变压器故障诊断[J]. 控制工程, 2022, 29(2): 280-286.
- SHAN Yafeng, DUAN Jinfeng, FU Hua, et al. Transformer fault diagnosis based on SSA-Ada Boost-SVM[J]. Control Engineering, 2022, 29(2): 280-286.
- [9] 郝玲玲, 朱永利, 王永正. 基于 DCAE-KSSELM 的变压器故障诊断方法[J]. 中国电力, 2022, 55(2): 125-130.
- HAO Lingling, ZHU Yongli, WANG Yongzheng. Transformer fault diagnosis method based on DCAE-KSSELM[J]. Electric Power, 2022, 55(2): 125-130.
- [10] 朱保军, 咸日常, 范慧芳, 等. WRSR 与改进朴素贝叶斯融合的变压器故障诊断技术研究[J]. 电力系统保护与控制, 2021, 49(20): 120-128.
- ZHU Baojun, XIAN Shili, FAN Huifang, et al. Transformer fault diagnosis technology based on the fusion of WRSR and improved naive Bayes[J]. Power System Protection and Control, 2021, 49(20): 120-128.
- [11] 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.
- TONG Zhaojing, QIAO Zhengrui, LI Jinxiang, et al. Transformer fault diagnosis based on MPC algorithm optimized Bayesian network[J]. Electronic Measurement Technology, 2021, 44(17): 41-45.
- [12] 刘成汉, 何庆. 改进交叉算子的自适应人工蜂群黏菌算法[J]. 小型微型计算机系统, 2021, 11(6): 1-8.
- LIU Chenghan, HE Qing. Adaptive artificial bee colony slime mold algorithm with improved crossover operator[J]. Small Microcomputer System, 2021, 11(6): 1-8.
- [13] 郭雨鑫, 刘升, 张磊, 等. 精英反向与二次插值改进的黏菌算法[J]. 计算机应用研究, 2021, 38(12): 3651-3656.
- GUO Yuxin, LIU Sheng, ZHANG Lei, et al. Elite opposition-based learning quadratic interpolation slime mould algorithm[J]. Computer Application Research, 2021, 38(12): 3651-3656.
- [14] 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 Guomin, NI Leshui. Transformer fault diagnosis based on an artificial bee colony-support vector machine optimization algorithm[J]. Power System Protection and Control, 2020, 48(15): 156-163.
- [15] 魏鹏飞, 樊小朝, 史瑞静, 等. 基于改进麻雀搜索算法优化支持向量机的短期光伏发电功率预测[J]. 热力发电, 2021, 50(12): 74-79.
- WEI Pengfei, FAN Xiaochao, SHI Ruijing, et al. Short-term photovoltaic power generation forecast based on improved sparrow search algorithm optimized support vector machine[J]. Thermal Power Generation, 2021, 50(12): 74-79.
- [16] 马骏, 江锐, 丁倩, 等. 基于多元宇宙优化支持向量机的短期光伏发电功率预测[J]. 热力发电, 2020, 49(4): 87-92.
- MA Jun, JIANG Rui, DING Qian, et al. Prediction of short-term photovoltaic generation power based on HIMVO-SVM[J]. Thermal Power Generation, 2020, 49(4): 87-92.
- [17] 张婷婷. 基于人工蜂群-支持向量机优化算法的变压器故障诊断[D]. 阜新: 辽宁工程技术大学, 2019: 1.
- ZHANG Tingting. Transformer based on artificial bee colony-support vector machine optimization algorithm trouble shooting[D]. Fuxin: Liaoning University of Engineering and Technology, 2019: 1.

(责任编辑 杨嘉蕾)