

# 神经网络在变压器故障诊断中典型算法研究

胡汉梅<sup>1</sup>, 鲍亮亮<sup>1</sup>, 赵海军<sup>2</sup>

(1. 三峡大学电气信息学院, 湖北 宜昌 443002; 2. 晋城煤业集团长平公司, 山西 晋城 048411)

**摘要:** 为了随时检测变压器状态, 及早发现并排除变压器可能存在的故障, 笔者将 3 种不同的神经网络(即 BP 网络、GA-BP 网络与 RBF 网络)应用于变压器故障诊断中, 分别介绍了这 3 种网络的结构及原理, 故障诊断采用 MATLAB 语言编程实现。大量实验数据结果分析表明, RBF 网络在诊断准确率相比其他两种网络具有一定的优势。

**关键词:** 变压器; 故障诊断; BP 网络; GA-BP 网络; RBF 网络; 诊断准确率

中图分类号: TM4

文献标志码: A

文章编号: 1001-1609(2008)03-0217-04

## Research on Typical Artificial Neural Networks in Power Transformer Fault Diagnosis

HU Han-mei<sup>1</sup>, BAO Liang-liang<sup>1</sup>, ZHAO Hai-jun<sup>2</sup>

(1. College of Electrical Engineering & Information Technology, China Three Gorges Univ., Yichang 443002, China;

2. Changping Company, China Shanxi Jincheng Anthracite Coal Mining Group Co., Ltd., Jincheng 048411, China)

**Abstract:** In order to examine transformer momentarily to exclude possible fault in time, three kinds of artificial neural network were applied in the transformer fault diagnosis, such as the BP network, the GA-BP network, and RBF network. The structures and principles of the three networks were analyzed, and fault diagnosis was realized by MATLAB programming. The analysis of the massive experimental data indicate that the RBF network is better than the others in diagnostic accuracy.

**Key words:** transformer; fault diagnosis; BP network; GA-BP network; RBF network; diagnostic accuracy

## 0 引言

电力变压器是电力系统中容量大、故障率较高的设备, 其运行状态的安全与否直接关系到整个电力系统的安全性和经济性。因此, 随时检测变压器状态, 及早发现并排除变压器可能存在的故障, 已成为保障供电可靠性的重要手段之一, 是电力系统中一项具有重大理论和实用价值的课题。

油中溶解气体的色谱分析(DGA)<sup>[1-4]</sup>技术是变压器故障诊断的一种重要手段, 基于 DGA 技术, 采用具有高度的非线性映射以及自组织、自学习能力的人工神经网络, 在变压器故障诊断中已有一些先例<sup>[5,6]</sup>。现阶段在进行故障诊断时采用比较多的是 BP 神经网络、GA-BP 网络和 RBF 网络。笔者将分别对这 3 种神经网络的原理及其在变压器故障诊断中的应用进行说明, 并就诊断准确率进行比较。

## 1 BP 神经网络的变压器故障诊断

### 1.1 BP 神经网络

BP 网络是目前应用最广泛的神经网络之一, 是

正向求解、反向传播并达到修改网络层次之间连线上权值的网络模型。BP 算法的具体思想是: 对一个输入样本, 从输入层经隐含层逐层正向计算, 得到输出层的输出。然后, 让它与期望样本比较, 如有偏差, 则把输出层单元的误差向输入层逆向传播, 由此调整连接权值与阈值, 从而使网络输出值逼近期望输出, 通常使之达到误差均方值取最小为止。

典型的 BP 网络是 3 层前馈网络<sup>[7]</sup>, 即输入层、隐含层和输出层, 其中每层的结点与上下层的结点间都有联系, 而同层结点之间不存在联系。隐含层可以为一层或者多层, 但是有一个隐含层的 BP 网络已经能以任何准确度完成任何连续函数的映射, 笔者采取一个隐含层。

### 1.2 输入输出模式确定

由于 DGA 技术是通过 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> 5 种气体体积分数结合查表来判定故障类型的, 因而笔者也以每种气体分别占 5 种气体总量的百分比作为 5 个输入神经元的输入向量。根据变压器发生故障的实际情况和相对比例, 经过反复综合考虑, 对输出层采用无故障、中低温过热、高温过热、低能量放电、高能量放电作为五个输出神经元, 分别对应

收稿日期: 2008-03-10; 修回日期: 2008-04-07

作者简介: 胡汉梅(1965-), 女, 湖北省宜昌市人, 教授, 硕士研究生导师, 主要从事电力系统绝缘与过电压研究。

$O_1, O_2, O_3, O_4, O_5$ , 输出值最大为 1, 表示属于此类故障, 数值越大则表明该类型故障的可能性越大; 输出值最小为 0, 表示不属于此类故障。高能量放电一般指电弧放电和比较强烈的火花放电; 低能量放电一般指局部放电和比较微弱的火花放电。反映过热的高温过热、中低温过热中只能有一个输出大于 0, 因为它们相互制约的; 反映放电的高能量放电、低能量放电中只能有一个输出大于 0, 但在过热类型和放电类型中可同时有大于 0 的输出, 因为它们可以伴随产生, 见表 1。

表 1 故障类型对应的神经元输出

故障类型	输出神经元期望输出				
	$O_1$	$O_2$	$O_3$	$O_4$	$O_5$
无故障	1	0	0	0	0
中低温过热	0	1	0	0	0
高温过热	0	0	1	0	0
低能量放电	0	0	0	1	0
高能量放电	0	0	0	0	1

### 1.3 仿真结果

选取 60 组历史故障数据作为训练样本, 15 组故障数据作为检验样本。基于 MATLAB7.0 平台, 经过对隐含层神经元个数<sup>[8]</sup>的选择, 确定隐含层神经元的个数为 12 时, 故障诊断准确率最高。训练步数为 65 步。

选取训练好的隐含层神经元个数为 12 的 BP 网络模型, 在 MATLAB7.0 软件中进行仿真, 测试样本期望仿真结果见表 2, BP 网络测试样本实际仿真结果见表 3。

表 2 测试样本期望的仿真数据

样本编号	期望仿真数据					样本编号	期望仿真数据				
1	1	0	0	0	0	8	0	0	1	0	0
2	1	0	0	0	0	9	0	0	1	0	0
3	1	0	0	0	0	10	0	0	1	0	0
4	0	1	0	0	0	11	0	0	0	1	0
5	0	1	0	0	0	12	0	0	0	0	1
6	0	1	0	0	0	13	0	0	0	0	1
7	0	1	0	0	0	14	0	0	1	0	1
						15	0	0	1	0	1

表 3 BP 网络测试样本实际仿真数据

样本编号	经 BP 网络实际仿真数据					样本编号	经 BP 网络实际仿真数据				
1	0.000 0	0.000 0	0.000 0	0.000 0	1.000 0	8	0.000 0	0.000 9	1.000 0	0.000 0	0.000 0
2	1.000 0	0.055 8	0.000 0	0.000 0	0.000 0	9	0.000 0	0.950 9	0.003 9	0.000 0	0.000 0
3	1.000 0	0.005 2	0.000 0	0.000 0	0.000 0	10	0.000 0	0.000 0	1.000 0	0.000 0	0.000 0
4	0.000 0	0.928 2	0.000 0	0.000 0	0.000 0	11	0.000 0	0.825 6	0.000 0	0.000 0	0.000 0
5	0.000 0	0.969 0	0.000 0	0.000 0	0.000 0	12	0.000 0	0.000 0	0.000 0	0.000 0	1.000 0
6	0.000 0	0.971 7	0.000 0	0.000 0	0.000 0	13	0.000 0	0.582 7	0.000 0	0.000 0	1.000 0
7	0.000 0	0.991 7	0.000 0	0.000 0	0.000 0	14	0.000 0	0.000 8	1.000 0	0.000 0	1.000 0
						15	0.000 0	0.002 8	1.000 0	0.000 0	1.000 0

对表 2、3 数据进行对比, 得出采用 BP 神经网络对变压器进行故障诊断的准确率为 73.3%。

## 2 GA-BP 神经网络的变压器故障诊断

### 2.1 GA-BP 神经网络

GA<sup>[9]</sup>是一种基于自然选择和基因遗传学原理的优化搜索方法。它将“优胜劣汰, 适者生存”的生物进化原理引入待优化参数形成的编码串群体中, 按照一定的适配值函数及一系列遗传操作对各个体进行筛选, 从而使适配值高的个体被保留下来, 组成新的群体, 新群体中各个体的适应度不断提高, 直至满足一定的极限条件。此时, 群体中适配值最高的个体即为待优化参数的最优解。由于遗传算法的工作原理, 使它能够在复杂空间进行全局优化搜索。GA-BP 算法就是在 BP 算法之前, 先用 GA 在随机点集中遗传出优化初值, 以此作为 BP 算法的初始权值, 再由 BP 算法进行训练。

### 2.2 GA-BP 神经网络算法实现

GA-BP 算法具体的实现步骤如下: ①对网络的

权值、阈值的解空间进行实数编码, 随机生成一个初始群体。笔者初始种群取 20。实数编码可以缩短染色体串的长度, 避免了有些变量难以进行二进制编码的困难, 也避免了在二进制编码条件下必需的译码过程, 提高了算法的精度和速度; ②调用神经网络, 对群体中的每一个个体都进行适应度评价。网络的目标函数为误差最小化问题, 网络适应度函数可为  $Fit[f(x)] = C_{max} - f(x), f(x) < C_{max}$ , 这里的  $C_{max}$  根据群体容量的大小及每代网络输出的误差大小确定; ③根据个体的适应度, 对群体中的个体进行选择、交叉、变异操作, 完成一代进化。选择操作采用最优个体保留法, 交叉变异采用多次均匀算数交叉法和多次均匀变异法; ④反复进行第 2 和第 3 步, 直至进化成代为预置的进化代数; ⑤以 GA 遗传出的优化初值作为初始权值, 进行 BP 网络训练, 直到指定的精度; ⑥由 BP 网络求得的结果, 解码获得权值、阈值的最优解, 输出检验样本的仿真结果。

### 2.3 仿真结果

文中 GA 算法进行了 59 代的遗传操作达到了

目标值, BP算法则是在进行了61次训练后, 收敛到指定误差, 同样使用上文中BP网络的检验样本, 仿真结果见表4。

对表2、4数据进行对比, 得出采用GA-BP神经网络对变压器进行故障诊断的准确率为80%。

表4 GA-BP网络测试样本实际仿真数据

样本编号	GA-BP网络实际仿真数据					样本编号	GA-BP网络实际仿真数据				
1	0.000 0	0.000 0	0.000 1	0.000 0	0.928 9	8	0.000 0	0.000 0	1.000 0	0.002 5	0.000 0
2	1.000 0	0.000 0	0.000 0	0.000 0	0.000 0	9	0.000 0	1.000 0	0.000 9	0.000 0	0.000 0
3	1.000 0	0.005 2	0.000 0	0.000 0	0.028 2	10	0.000 0	0.000 0	1.000 0	0.000 0	0.000 0
4	0.000 0	1.000 0	0.000 0	0.000 0	0.000 0	11	0.000 0	0.882 0	0.000 0	0.000 0	0.000 0
5	0.000 0	0.969 8	0.000 0	0.000 0	0.000 0	12	0.000 0	0.000 0	0.000 0	0.000 0	1.000 0
6	0.000 0	0.901 7	0.000 0	0.000 0	0.000 0	13	0.000 0	0.005 0	0.000 0	0.000 0	1.000 0
7	0.000 0	0.991 0	0.000 0	0.000 0	0.000 0	14	0.000 0	0.000 7	1.000 0	0.000 0	1.000 0
						15	0.000 0	0.001 8	1.000 0	0.000 0	1.000 0

数构成。一般隐含层各节点采用相同的径向基函数, 当基函数取高斯函数时, 网络输入与输出之间可认为是一种映射关系, 可表示为

$$y_{kj}(X_k) = \sum_{i=1}^l w_{ij} \varphi(X_k, C_i)$$

其中  $C_i = [c_{i1}, c_{i2}, \dots, c_{im}]$  为高斯函数  $\varphi$  的中心;  $X_k = [x_{k1}, x_{k2}, \dots, x_{km}]$  为输入样本;  $\sigma_i$  为高斯函数的方差;  $w_{ij}$  为隐含层与输出层间的权值;  $y_{kj}$  为  $k$  样本第  $j$  个输出。

RBF网络是一种单隐层前馈网络, 其输出节点计算为隐节点给出的基函数输出的线性组合, 其中隐含层中的基函数对输入激励产生一个局部化的响应, 即每一个隐节点有一个称之为中心的参数矢量, 该中心用来与网络输入矢量相比较以产生径向对称响应, 仅当输入落在一个很小的指定区域中时隐节点才做出有意义的非零响应, 响应值在0~1之间。输入与基函数中心的距离越近, 隐节点响应越大。若  $\sigma_i$  值过小, 则网络对噪声太敏感, 易失真; 若  $\sigma_i$  过大, 会使网络丧失区分和拟合的能力, 因此RBF网络需要选择合适的  $\sigma_i$  值。而输出单元一般是线性的, 即输出单元对隐节点输出进行线性加权组合。

### 3.2 RBF神经网络学习算法

RBF网络需要学习的参数有3个: 基函数的中

## 3 RBF神经网络的变压器故障诊断

### 3.1 RBF神经网络

RBF网络输出层可以只有一个节点, 也可有多个输出节点, RBF神经网络隐含层由一组径向基函

数  $C_i$ 、方差  $\sigma_i$  以及隐含层与输出层间的权值  $w_i$ 。根据径向基函数中心选取方法的不同, 最常见的学习方法有<sup>[10-12]</sup>: 自组织选取中心法、正交最小二乘法等方法。自组织学习过程中确定  $C_i$  和  $\sigma_i$  的方法是聚类方法。聚类方法就是把样本聚成几类, 以类中心作为各RBF函数的中心, 常用的方法有  $k$  均值聚类法<sup>[10-12]</sup>。权值  $w_i$  的学习算法可用LMS(最小均方误差)方法, 也可直接用伪逆法或最小二乘法求解。其中LMS权值  $w$  的调整规则为:  $e(n) = d(n) - X^T(n)w(n)$ ;  $w(n+1) = w(n) + \eta X(n)e(n)$ 。这里  $X(n)$  为隐含层输出;  $w(n)$  为权值向量;  $d(n)$  为期望输出;  $\eta$  为学习速率;  $n$  为迭代次数。

RBF神经网络结构简单, 其设计比普通前向网络训练要省时得多。如果隐含层神经元的数目足够, 每一层的权值和阈值正确, 那么RBF函数网络就完全能够精确地逼近任意函数。

### 3.3 仿真结果

文中使用正交最小二乘法OSL训练RBF网络。训练步数为47步。在MATLAB中, RBF神经网络的实际仿真结果见表5。

表2、5数据对比得出, 采用RBF神经网络对变压器进行故障诊断的准确率为93.3%。

表5 测试的样本实际仿真数据

样本编号	RBF网络实际仿真数据					样本编号	RBF网络实际仿真数据				
1	1.000 0	0.000 5	0.000 0	0.004 4	0.000 0	8	0.000 0	0.000 9	1.000 0	0.000 0	0.000 0
2	1.000 0	0.052 4	0.000 7	0.002 0	0.000 0	9	0.000 0	0.007 9	0.903 4	0.000 0	0.000 6
3	1.000 0	0.014 4	0.000 0	0.001 0	0.003 9	10	0.000 0	0.000 5	1.000 0	0.003 6	0.000 1
4	0.000 0	0.921 0	0.000 0	0.001 5	0.000 0	11	0.000 0	0.682 3	0.000 0	0.000 3	0.000 0
5	0.000 0	0.969 0	0.000 4	0.009 0	0.000 0	12	0.000 0	0.033 0	0.000 0	0.000 5	1.000 0
6	0.000 0	0.915 7	0.000 0	0.056 0	0.000 0	13	0.000 0	0.005 1	0.000 0	0.000 0	1.005 4
7	0.000 0	0.976 1	0.000 0	0.002 8	0.000 0	14	0.000 0	0.006 9	1.000 0	0.000 0	1.000 0
						15	0.000 0	0.002 5	1.000 0	0.000 0	1.000 0

### 4 3 种典型神经网络比较

笔者通过对 BP 神经网络、GA-BP 神经网络和 RBF 神经网络诊断结果的比较,来判断在变压器故障诊断应用中哪种神经网络实际应用效果最理想。为了使比较更有说服力,整个过程中所用到的训练样本、检验样本完全一样。计算机的配置为英特尔酷睿 2 双核 T5500 处理器,英特尔 945PM 主板芯片组,512MB 内存。开发工具及仿真平台选择 MATLAB7.0。笔者首先对 3 种神经网络训练过程进行比较,见表 6。

由表 6 可知,在文中涉及的 3 种神经网络中,BP 神经网络的训练误差最大,笔者认为这是 BP 的网络本身缺陷导致其易于陷入局部最优造成的。GA-BP 神经网络相对于直接采用 BP 神经网络在训练误差

表 6 BP 网络,GA-BP 网络与 RBF 网络训练过程比较

神经网络类型	训练步长	训练时间/s	训练误差
BP	65	6.543 0	0.009 543 2
GA-BP	120	352.452 0	0.008 699 0
RBF	47	4.598 0	1.327 9e-005

上有着更好的表现,但训练所花费的时间却远远高于后者。与前两种神经网络相对应的是,RBF 神经网络在训练时间和训练误差方面表现得更优秀。

对 3 种典型神经网络诊断结果进行比较。通过上面 3 个章节的讨论,采用 BP 神经网络与 GA-BP 神经网络后的变压器故障诊断的准确率分别为 73.3%与 80%。GA-BP 神经网络的诊断准确率高于 BP 神经网络。而采用 RBF 神经网络的诊断准确率为 93.3%,明显高于上述两者。详细比较结果见表 7。

表 7 BP 网络,GA-BP 网络与 RBF 网络诊断结果与实际故障结果比较

样本	气体的相对比值/%					实际故障	BP 网络诊断	GA-BP 网络诊断	RBF 网络诊断
	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>				
1	39.18	24.50	18.37	11.43	6.53	无故障	高能放电	高能放电	无故障
2	33.66	2.97	33.17	27.72	2.48	无故障	无故障	无故障	无故障
3	46.13	11.57	33.14	8.52	0.63	无故障	无故障	无故障	无故障
4	40.26	25.11	18.61	16.02	0.00	中低温过热	中低温过热	中低温过热	中低温过热
5	35.35	51.17	8.01	5.47	0.00	中低温过热	中低温过热	中低温过热	中低温过热
6	0.98	43.83	26.80	28.39	0.00	中低温过热	中低温过热	中低温过热	中低温过热
7	12.15	40.50	18.90	28.35	0.09	中低温过热	中低温过热	中低温过热	中低温过热
8	14.71	12.56	12.44	60.29	0	高温过热	高温过热	高温过热	高温过热
9	1.38	6.15	9.21	76.63	6.63	高温过热	中低温过热	中低温过热	高温过热
10	11.31	21.83	11.24	53.14	2.46	高温过热	高温过热	高温过热	高温过热
11	89.99	5.35	1.96	2.70	0	低能放电	中低温过热	中低温过热	中低温过热
12	17.01	13.76	3.07	39.57	26.59	高能放电	高能放电	高能放电	高能放电
13	26.86	16.89	3.09	39.43	13.73	高能放电	高能放电兼中低温放热	高能放电	高能放电
14	11.18	41.92	21.41	15.51	10.25	高能放电兼高温过热	高能放电兼高温过热	高能放电兼高温过热	高能放电兼高温过热
15	7.01	26.66	3.28	48.76	14.28	高能放电兼高温过热	高能放电兼高温过热	高能放电兼高温过热	高能放电兼高温过热

### 5 结语

与 BP 神经网络、GA-BP 神经网络相比较,RBF 神经网络在训练上所花费时间最少,训练误差最低,诊断结果准确率最高,因此,在用神经网络诊断变压器故障时可以将 RBF 网络作为优先选择。

### 参考文献:

[1] 操敦奎. 变压器油中气体分析与故障诊断 [M]. 北京: 中国电力出版社, 2005.  
 [2] 李义仓. 用色谱法诊断变压器过热故障及其部位[J]. 变压器, 1995(7): 35-38  
 [3] 王昌长, 李福祺. 电力设备的在线监测与故障诊断[M]. 北京: 清华大学出版社, 1996.  
 [4] GBDL/T 722-2000. 变压器油中溶解气体分析和判断导则[S]. 北京: 国家标准局, 2000.

[5] 丁晓群. 神经网络应用于电力变压器故障诊断 [J]. 电力系统自动化, 1996, 20(2): 32-35.  
 [6] 徐志钮, 律方成. 多神经网络方法在变压器油色谱故障诊断中的应用[J]. 高压电器, 2005, 41(3): 206-208.  
 [7] 彭宁云, 文习山, 陈江波. 电力变压器 BP 神经网络故障诊断法的比较研究[J]. 高压电器, 2004, 40(3): 173-176.  
 [8] MATINT, HAGAN, HOWARDB, et al. 神经网络设计[M]. 戴 魁,译. 北京: 清华大学出版社, 1996.  
 [9] 刘水生, 沈元隆. 遗传算法在冗余系统可靠性最优分配问题上的应用 [J]. 电力系统通信, 2003(8): 56-59.  
 [10] 臧宏志, 胡玉华, 愈晓冬. 基于径向基函数的集成神经网络在变压器故障诊断中的应用 [J]. 电力系统及自动化学报, 2003, 15(1): 51-53.  
 [11] 王洪斌, 杨香兰, 王洪瑞. 一种改进的 RBF 神经网络学习算法[J]. 系统工程与电子技术, 2002, 24(6): 103-105.  
 [12] 闻周露. MATLAB 神经网络应用设计[M]. 北京: 科学出版社, 2000.