

DOI: 10.7667/PSPC160081

PSO改进RBPNN在变压器故障诊断中的应用

施恂山¹, 马宏忠¹, 张琳¹, 李凯², 许洪华², 陈冰冰²

(1. 河海大学能源与电气学院, 江苏 南京 211100; 2. 江苏省电力公司南京供电公司, 江苏 南京 210008)

摘要: 针对概率神经网络(PNN)及遗传算法(GA)在变压器内部故障诊断中存在的不足, 提出了一种基于粒子群算法(PSO)改进径向基概率神经网络(RBPNN)的故障诊断方法。首先, 引入RBPNN, 选取反向传播作为学习算法以及油中溶解气体含量比值作为故障特征量。然后, 由于该模型受网络结构和初值影响较大, 故拟用GA、PSO和改进的PSO对网络优化并测试。通过对比分析, 得出改进的PSO在确定拓扑结构、降低误差精度、加快收敛速度和提高预测准确度上更占优势的结论, 同时证明了所提方法在故障诊断中的正确性和可行性。

关键词: 粒子群算法; 径向基概率神经网络; 反向传播; 变压器; 故障诊断

Application of RBPNN improved by PSO in fault diagnosis of transformers

SHI Xunshan¹, MA Hongzhong¹, ZHANG Lin¹, LI Kai², XU Honghua², CHEN Bingbing²

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China;

2. Nanjing Power Supply Company, Jiangsu Electric Power Company, Nanjing 210008, China)

Abstract: Aiming at the existing deficiencies of probabilistic neural network (PNN) and genetic algorithm (GA) in internal faults of transformers, a fault diagnosis method based on radial basis probabilistic neural network (RBPNN) improved by particle swarm optimization (PSO) is proposed. Firstly, this paper introduces RBPNN and selects back-propagation as the learning algorithm as well as the content ratio of dissolved gases in oil as the characteristic quantity of fault. Then, since the network structure and the initial value have a great impact on RBPNN, this model is optimized and tested with GA, PSO and improved PSO. The comparison results show that improved PSO has more advantages in determining topology, decreasing error accuracy, accelerating the convergence speed and improving prediction accuracy, which also verify the correctness and feasibility of the proposed method in fault diagnosis.

This work is supported by National Natural Science Foundation of China (No. 51577050) and Science and Technology Project of Jiangsu Province Electric Power Company (No. J2014055).

Key words: PSO; RBPNN; back propagation; power transformer; fault diagnosis

0 引言

随着电网容量的不断扩大, 电力系统的核心设备之一——电力变压器, 其电压和容量也不断增大, 当发生内部故障, 产生的负面影响更大^[1]。因此, 为了整个电网的安全运行, 对变压器运行状态及其早期潜伏性故障进行监测和判断, 已经引起了相关电力系统部门的高度重视。

目前, 油中溶解气体分析法(DGA)是对变压器内部故障诊断相对比较有效的一种方法, 而其三比值法的固有缺点是存在编码边界过于绝对且编码不

全的现象^[2]。日本电气协同研究会提出的电协研法^[3]对IEC编码进行了补充, 故障判断准确率得到了一定的提升, 但其诊断精度仍有待进一步的提高。近几年, 国内外研究学者应用人工神经网络^[4-6]、支持向量机^[7]、深度信念网络^[8]和模糊理论^[9]等建立相应模型, 结合油中溶解气体特征量对变压器故障进行诊断探索, 取得了一定的成效。其中, 以人工神经网络研究较多, 成效显著。文献[6]利用遗传算法对概率神经网络中的平滑因子进行优化, 提高了变压器故障诊断准确率。但是, 一方面由隐节点输出结果可以看出, 概率神经网络(PNN)没有考虑不同类别模式间的交错影响, 即未考虑样本的总体分布。另一方面遗传算法采用二进制优化网络参数, 需要编码和解码, 过程复杂; 变异和交叉步骤中的许多

基金项目: 国家自然科学基金项目(51577050); 江苏省电力公司科技项目(J2014055)

参数与诊断结果有直接联系, 却只能靠经验设置。因而, 故障准确率和网络训练速度进一步提高受到限制。文献[10-11]以径向基函数网络(RBFNN)的整体性能较好, 弥补 PNN 的缺陷, 提出了一种新的神经网络模型-径向基概率神经网络(RBPNN), 从理论和实例验证了其在模式识别问题上的可行性。而启发式粒子群算法在速度迭代过程中, 省去了交叉和变异操作, 相对编程实现更为简单; 与遗传算法相比, 所有粒子寻优是跟随当前最优粒子, 而不是整个种群以比较均匀的速度向最优解区域移动, 相对到达最优解位置时间更短。

因此, 本文提出了一种基于粒子群算法(PSO)改进径向基概率神经网络(RBPNN)诊断变压器故障的方法。经测试, 该方法能够对变压器常见内部故障准确分类, 同时拥有较好的鲁棒性。

1 RBPNN 模型

1.1 RBPNN 结构原理

径向基概率神经网络(RBPNN)^[10-11]是一种结合 RBFNN 和 PNN 各自优点而产生的神经网络模型, 分别由输入层、第 1 隐层、第 2 隐层和输出层构成, 如图 1 所示。设输入层节点个数为 p , 其大小由反应问题本质的特征量决定; 第 1 隐层节点个数为 m , 其大小决定网络结构是否最优; 第 2 隐层节点个数与输出层个数都为 n , 其大小由需判别的模式类别决定。对于 N 个学习样本 $(\mathbf{X}, \bar{\mathbf{Y}})$, \mathbf{X} 是输入向量 $\mathbf{X}=[x_1, x_2, \dots, x_p]^T$, 网络期望输出向量 $\bar{\mathbf{Y}}=[\bar{y}_1, \bar{y}_2, \dots, \bar{y}_n]^T$ 。每层神经元具体描述如下:

a) 输入层-可任选 RBFNN 或 PNN 的输入层;

b) 第 1 隐层-选择 RBFNN 的隐层作为当前层, 隐层中第 i 个神经元的输入表示为

$$s_i = \exp\left[-\frac{(\mathbf{X} - \mathbf{u}_i)^T (\mathbf{X} - \mathbf{u}_i)}{2\sigma_i^2}\right], \quad i=1, 2, \dots, m \quad (1)$$

式中: \mathbf{u}_i 为第 i 个神经元的中心因子; σ_i 为第 i 个神经元的宽度因子。由文献[12]可知, 当中心因子 \mathbf{u}_i 确定后, 宽度 σ_i 可由式(2)得出。

$$\sigma_i = d_{i\max} / \sqrt{2m} \quad (2)$$

式中, $d_{i\max}$ 为当前神经元中心与其他神经元中心的最大距离。

c) 第 2 隐层-选择 PNN 的求和层作为当前层, 隐层第 j 个神经元的输入表示为

$$S_j = \lambda_j \sum_{i=1}^{m_j} s_i, \quad j=1, 2, \dots, n \quad (3)$$

式中: λ_j 为故障类别 j 的先验概率等于 N_j/N (N_j 为故障模式 j 的训练样本数); m_j 为第 j 个故障类别节点

连接数, 大小等于 $\text{INT}(\lambda_j \times m)$, 其中 $m=m_1+m_2+\dots+m_n$ 。

d) 输出层-选择 RBFNN 的线性求和层作为当前层, 采用 sigmoid 作为激活函数。其中第 k 个神经元的输出表示为

$$y_k = f\left(\sum_{j=1}^n \omega_{jk} S_j\right), \quad k=1, 2, \dots, n \quad (4)$$

式中: ω_{jk} 表示第 2 隐层第 j 个神经元与输出层第 k 个神经元连接权; $f(v)=1/(1+e^{-v})$ 。

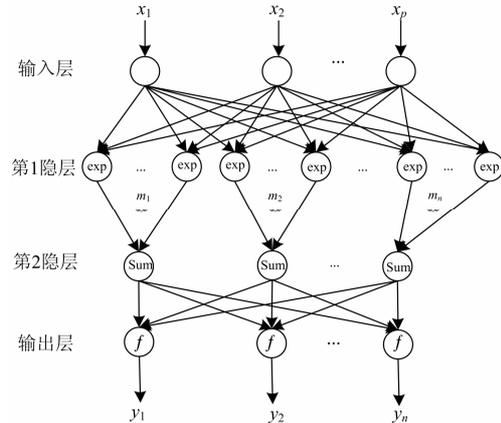


图 1 RBPNN 结构原理图

Fig. 1 Structure diagram of RBPNN

1.2 适应度函数

由上述分析可知, 对于 N 个样本数据, 此类网络均方误差可由式(5)表示为

$$E = \frac{1}{N} \sum_{l=1}^N \sum_{k=1}^n (\bar{y}_{l,k} - y_{l,k})^2 \quad (5)$$

式中: $\bar{y}_{l,k}$ 表示训练第 l 个样本, 第 k 个输出神经元的理想输出值; $y_{l,k}$ 表示训练第 l 个样本, 第 k 个输出神经元的实际输出值。

因此, 把式(5)作为适应度函数, 即当误差越小时, 网络性能越优。

1.3 网络学习算法

本网络模型采用成熟的反向传播算法, 根据网络预测输出和期望输出的误差, 通过修正公式从而更新网络模型的特征参数 $\pi = \{u_i, \omega_{jk}\}$ 。但此算法易陷入局部最小、对初值要求较高。第 1 隐层的节点个数只能通过“运气”选取, 多次尝试后才能得到较优的网络拓扑结构。因而, 本文引入全局优化能力较强、算法简单及收敛速度迅速的粒子群算法, 对网络的结构和初值进行确定。

1.4 隐层节点数确定方法

在特征参数 $\pi = \{u_i, \omega_{jk}\}$, 加入一个网络结构变量 $g_i \in [0, 1]$, 其值大小越接近 1 代表第 1 隐层中第

i 个神经元存在的可能性越大。实践表明, 当 $g_i \geq 0.65$ 时可以认为该神经元存在, 反之亦然^[13]。

2 PSO 和诊断流程

2.1 PSO 及改进

粒子群算法(PSO)^[14]是一种通过模拟鸟群起飞时信息相互交互过程(学习和模仿)的智能优化算法。首先, 在一个 D 维的解空间, 对鸟群中的 n 只鸟(通常称为“粒子”)进行初始化, 其中每个粒子代表着问题的一个潜在解, 其优劣程度通过式(5)适应度函数来表示。第 i 个粒子的位置和速度分别如式(6)、式(7)表示; 其对应个体极值和种群极值由式(8)、式(9)表示。

$$X_i = (X_{i1}, X_{i2}, \dots, X_{iD}) \quad (6)$$

$$V_i = (V_{i1}, V_{i2}, \dots, V_{iD}) \quad (7)$$

$$P_i = (P_{i1}, P_{i2}, \dots, P_{iD}) \quad (8)$$

$$P_g = (P_{g1}, P_{g2}, \dots, P_{gD}) \quad (9)$$

在每次迭代过程中, 第 i 个粒子通过个体极值和种群极值更新自身第 d 维的速度和位置, 更新公式如式(10)、式(11)。

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 rand_1 (P_{id}^k - X_{id}^k) + \quad (10)$$

$$c_2 rand_2 (P_{gd}^k - X_{id}^k)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (11)$$

式中: ω 为惯性权重, 其值大小影响粒子全局和局部搜索能力, 通常取在[0.8, 1.2]; c_1, c_2 为加速度因子, 分别控制飞向最优个体和群体的距离, 设置为 2.5; $rand_1, rand_2$ 为分布于[0, 1]之间的随机数。

经验表明, 上述优化算法在训练网络结构和特征参数时, 具有收敛速度迅速、通用性强的特点, 但同时也存在着容易早熟、后期迭代效率不高等缺陷。为此, 本文通过对算法关键参数-惯性权重(ω)、加速度因子(c_1, c_2)进行修改, 并引入变异算子, 使得算法兼具前期全局和后期局部的寻优能力。具体体现在:

a) 有学者提出了一种线性递减的惯性权重因子^[15], 然而迭代后期, ω 的减小会使粒子陷入局部最优, 为此本文采用一种线性微分递减策略, 化简后的计算公式为

$$\omega_k = \omega_{\max} - (\omega_{\max} - \omega_{\min}) (k/T_{\max})^2 \quad (12)$$

式中: ω_{\max} 为惯性权重最大值, 本文选择 0.9; ω_{\min} 为惯性权重最小值, 选择 0.4; k 代表当前迭代次数; T_{\max} 代表迭代总数。

b) 学习因子 c_1 和 c_2 的大小决定了粒子间信息交流的能力, 通常其和大于 4。本文采用线性调整

学习因子的策略, 原理简单、编程方便且应用效果较好。变换公式如下:

$$c_1 = 2.5 - 1.5k/T_{\max} \quad (13)$$

$$c_2 = 1 + 1.5k/T_{\max} \quad (14)$$

c) 迭代后期, 为了使粒子能够跳出当前搜索到的最优位置, 在更大的空间中展开搜索, 引入变异因子, 此方法避免引入选择因子^[16], 导致种群多样性丢失的缺点。定义个体有 4% 的变异率, 其伪代码如下:

if $rand_1$ 大于 0.96 或者小于 0.04

则对当前粒子随机赋值

else 保持当前粒子不变

2.2 故障诊断步骤及流程图

综上所述, 基于 PSO 算法改进 RBPNN 神经网络的变压器故障诊断的具体实施步骤为:

Step 1: 在可行域内, 对迭代总次数 T_{\max} 、种群规模 M 、个体位置和速度最大、最小值(防止粒子盲目寻找)及最小误差精度进行设定。

Step 2: 根据特征参数可以确定每个粒子的维数 $D=m+n+n^2$, 在[0,1]内随机赋值。

Step 3: 导入训练样本, 通过 RBPNN 进行第 1 次前向运算, 计算每个粒子适应度值, 根据适应度值的大小, 对粒子进行排序, 寻找出初始个体极值 P_{sti} 和群体极值 P_{stg} 。

Step 4: 进入迭代过程, 根据式(10)和式(11)对位置和速度更新, 并判断是否越界。若越界, 则赋予最值; 否则, 进入下一步。

Step 5: 判断个体是否变异, 若变异则对当前个体位置随机赋值, 并计算当前粒子的适应度值; 否则, 根据更新后的粒子位置, 计算其适应度值。

Step 6: 根据更新后的适应度值, 与上次得到的个体极值 P_i 和群体极值 P_g 比较并更新。

Step 7: 判断当前迭代次数是否达到了设定的最大迭代次数 T_{\max} , 或者 P_g 达到最小误差精度 ε 。若符合, 则迭代终止, 否则转向 Step 4。

Step 8: 网络训练结束后, 根据寻找到的最优粒子, 得到 RBPNN 结构和初值。导入测试样本进行测试, 评价其泛化能力。

故障诊断流程框图如图 2 所示。

3 实例验证

3.1 各层神经元节点及模型参数

当变压器内部发生过热或者放电故障时, 油会发生裂解, 产生一些特定的气体, 主要包括甲烷

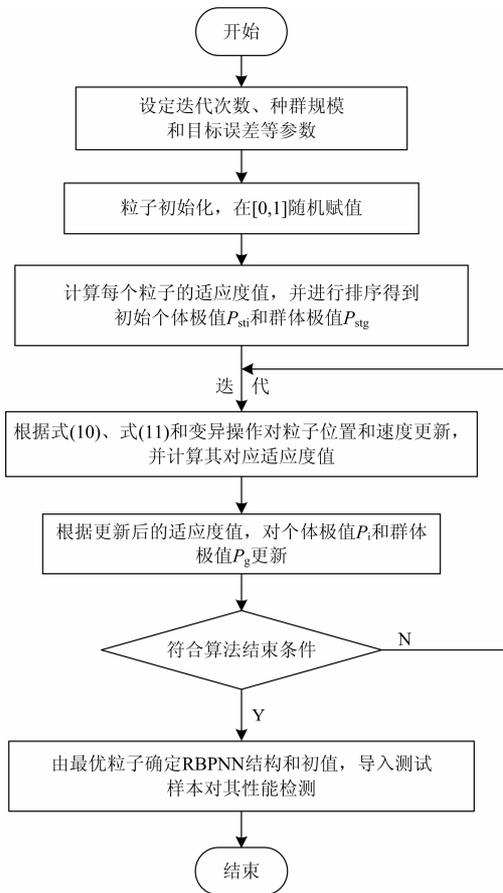


图 2 诊断流程图

Fig. 2 Flowchart of diagnosis

(CH₄)、乙烷(C₂H₆)、乙烯(C₂H₄)、乙炔(C₂H₂)和氢气(H₂)五种特征气体。依据三比值法, 我们采用 C₂H₂/C₂H₄、CH₄/H₂ 和 C₂H₄/C₂H₆ 作为特征输入量, 因此输入层节点设定为 3。

由实际经验可知, 特征输入量数值大小不一, 如果直接作为输入量, 神经网络会对一些较小数值不太敏感, 影响其输出响应。因此有必要对输入数据进行规格化处理, 具体如式(15)。

$$\bar{x}_i = (x_i - x_{\min}) / (x_{\max} - x_{\min}) \quad (15)$$

式中: x_i 为原始数据(假设 C₂H₂/C₂H₄ 比值); x_{\min} 、 x_{\max} 为所有样本中 C₂H₂/C₂H₄ 比值的最小和最大值; \bar{x}_i 归一化后的数据。另外两种特征量采取类似的方法。

通常, 选择低温过热、中温过热、高温过热、低能放电、高能放电和局部放电六种故障状态, 加上正常状态, 故输出节点设置为 7。其理想输出结果见表 1。

第 1 隐层节点数由粒子群算法优化模型后得

出, 在使用之前, 首先需设置相应参数^[17], 见表 2。

表 1 故障理想输出值

Table 1 Ideal output values of faults

故障类型	理想输出						
低温过热	0	0	0	0	0	0	1
中温过热	0	0	0	0	0	1	0
高温过热	0	0	0	0	1	0	0
局部放电	0	0	0	1	0	0	0
低能放电	0	0	1	0	0	0	0
高能放电	0	1	0	0	0	0	0
正常	1	0	0	0	0	0	0

表 2 参数设置

Table 2 Setting of parameters

参数	数值
种群规模(M)	40
位置最大值(X_{\max})	1
位置最小值(X_{\min})	-1
速度最大值(V_{\max})	0.1
最大迭代次数(T_{\max})	160
隐节点最大个数(m_{\max})	40

3.2 样本选择

从文献[18-19]搜集到 168 组典型变压器油中溶解特征气体比值和对应确定故障类型的样本数据, 选择其中 100 组数据作为训练样本, 剩下 68 组作为测试样本。

3.3 网络性能测试

为了更好地说明优化算法的性能, 输入相同训练样本, 分别采用反向传播算法、遗传算法、粒子群算法和改进后的粒子群算法进行网络训练, 得到均方误差随着迭代次数增加的变化曲线, 如图 3 所示。采用相同的测试样本对训练好的四种网络模型进行测试, 将隐节点个数和泛化能力列于表 3 作对比分析。

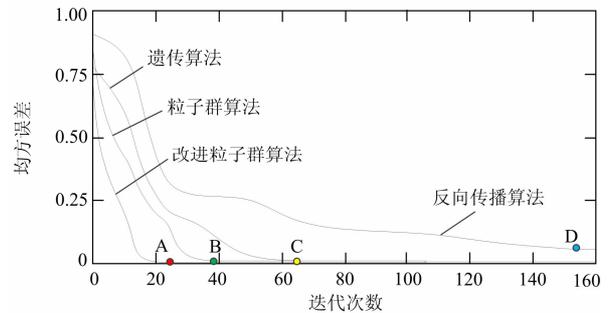


图 3 四种算法的均方误差

Fig. 3 Error accuracy comparison of four algorithms

表 3 隐节点个数和泛化能力列表

Table 3 Number of hidden nodes and generalization

ability of different algorithms		
训练算法类型	隐节点个数	预判准确率/%
反向传播算法	35	77.94
遗传算法	29	86.76
粒子群算法	20	88.24
改进粒子群算法	18	94.12

从图 3 可以看出, 改进粒子群算法经过 24 次迭代后, 均方误差达到最小, 为 0.004 2; 粒子群算法、遗传算法和反向传播算法分别经过 38 次、63 次和 153 次后, 均方误差才达到最小, 分别为 0.009 8、0.012 和 0.068。从表 3 也可以看出, 与另外三种方法相比, 改进粒子群算法预判准确率最高, 及隐节点个数最少。因此, 从收敛速度、误差精度、网络结构和预判准确率分析, 改进粒子群算法在优化本网络时占有显著优势。

为进一步测试其预测稳定性, 利用随机函数对样本集重新抽取 100 组作为训练样本, 进行 2 次。采用改进粒子群算法进行网络训练并测试。连同初始 1 次的测试结果, 三批样本的测试情况分别如表 4(a)、(b)和(c)所示。从表 4 中可以看出, 总计判正率均达到 94%以上, 拥有较高的精度和稳定性。另外, 采用文献[6]所提方法对文中样本进行训练并测试, 总计判正率最高为 91.18%, 低于本文所提方法。

表 4 测试结果

Table 4 Testing results

(a) 第 1 批次预测结果

故障类型	样本数	判正数	判正率(%)	总计判正率(%)
低温过热	9	9	100	
中温过热	8	7	87.5	
高温过热	10	10	100	
局部放电	11	10	90.91	94.12
低能放电	13	13	100	
高能放电	12	10	83.33	
正常	5	5	100	

(b) 第 2 批次预测结果

故障类型	样本数	判正数	判正率(%)	总计判正率(%)
低温过热	7	6	85.71	
中温过热	10	10	100	
高温过热	8	8	100	
局部放电	10	9	90	95.59
低能放电	7	7	100	
高能放电	20	19	95	
正常	6	6	100	

(c) 第 3 批次预测结果

故障类型	样本数	判正数	判正率(%)	总计判正率(%)
低温过热	9	8	88.89	
中温过热	5	5	100	
高温过热	12	12	100	
局部放电	14	13	92.86	94.12
低能放电	12	11	91.67	
高能放电	10	9	90	
正常	6	6	100	

4 结论

由于 RBPNN 自身网络学习算法存在缺陷, 笔者将多种优化算法与 RBPNN 结合, 以油中溶解的气体含量比值作为故障特征量, 并应用于变压器故障诊断中。经验证, 改进 PSO 在优化本网络时效果最好, 该方法能够对不同故障模式有效分类, 为变压器故障诊断提供了一条新的诊断途径。

参考文献

- [1] 廖瑞金, 杨丽君, 郑含博, 等. 电力变压器油纸绝缘热老化研究综述[J]. 电工技术学报, 2012, 27(5): 1-12.
LIAO Ruijin, YANG Lijun, ZHENG Hanbo, et al. Reviews on oil-paper insulation thermal aging in power transformers[J]. Transactions of China Electrotechnical Society, 2012, 27(5): 1-12.
- [2] 许惠君, 王宗耀, 苏浩益. 基于 DGA 的反馈云熵模型电力变压器故障诊断方法研究[J]. 电力系统保护与控制, 2013, 41(23): 115-119.
XU Huijun, WANG Zongyao, SU Haoyi. Dissolved gas analysis based feedback cloud entropy model for power transformer fault diagnosis[J]. Power System Protection and Control, 2013, 41(23): 115-119.
- [3] 钱之银, 陆志浩, 楼其民, 等. 变压器油中溶解气体判断方法综述[J]. 高压电器, 2002, 38(6): 34-37.
QIAN Zhiyin, LU Zhihao, LOU Qimin, et al. Overview of analysis and diagnosis of the dissolved gas in transformer oil[J]. High Voltage Apparatus, 2002, 38(6): 34-37.
- [4] 程加堂, 艾莉, 段志梅. 改进证据理论与神经网络集成的变压器故障诊断[J]. 电力系统保护与控制, 2013, 41(14): 92-96.
CHENG Jiatang, AI Li, DUAN Zhimei. Transformer fault diagnosis based on improved evidence theory and neural network integrated method[J]. Power System Protection and Control, 2013, 41(14): 92-96.
- [5] ZHANG Yongtao, WANG Yajuan, ZHAO Yanjun, et al. Transformer failure diagnosis based on BP neural network[C] // Mechatronic Science, Electric Engineering

- and Computer (MEC), 2011 International Conference on Jilin, August 19-22, 2011: 1445-1448.
- [6] 陈波, 郭壮志. 基于优化平滑因子 σ 的概率神经网络的变压器故障诊断方法研究[J]. 现代电力, 2007, 24(2): 44-47.
CHEN Bo, GUO Zhuangzhi. Fault diagnosis method research of transformer based on optimized smooth factor of probability neural network[J]. Modern Electric Power, 2007, 24(2): 44-47.
- [7] 薛浩然, 张珂珩, 李斌, 等. 基于布谷鸟算法与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.
- [8] 石鑫, 朱永利, 萨初日拉, 等. 基于深度信念网络的电力变压器故障分类建模[J]. 电力系统保护与控制, 2016, 44(1): 71-76.
SHI Xin, ZHU Yongli, SA Churila, et al. Power transformer fault classifying model based on deep belief network[J]. Power System Protection and Control, 2016, 44(1): 71-76.
- [9] 公茂法, 张言攀, 柳岩妮, 等. 基于 BP 网络算法优化模糊 Petri 网的电力变压器故障诊断[J]. 电力系统保护与控制, 2015, 43(3): 113-117.
GONG Maofa, ZHANG Yanpan, LIU Yanni, et al. Fault diagnosis of power transformers based on back propagation algorithm evolving fuzzy Petri nets[J]. Power System Protection and Control, 2015, 43(3): 113-117.
- [10] 黄德双. 一种新的径向基概率神经网络模型(I): 基本理论[J]. 计算机研究与发展, 1998, 35(2): 118-121.
HUANG Deshuang. A new model on radial basis probabilistic neural networks (I): basic theory[J]. Computer Research & Development, 1998, 35(2): 118-121.
- [11] 黄德双. 一种新的径向基概率神经网络模型(II): 模型分析[J]. 计算机研究与发展, 1998, 35(2): 122-127.
HUANG Deshuang. A new model on radial basis probabilistic neural networks (II): case studies[J]. Computer Research & Development, 1998, 35(2): 122-127.
- [12] 李国友, 姚磊, 李惠光, 等. 基于优化的 RBF 神经网络模式识别新方法[J]. 系统仿真学报, 2006, 18(1): 181-184.
LI Guoyou, YAO Lei, LI Huiguang, et al. A new method of pattern recognition based on optimized RBF neural networks[J]. Journal of System Simulation, 2006, 18(1): 181-184.
- [13] 潘翀, 陈伟根, 云玉新, 等. 基于遗传算法进化小波神经网络的电力变压器故障诊断[J]. 电力系统自动化, 2007, 31(13): 88-92.
PAN Chong, CHEN Weigen, YUN Yuxin, et al. Fault diagnosis of power transformers based on genetic algorithm evolving wavelet neural network[J]. Automation of Electric Power Systems, 2007, 31(13): 88-92.
- [14] 韩敏. 基于微粒群的神经网络预测控制理论及应用[M]. 北京: 中国水利水电出版社, 2013.
- [15] 李丽, 牛奔. 粒子群优化算法[M]. 北京: 冶金工业出版社, 2009.
- [16] 魏星, 舒乃秋, 张霖, 等. 基于改进 PSO-BP 混合算法的电力变压器故障诊断[J]. 电力自动化设备, 2006, 26(5): 35-38.
WEI Xing, SHU Naiqiu, ZHANG Lin, et al. Power transformer fault diagnosis based on improved PSO-BP hybrid algorithm[J]. Electric Power Automation Equipment, 2006, 26(5): 35-38.
- [17] 史峰, 王小川, 郁磊, 等. MATLAB 神经网络 30 个案例分析[M]. 北京: 北京航空航天大学出版社, 2010.
- [18] 雷铭. 电力设备诊断手册[M]. 北京: 中国电力出版社, 2000.
- [19] 万怡巖. 基于概率神经网络的变压器故障诊断[D]. 南昌: 南昌大学, 2007.
WAN Yiqin. Transformer fault diagnosis based on probabilistic neural networks[D]. Nanchang: Nanchang University, 2007.

收稿日期: 2016-01-14; 修回日期: 2016-03-23

作者简介:

施恂山(1991-), 男, 通信作者, 硕士研究生, 主要研究方向为电力设备状态检测与故障诊断; E-mail: shixunshangdy@163.com

马宏忠(1962-), 男, 教授, 博士生导师, 从事电力设备状态监测、故障诊断等方面的研究工作;

张琳(1991-), 女, 硕士研究生, 主要研究方向为电力设备状态检测与故障诊断。

(编辑 魏小丽)