

# CP 组合神经网络在基于 DGA 的变压器绝缘故障诊断中的应用

汪晓明<sup>1</sup>, 何萍<sup>1</sup>, 吴花<sup>1</sup>, 陈振刚<sup>1</sup>, 欧阳瑾<sup>2</sup>, 李彦明<sup>3</sup>

(1. 江西省电力公司超高压分公司, 江西 南昌 330006; 2. 江西省南昌市供电公司, 江西 南昌 330006;  
3. 西安交通大学电气工程学院, 陕西 西安 710049)

**摘要:** 对向传播(CP)算法是一种有教师学习和无教师学习算法的混合体,既具有良好的模式识别性能,又能很好地解决反馈型神经网络的收敛问题。笔者提出了基于 CP 分类器人工神经网络的变压器故障诊断方法,建立了 CP 组合神经网络模型,通过比较不同训练情况下的正判率来确定 CP 网络中的训练次数和竞争层神经元的个数。实例证明该模型诊断结果的正判率比改良电协研法和 IEC 三比值法有较大的提高,具有较高的诊断准确率和应用价值。

**关键词:** 变压器; 故障诊断; 油中溶解气体分析; CP 组合神经网络

中图分类号: TM855

文献标志码: A

文章编号: 1001-1609(2008)06-0543-05

## Application of CP Compound Modular Neural Network in DGA Based Power Transformer Fault Diagnosis

WANG Xiao-ming<sup>1</sup>, HE Ping<sup>1</sup>, WU Hua<sup>1</sup>, CHEN Zhen-gang<sup>1</sup>, OU YANG Jin<sup>2</sup>, LI Yan-ming<sup>3</sup>

(1. Ultra High Voltage Transmission Subcompany of Jiangxi Electric Power Corporation, Nanchang 330006, China;  
2. Jiangxi Nanchang Power Corporation, Nanchang 330006, China;  
3. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** Counter propagation (CP) arithmetic is one kind mixture arithmetic complsed supervised learning algorithm and unsupervised learning algorithm. It has good pattern recognition performance, and can solve the convergence problem of feedback neural network. This paper presents a fault diagnosis method for power transformer based on CP neural network, and builds a compound neural networks model. The training times and the number of neurons on a competition level in CP network are determined by comparing the results in different training situations. The diagnostic examples indicate the diagnostic correctness of the proposed method is higher than that of the improved three rations method.

**Key words:** transformer; fault diagnosis; dissolved gases analysis (DGA); CP compound neural networks

## 0 引言

电力变压器是电力系统中的重要设备,其运行状态直接影响系统的安全性。油中溶解气体分析(DGA)技术是目前对油浸式电力变压器进行故障诊断最方便、有效的手段,它能有效发现变压器内部的潜伏性故障及其发展程度,防止由此引起重大事故。目前有很多人智能的方法被应用于电力变压器绝缘诊断中,其中人工神经网络技术是引入到变压器故障诊断中的智能技术中最重要的方法之一,并与模糊技术、专家系统等相结合,目前已经有很多这方面的研究,取得了比较好的效果<sup>[1-4]</sup>。但是,通常人工神经网络有几个比较大的缺点,如训练时间比较长、存在局部最优等问题,严重制约了人工神经网络

的发展。因此,如何寻找一种新的算法,避免以上算法的本质缺点,成为神经网络在 DGA 中应用的关键。

对向传播网络,简称 CP 网络,是美国计算机专家 Robert Hecht-nielsen 于 1987 年提出的<sup>[5,6]</sup>。它是将 Kohonen 特征映射与 Grossberg 基本竞争型相结合,发挥各自特长的一种新型特征映射网络,是一种有教师学习和无教师学习算法的混合体,既具有良好的模式分类能力,又能解决训练时间比较长、存在局部最优等问题,在模式分类、函数近似、统计分析和数据压缩等领域都有着广泛的应用。笔者将 CP 算法引入到变压器故障诊断中,提出了基于 CP 分类器的变压器故障诊断方法,建立了 CP 组合神经网络模型,同时针对 CP 网络中训练次数和竞争层神经元个数的确定,提出了通过比较不同训练情况下的正判率来确定 CP 网络的参数。通过实例验证表

收稿日期:2007-11-10; 修回日期:2008-05-27

作者简介:汪晓明(1978-),男,硕士,助理工程师,从事高压试验工作。

明该模型具有较高的诊断准确率和应用价值。

### 1 CP神经网络结构及其算法

#### 1.1 CP神经网络结构

CP网络结构见图1。网络分为输入层、竞争层和输出层。输入层与竞争层构成自组织特征映射(SOM)网络,竞争层与输出层构成基本竞争型网络。从整体上看,该网络属于有教师型,而由输入层和竞争层构成的SOM网络又是一种典型的无教师神经网络。因此,这一网络既汲取了无教师型网络分类灵活、算法简练的优点,又采纳了有教师型网络分类精细、准确的长处,使两种不同类型的网络有机地结合起来。




图1 CP网络结构

CP网络的基本思想是,由输入层至输出层,网络按照SOM学习规则产生竞争层的获胜神经元,并按这一规则调整相应的输入层至竞争层的连接权;由竞争层到输出层,网络按照基本竞争型网络学习规则,得到各输出神经元的实际输出值,并按照有教师型的误差校正方法,修正由竞争层到输出层的连接权。经过这样的反复学习,可以将任意的输入模式映射为输出模式。

#### 1.2 CP算法的训练步骤

假定输入层有N个神经元,p个连续值的输入模式为 $A_k=(a_1^k, a_2^k, \dots, a_N^k)$ ,竞争层有Q个神经元,对应的二值输出向量为 $B_k=(b_1^k, b_2^k, \dots, b_Q^k)$ ,输出层有M个神经元,其连续值的输出向量为 $C^k=(c_1^k, c_2^k, \dots, c_M^k)$ ,目标输出向量为 $C_k=(c_1^k, c_2^k, \dots, c_M^k)$ ,以上 $k=1, 2, \dots, p$ 。由输入层至竞争层的连接权向量为 $W_j=(w_{j1}, w_{j2}, \dots, w_{jN}), j=1, 2, \dots, Q$ ;由竞争层到输出层的连接权向量为 $V_h=(v_{h1}, v_{h2}, \dots, v_{hQ}), h=1, 2, \dots, M$ ;网络学习和工作规则如下所述:

(1)初始化。将连接权向量 $W_j$ 和 $V_h$ 赋予区间 $[0, 1]$ 内的随机值。将所有的输入模式 $A_k$ 进行归一化处理

$$a_i^k = \frac{a_i^k}{\|A_k\|}, \|A_k\| = \sqrt{\sum_{i=1}^N (a_i^k)^2}, i=1, 2, \dots, N$$

(2)将第K个输入模式 $A_k$ 提供给网络的输入层。

(3)将连接权值向量 $W_j$ 按照下式进行归一化处理

$$w_{ji} = \frac{w_{ji}}{\|w_{ji}\|}, \|w_{ji}\| = \sqrt{\sum_{i=1}^N w_{ji}^2}, i=1, 2, \dots, N$$

(4)求竞争层中每个神经元的加权输入和

$$s_j = \sum_{i=1}^N a_i^k w_{ji}, j=1, 2, \dots, Q$$

(5)求连接权向量 $W_j$ 中与 $A_k$ 距离最近的向量 $W_g$

$$W_g = \max_{j=1, 2, \dots, Q} \sum_{i=1}^N a_i^k w_{ji} = \max_{j=1, 2, \dots, Q} s_j$$

将神经元g的输出设定为1,其余竞争层神经元的输出设定为0

$$b_j = \begin{cases} 1 & j=g \\ 0 & j \neq g \end{cases}$$

(6)将连接权向量 $W_g$ 按照下式进行修正

$w_{gi}(t+1) = w_{gi}(t) + a[a_i^k - w_{gi}(t)], i=1, 2, \dots, N$ ,其中, $0 < a < 1$ 为学习率。

(7)将连接权向量 $W_g$ 重新归一化,归一化算法同上。

(8)按照下式修正竞争层到输出层的连接权向量 $V_h$

$$v_{hi}(t+1) = v_{hi}(t) + \beta b_j (c_h - c_h'), h=1, 2, \dots, Q$$

其中, $0 < \beta < 1$ 为学习率。由步骤(5)将上式简化为

$$v_{hg}(t+1) = v_{hg}(t) + \beta b_j (c_h - c_h'), h=1, 2, \dots, M。$$

由此可见,只需要调整竞争层获胜神经元g到输出层的连接权向量 $V_g$ ,其他连接权向量保持不变。

(9)求输出层各神经元的加权输入,并将其作为输出神经元的实际输出值,

$$c_h' = \sum_{j=1}^Q b_j v_{hg}, h=1, 2, \dots, M, \text{同理可将其简化为}$$

$$c_h' = v_{hg}$$

(10)返回步骤(2),直到将p个输入模式全部提供给网络。

(11)令 $t=t+1$ ,将输入模式 $A_k$ 重新提供给网络学习,直到 $t=T$ 。其中T为预先设定的学习总次数,一般取 $500 < T < 10000$ 。

### 2 CP网络模型的建立

文[7]指出,由于DGA在判别过热故障的性质是否涉及固体绝缘的确定性一直没有得到很好的解决,因此网络模型的DGA数据采用氢气、甲烷、乙烷、乙烯、乙炔5种气体。从文[8]可知,目前从油中气体分析结果很难加以区分局部放电和受潮故障,应根据外部检查和其他实验结果加以综合判断。故笔者将变压器的故障类型分为低温过热、高温过热、低能放电和高能放电,网络模型的输出分别为正常、异常。基于CP组合神经网络的变压器故障诊断模型见图2。

#### 2.1 诊断规则 RULE<sub>0</sub>、RULE<sub>1</sub>和RULE<sub>2</sub>

ANN<sub>1</sub>~ANN<sub>3</sub>:ANN<sub>1</sub>是初步诊断有无故障模型,

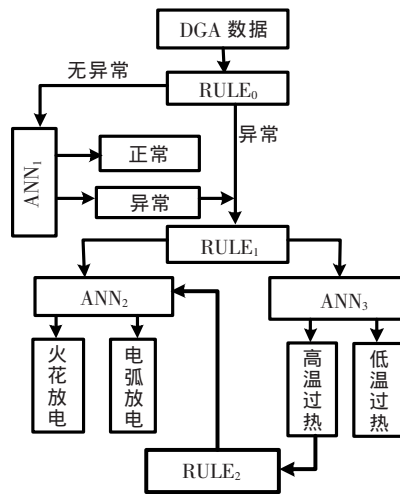


图2 CP组合神经网络模型结构图

ANN<sub>2</sub>是电性故障诊断模型,ANN<sub>3</sub>是热性故障诊断模型。这3个诊断模型分别采用CP网络模型作为基本分类器,通过对各自的训练样本集进行学习,以获得对具体判别规则的描述,并且对不同的神经网络模块可选用对其更具针对性的输入特征矢量。

RULE<sub>0</sub>: 根据电力系统多年的运行经验,采用《电力设备预防性试验规程》<sup>[9]</sup>中规定的色谱注意值及产气率作为区分变压器是否存在异常的界限。

RULE<sub>1</sub>和RULE<sub>2</sub>: 利用C<sub>2</sub>H<sub>2</sub>在总烃中所占的体积分数区分电性故障和热性故障<sup>[10,11]</sup>,笔者对收集的300个训练样本中C<sub>2</sub>H<sub>2</sub>在总烃中所占的体积分数进行统计后得出:电性故障中C<sub>2</sub>H<sub>2</sub>在总烃中所占比例为16.254%,热性故障中C<sub>2</sub>H<sub>2</sub>在总烃中所占的最大比例为5.01%。因此RULE<sub>1</sub>可以定义为:计算样本中C<sub>2</sub>H<sub>2</sub>在总烃中所占比例,如果大于16.254%,就进入ANN<sub>2</sub>,进行电弧、火花放电识别;如果小于5.01%,就进入ANN<sub>3</sub>,进行高温、低温过热识别;RULE<sub>2</sub>可以定义为:计算样本中C<sub>2</sub>H<sub>2</sub>在总烃中所占比例,如果是大于5.01%,而小于16.254%,就先进入ANN<sub>3</sub>,进行高温、低温过热识别,如果诊断结果是高温过热,则再进入ANN<sub>2</sub>,进行电弧、火花放电识别,从而避免系统无法识别高温过热加火花放电的故障。

## 2.2 数据样本集的建立

对故障实例进行大量统计后,选取了实际结论比较明确的420台次故障变压器的色谱数据作为故障样本集,各种类型故障在故障样本集中的分布情况见表1。

考虑到各种气体组分体积分数之间的巨大差异性及其分散性,为降低其相互之间由于量值差异造成的影响,对DGA原始数据进行归一化处理,以降低气体之间的互斥性<sup>[12]</sup>。笔者选用的归一化处理方法为:将H<sub>2</sub>、CH<sub>4</sub>、C<sub>2</sub>H<sub>6</sub>、C<sub>2</sub>H<sub>4</sub>和C<sub>2</sub>H<sub>2</sub>的值分别进行如下处理:H<sub>2</sub>/(H<sub>2</sub>+总烃)、CH<sub>4</sub>/总烃、C<sub>2</sub>H<sub>6</sub>/总烃、C<sub>2</sub>H<sub>4</sub>/总

表1 所收集变压器故障样本的分布情况

故障类型	样本总数	训练样本数	检验样本数
有、无故障	140	100	40
电弧放电	70	50	20
火花放电	70	50	20
高温过热	70	50	20
低温过热	70	50	20

烃、C<sub>2</sub>H<sub>2</sub>/总烃。其中总烃指所测CH<sub>4</sub>、C<sub>2</sub>H<sub>6</sub>、C<sub>2</sub>H<sub>4</sub>和C<sub>2</sub>H<sub>2</sub>值之和。

## 3 CP网络参数的确定

对于CP网络需要确定5个参数:输入层神经元个数、输出层神经元个数、竞争层神经元个数、训练速率和训练次数。网络的输入层神经元个数为5;输出层神经元个数为2;由于训练样本经过归一化处理,精度为0.0001,所以取训练速率为0.0001。但是对于CP网络的训练次数和竞争层的神经元,现今并没有确切的参数确定方法。由于CP网络训练次数和竞争层神经元个数都会影响到诊断正判率,所以合理的确定训练次数和竞争层神经元个数是整个模型诊断的关键。笔者将通过比较不同训练次数和不同竞争层神经元个数时的训练结果,综合考虑来确定这两个参数。首先通过比较不同训练次数和不同竞争层神经元个数情况下诊断的正判率来确定训练次数,然后在训练次数下找出诊断正判率趋于稳定的竞争层神经元个数点,从而作为竞争层神经元个数。具体的做法是每个模型的训练次数从3000开始,增加的步长为1000,竞争层的神经元从12开始,增加的步长是2。通过比较训练次数分别为3000~6000(或7000)、竞争层神经元个数为12~20情况下诊断的正判率,选取正判率最优情况下的训练次数,然后在训练次数中选取诊断正判率趋于稳定的竞争层神经元个数点,在该点的左右再各取一个点,比较这3点诊断的正判率,考虑各种因素,取最合理的一个点作为竞争层神经元的个数。

### 3.1 ANN<sub>1</sub>网络参数的确定

ANN<sub>1</sub>训练次数分别为3000、4000、5000、6000次且竞争层神经元个数为(12~20)时,训练的结果见图3。

由图3可以看出,当训练次数达到5000次、竞争层神经元个数为18(见图3(c))和训练次数为6000次、竞争层神经元个数为16(见图3(d))时,训练的效果都能达到最佳且趋于稳定。对于训练次数为5000次、竞争层神经元个数为16的CP网络模型而言,增加1000次训练所消耗的时间为1242s,增加2个竞争层神经元所消耗的时间为984s,相同

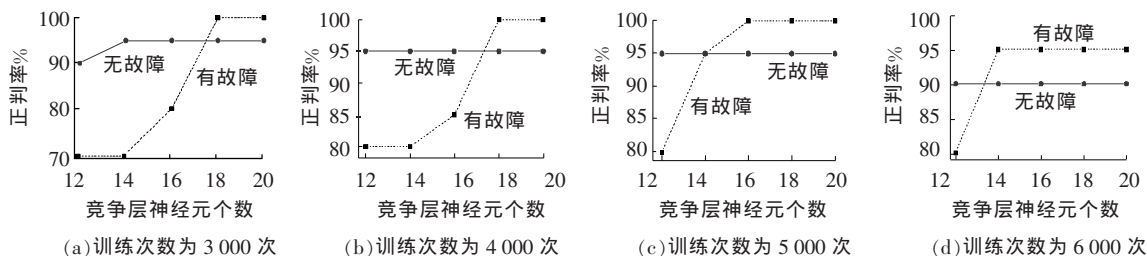


图3 不同参数下 ANN<sub>1</sub> 网络的训练结果

条件下增加1 000 次训练次数所消耗的时间要远大于增加2 个竞争层神经元所消耗的时间。因此,综合考虑神经网络训练的效果和训练的时间,训练次数决定选用5 000 次。

对竞争层神经元个数为17、18 和19 3 种情况随机训练3 次,并对诊断结果进行比较,见表2,其中竞争层神经元个数为18 和19 时诊断结果一样,比个数为17 时的效果好,考虑运算速度竞争层神经元的个数选为18。

表2 ANN<sub>1</sub> 不同竞争层神经元个数的情况比较

项目	神经元个数		
	17	18	19
误判组	5	3	3
效果不好组	1	1	1

### 3.2 ANN<sub>2</sub> 网络参数的确定

ANN<sub>2</sub> 训练次数为3 000、4 000、5 000、6 000、7 000 次且竞争层神经元个数为12~20 时,训练的结果见图4。其中,训练次数达到6 000 次、竞争层神




图4 不同参数下 ANN<sub>2</sub> 网络的训练结果

元个数为18(见图4(d))后能达到最佳效果,再增加参数改善效果不明显。综合考虑神经网络训练的效果和训练的时间,训练次数决定选用7 000 次。

对竞争层神经元个数为17、18 和19 3 种情况随机训练3 次,并对诊断结果进行比较,见表3,其中竞争层神经元个数为19 时诊断正判率最高,所以取竞争层神经元的个数为19。

表3 ANN<sub>2</sub> 不同竞争层神经元个数的情况比较

项目	神经元个数		
	17	18	19
误判组	10	8	7
效果不好组	8	11	4

### 3.3 ANN<sub>3</sub> 网络参数的确定

ANN<sub>3</sub> 训练次数为3 000、4 000、5 000、6 000 次




图5 不同参数下 ANN<sub>3</sub> 网络的训练结果

对竞争层神经元个数为15、16 和17 3 种情况随机训练3 次,并对诊断结果进行比较,见表4,其中竞争层神经元个数为17 的时候诊断正判率最高,所以取竞争层神经元的个数为17。

且竞争层神经元个数为12~20 时,训练结果见图5。其中,训练次数达到5 000 次、竞争层神经元个数为18(见图5(c))后能达到最佳效果,再增加参数改善效果不明显。综合考虑神经网络训练的效果和训练的时间,训练次数决定选用5 000 次。

## 4 仿真结果

### 4.1 诊断模型的检验

从文献中选取具有一定典型性的数据对构造的

表4 ANN<sub>3</sub>不同竞争层神经元个数的情况比较

项目	神经元个数		
	15	16	17
误判组	9	5	3
效果不好组	10	9	5

诊断模型进行检验,其中,电弧放电故障样本7例、火花放电故障样本4例、高温过热故障样本7例和低温过热故障样本7例。分别用IEC三比值法、改良电协研法和笔者所提出的CP组合神经网络诊断模型进行判别,结果见表5。

表5 不同方法下的正判率

方法名称	IEC三比值法	改良电协研法	基于CP组合神经网络诊断模型
正判率/%	60	72	88

从表5中可以看出,与规程中所推荐的IEC三比值及改良电协研法相比,基于CP组合神经网络的变压器诊断模型有较大优势。

#### 4.2 故障实例

某220kV变电站1号主变,型号为SFPSZ9-12000/220,投运时间为1997年6月。2003年8月6日色谱分析结果为H<sub>2</sub>:12.01 μL/L,CH<sub>4</sub>:9.61 μL/L,C<sub>2</sub>H<sub>6</sub>:6.06 μL/L,C<sub>2</sub>H<sub>4</sub>:12.1 μL/L,C<sub>2</sub>H<sub>2</sub>:11.6 μL/L。改良电协研法的编码为101,诊断结果为电弧放电。

经归一化处理后,输入数据样本为[0.233 7 0.244 1 0.153 9 0.307 3 0.294 6],ANN<sub>1</sub>诊断结果为[0.906 7 0.093 3],根据最大隶属度原则诊断为异常;C<sub>2</sub>H<sub>2</sub>在总烃中所占的比例为29.46%,大于RULE<sub>1</sub>规定的16.254%,应该属于电性故障,经混合归一化处理后,输入数据样本为[0.990 0 0.244 1 0.153 9 0.307 3 0.294 6],ANN<sub>2</sub>诊断结果为[0.082 7 0.917 3],根据最大隶属度原则诊断为火花放电故障。

检查结果:随时间推移,该站1号主变油色谱中的C<sub>2</sub>H<sub>2</sub>缓慢升高,2003年4月C<sub>2</sub>H<sub>2</sub>为11.84 μL/L,2003年11月对主变进行吊罩检查。110kV·A相套管下部瓷面距均压球约250mm处有一约7×7mm<sup>2</sup>的黑斑,经仔细检查为一气孔,内有碳黑。CP网络诊断结果与实际检查情况一致,改良电协研法诊断结果与实际检查情况不一致。

## 5 结论

(1)CP算法是一种非常有效的非线性特征提取方法,它是一种有教师学习和无教师学习算法的混合体,既具有良好的模式分类能力,又能解决训练时

间比较长、存在局部最优等问题,适于油浸式电力变压器油中溶解气体分析中气体组分与故障类型的复杂对应关系。

(2)针对CP网络训练次数和竞争层神经元个数对诊断正判率的影响,通过比较不同训练次数和不同竞争层神经元个数时的训练结果,综合考虑来确定这两个参数,结果表明该方法能很好确定CP网络参数。

(3)结合电力变压器故障诊断的特点,用CP组合神经网络判别不同的故障种类,这种处理方法提高了网络的训练效率和诊断的准确性。通过对诊断实例的计算和分析表明,利用基于对向传播算法的人工神经网络构建的组合诊断网络的诊断正判率高于改良电协研法和IEC三比值法诊断的正判率,将其应用于充油电力设备的故障诊断有良好的前景。

#### 参考文献:

- [1] BHATTACHARYYA S K, SMITH R E, HASKEW T A, et al. A Neural Network Approach to Transformer Fault Diagnosis Using Dissolved Gas Analysis Data [J]. North America Power Symposium, 1993(5): 121-123.
- [2] 颜湘莲, 文远芳. 模糊神经网络在变压器故障诊断中的应用研究[J]. 变压器, 2002, 39(7): 41-43.
- [3] 张勇, 李昕, 刘君华, 等. 数据融合技术在识别变压器油中四种特征气体的研究[J]. 中国电机工程学报, 2001, 21(8): 10-14.
- [4] 王由华, 刘振娟, 李宏光. 混合型集成神经网络故障诊断方法研究[J]. 北京化工大学学报(自然科学版), 2003, 30(1): 65-68.
- [5] 王哲, 陈学允. 树状放电的CPN识别方法[J]. 哈尔滨工业大学学报, 2000, 32(5): 5-9.
- [6] 飞思科技产品研发中心. 神经网络理论与MATLAB 7实现[M]. 北京: 电力工业出版社, 2005.
- [7] 丁晓群, LIU Y, 林钟云. 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.
- [8] 操敦奎. 变压器油中气体分析诊断与故障检查[M]. 北京: 中国电力出版社, 2005.
- [9] 中华人民共和国电力工业部. 电力设备预防性试验规程 DL/T 596-1996 [S]. 北京: 中国电力出版社, 1996.
- [10] 操敦奎. 变压器油中气体分析与故障检查[M]. 北京: 中国电力出版社, 2005.
- [11] 孙才新, 陈伟根. 电气设备油中气体在线监测与故障诊断技术[M]. 北京: 科学出版社, 2003.
- [12] 钱政, 杨莉, 严璋. 组合神经网络模型中典型训练样本集的选取[J]. 高压电技术, 1999, 25(4): 1-6.