

文章编号: 1006-4729(2004)04-0029-05

# 人工智能在变压器故障检测中的应用

刁婷婷

(武汉大学 电气工程学院, 湖北 武汉 430072)

**摘要:** 提出一种新型人工智能的应用, 运用模糊控制理论将人工神经网络、专家系统技术结合起来, 构成 ESANN 系统, 对运行中的变压器故障进行诊断. 重点介绍了 ESANN 的操作结构, 并通过现场实例说明了该智能型系统较 ANN 和 ES 单独运行时具有更优性能.

**关键词:** 故障诊断; 人工神经网络; 专家系统

中图分类号: TP18; TM407 文献标识码: A

## Application of the Intelligent Diagnosing System for Power Transformer Fault

DIAO Ting-ting

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

**Abstract:** The AI (artificial intelligence) techniques include artificial neural network (ANN), expert system (ES), fuzzy logic, evolutionary algorithm. In serious non-linear system, AI performance could be superior to other methods. In this paper, a hybrid algorithm ESANN, which combines expert system (ES) with artificial neural network (ANN), is applied to transformer fault diagnosis using dissolved gas-in-oil analysis (DGA). Test results show that the system has better performances than ES or ANN used separately.

**Key words:** transformer fault diagnosis; artificial neural network; expert system

笔者在油中气体色谱分析方法 (DGA) 的基础上提出了将人工神经网络和专家系统结合起来的 ESANN 方法. ESANN 利用了人工神经网络和专家系统的各自优势, 并以此为基础作了深层改良. 电力变压器是电力系统的重要设备, 其异常情况的诊断对整个电力系统的安全性、可靠性极为重要. 提高变压器运行维护和技术管理水平, 已成为保障供电可靠性的重要手段.

众所周知, 变压器的故障诊断是个非常复杂的问题, 许多因素如变压器容量、电压等级、绝缘性能、工作环境、运行历史, 甚至不同厂家的产品

等, 均会对诊断结果产生影响. 各种试验方法和测试仪器只是起到获得变压器运行状态信息的作用, 而根据这些信息做出正确判断则必须要依靠丰富的运行维护经验. 由于人类经验在该问题中的重要作用, 采用人工智能技术开发智能化的故障诊断系统就显得很有实际意义.

专家系统 (ES) 和人工神经网络 (ANN) 是目前研究较多的两个领域. 但专家系统技术本身存在着知识获取“瓶颈”, 其主要问题有:

(1) ES 的知识库获取大部分来自人工移植, 专家将知识移植计算机, 过程费时费力;

(2) ES 的知识库只能解决该领域的问题, 解决相似领域的问题的能力很差;

(3) 有写 ES 却没有自组织记忆和自学能力, 所以不能在实际应用中得到升级;

(4) 知识库越大, 处理速度越慢, 效率越低. 但准确性和效率不可兼得.

ANN 因具有自组织、自学习能力, 能克服传统 ES 在这方面的不足. 通过运用油中气体分析 (DGA) 技术, ESANN 在变压器故障诊断方面得到了初步应用. 在众多的 ANN 模型中, BP 网络由于具有良好的模式分类能力, 很适合用于模式识别、故障诊断等.

### 1 ESANN 系统流程

#### 1.1 ESANN 系统结构框图

图 1 所示的 ESANN 系统包括以下几个部分:

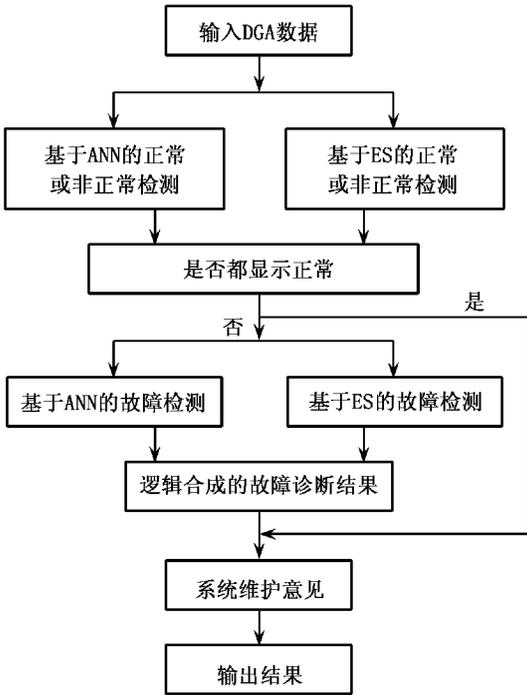


图 1 ESANN 流程

(1) ANN 检测, 检测结果为正常或不正常, 为进一步检测提供依据;

(2) ES 检测, 检测结果为正常或不正常, 为进一步检测提供依据;

(3) 运用 ANN 进行故障分析;

(4) 应用 ES 进行故障分析;

(5) 对故障诊断结果进行综合逻辑合成;

(6) 对系统给出维护建议, 估计下次检测的间隔时间, 实现正确的维护动作.

#### 1.2 输入数据

输入数据包括以下几个方面.

(1) 油中溶解气体的含量 ( $\mu\text{l/l}$ ) 和产气速率 ( $\text{ml/h}$ ), 包括  $\text{CH}_4$ ,  $\text{C}_2\text{H}_4$ ,  $\text{CO}$ ,  $\text{CO}_2$ ,  $\text{H}_2$ ,  $\text{C}_2\text{H}_6$ ,  $\text{C}_2\text{H}_2$ ,  $\text{O}_2$ ,  $\text{C}_2\text{H}_2$ ,  $\text{N}_2$ , 是诊断过程的主要输入参数.

(2) 油样信息, 包括日期样本 (用来和历史的产气趋势作对比)、所取气体样本的位置 (用来决定相关气体的权值).

(3) 变压器的相关信息, 包括变压器容量、电压等级、铁心类型、级对数、绝缘性能、工作环境、运行历史.

(4) 背景信息, 包括变压器序列号、变电站信息、鉴定的油样数目、故障报告的历史数据等.

以上的信息在诊断过程中并不是都需要的, 虽然变压器油中溶解气体受到许多因素的影响, 但是就目前看来, 只有一小部分能用于故障诊断. 同时, 为了系统的数据库能得到及时的更新以获得新的诊断规则, 在数据库中保存尽可能多的信息是很重要的.

#### 1.3 诊断的逻辑输出

诊断的结果输出包括故障类型、诊断结果的可信度、复检时间、维护建议. 以下所列的是几种主要的故障类型:

- (1) 过热 (OH);
- (2) 油过热 (OHO);
- (3) 低能量放电 (LED);
- (4) 高能量放电或电弧 (HEDA);
- (5) 纤维素绝缘质损坏 (CD).

#### 1.4 数据库的建立

在运用 ESANN 诊断的过程中, 每一个样本都记录在一个动态的数据库中, 方便下次作为训练数据库来使用. 诊断也是建立在该记录的基础上, 同时诊断的结果被存入另一个动态数据库中, 便于与历史记录进行比较, 及时更新诊断规则.

### 2 ESANN 的工作原理

在 ESANN 系统中, 将有 4 个独立的 ANN 单元被用于故障检测, 所采用的是具有 3 隐层的以

BP 算法进行训练的 ANN. BP 网络, 即前向多层神经网络的反传学习理论 (Back-Propagation, 缩写为 BP, 最早是由韦伯斯在 1974 年提出来的)。

在众多的 ANN 类型中, 采用误差反向传播 (Error Back-Propagation) 算法作为训练算法的 BP 网络, 由于具有良好的模式分类能力, 尤其适用于故障诊断, 因此在故障诊断系统中具有广泛的应用前景。

ESANN 采用 Microsoft Visual C++ 编写, 下面详细介绍 ESANN 各个模块。

### 2.1 基于 ANN 的正常或非正常检测

输入数据为故障气体的含量 ( $\mu\text{L/L}$ ) 和产气速率 ( $\text{ml/h}$ ), 通过两个 ANN 网络判断是否正常, 如图 2 所示。

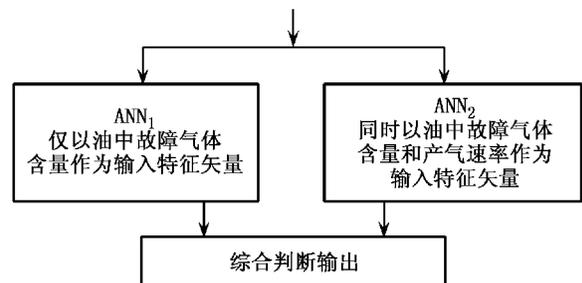


图 2 基于 ANN 的正常或非正常检测

输入数据分别经过两个独立的检测环节, 只有当两个环节的输出都是正常时, 才输出“正常”, 否则输出“非正常”。

### 2.2 基于 ES 的正常或非正常检测

基于 ES 的正常或非正常检测如图 3 所示。

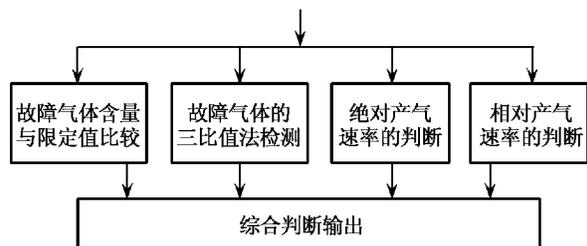


图 3 基于 ES 的正常或非正常检测

输入的数据分别经过 4 个独立的检测环节, 只有当 4 个环节的输出都是正常时, 才输出“正常”, 否则输出“非正常”。4 个检测环节的判据分

别为: 故障气体是否在限定值内 (采用 IEEE C57.104 标准); 三比值法: 绝对产气速率; 相对产气速率。

### 2.3 基于 ANN 的故障检测

当上述判断的结果是“非正常”时, 数据就被分别送进 ANN 和 ES 进行故障检测判断。如图 4 所示。

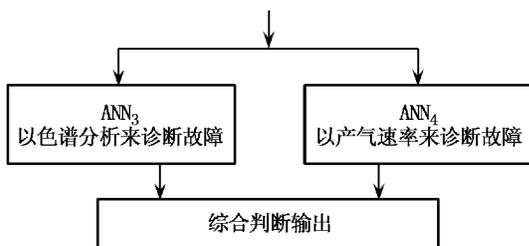


图 4 基于 ANN 的故障检测

在 ANN 检测环节中, 运用了两个独立的 ANN 环节来分别判断主要故障。在笔者所做的大量前期研究中, 这种结构比图 2 输出的单个 ANN 网络具有更高的诊断精度, 样本训练时间也将大大缩短。

### 2.4 基于 ES 的故障检测

基于 ES 的故障检测如图 5 所示。

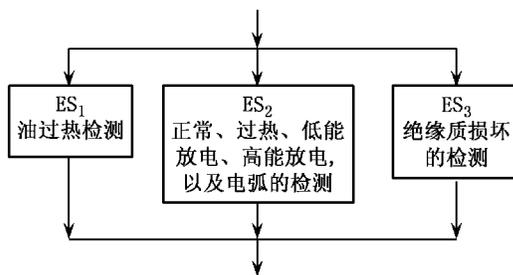


图 5 基于 ES 的故障诊断

整个诊断环节包括 3 个部分, 其核心部分包括检测正常 (Normal)、过热 (OH)、低能放电 (LED)、高能放电和电弧 (HEDA), 参考标准为 IEC599. 油过热 (OHO) 和绝缘质破坏 (CD) 的判断标准来自 Doble 准则。

关于该准则举例如下:

If  $(\text{CO} > x \text{ ppm}) \text{ AND } (\text{CO} / \text{CO}_2 < y)$  then there is a CD fault

### 2.5 诊断结果的综合逻辑合成

经过大量的数据验证, ANN 和 ES 诊断结果的逻辑合成在很大程度上提高了诊断精度, 如图 6 所示.



图 6 综合故障诊断

该合成过程包括 3 个步骤, 即: 在一个特定的诊断类型中, 以  $ESi$  表示 ES 诊断结果的可信度,  $ANNi$  表示 ANN 诊断结果的可信度, 那么, 在诊断过热、油过热、低能放电和绝缘质破坏等故障类型中, 可运用以下产生式规则.

$$\text{If}(ANNi > 0.6 \text{ OR } ANNi < 0.4) \text{let } COMi = ANNi$$

$$\text{else let } COMi = \sqrt{ESi \times ANNi}$$

式中,  $COMi$  —— 经过逻辑合成后该种故障发生的可信度.

在这几种故障情况下, 由于经良好训练的 ANN 样本具有更高的诊断精度, 所以 ANN 的输出主导最后的合成输出. 如果 ANN 的输出是在 0.5 左右, 具有弱倾向性, 则需要从 ES 获得信息来得出最后的诊断结果.

在故障类型为高能放电及电弧时, 经过长期的研究发现, ES 在诊断这种故障时具有更高的可信度. 因此, 合成规则用下式表示

$$\text{If}(ESi > 0.9) \text{let } COMi = ESi$$

$$\text{else let } COMi = \sqrt{ESi \times ANNi}$$

如果专家系统的诊断输出结果是次要故障如低能放电或者低温过热, 而变压器的实际情况可能是正常的, 这时需要通过基于 ANN 的正常或非正常检测的结果来确认, 如图 1 中的第 2 步.

当判断出存在某种类型的故障、但产气速率又不很高时, 可能存在非正常情况, 这个过程在图 1 中的第 3 步进行.

## 3 实例及讨论

### 3.1 系统的整体性能

本文所讨论的系统是经过 220 组数据训练的样本, 包括 22 个正常情况. 其中 150 组数据被用来训练 ANN 网络, 70 个数据被用作实验测试. 表 1 所示的是 ESANN 与 ANN 及 ES 单独运行时的准确性比较.

表 1 训练样本的测试结果 %

故障类型	ESANN		ANN		ES	
	训练	测试	训练	测试	训练	测试
过热	100	97	100	95	97.3	90
油过热	100	95	100	95	99.3	90
低能量放电	100	95	100	95	95.2	91
高能量放电或电弧	99.7	97	100	95	96.7	85
纤维素绝缘质损坏	99.7	93.3	100	95	90.7	91.7

### 3.2 实例讨论

测试实例数据如表 2 所示.

表 2 测试实例数据

例子	实际故障类型	输入								输出		
		容量 /MVA	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	CO	CO <sub>2</sub>	OH		
			/μL·L <sup>-1</sup>								ANN	ES
1	OH, CD	260	22	40	1	6	36	199	3 020	1.00	0.01	1.00
2	OH, OHO, CD	—	1 770	3 660	78	8 480	1070	862	7 940	1.00	0.99	1.00
3	HEDA	46.6	88	30	29	35	10	134	5 090	0.12	0.01	0.12
4	HEDA	105	33	36	9	40	9	54	443	0.00	0.01	0.00
5	LED	11.5	142	3	1	8	2	146	2 230	0.00	0.01	0.00

例子	实际故障类型	输出											
		OHO			LED			HEDA			CD		
		ANN	ES	ESANN									
1	OH, CD	0.00	0.01	0.00	0.00	0.01	0.00	0.01	0.60	0.05	0.92	0.01	0.92
2	OH, OHO, CD	1.00	0.99	1.00	0.00	0.01	0.00	0.00	0.01	0.00	0.42	0.99	0.65
3	HEDA	0.00	0.01	0.00	0.00	0.01	0.00	0.99	0.99	0.99	0.57	0.01	0.08
4	HEDA	0.00	0.01	0.00	0.00	0.01	0.00	0.00	0.99	0.99	0.00	0.01	0.00
5	LED	0.00	0.01	0.00	0.65	0.01	0.65	0.00	0.01	0.01	0.00	0.01	0.00

在例 1 中, ES 判断结果为无 CD 故障, 但可能存在 HEDA 故障, 因为 CD 故障的特征气体 CO 低于它的限值而同时存在少量的  $C_2H_2$  (HEDA 故障的特征气体). 但是在该种情况下, 由于 ANN 不是简单的基于限值来判断, 而是通过自适应的推理过程得到结果, 因此, 具有很好的诊断精确度.

在例 2 中, ES 的诊断结果显示存在 OH, OHO, CD 故障, 因为特征气体  $CH_4$ ,  $C_2H_4$ , CO,  $C_2H_6$  都明显过量. ANN 在判断 CD 故障时, 这些特征气体无明显过量, 可能是由于缺少同类型的样本所致.

在例 3 中, ANN 判断 CD 故障的可能性为 0.57. 在例 3 中, 由于 CO 含量低于故障限值, 因此, 排除了 CD 故障.

在例 4 中, ES 明确判断存在 HEDA 故障, 因为在这两种情况下,  $C_2H_2$  的值都较高, 而  $C_2H_4$ ,  $C_2H_6$  的值都较低.

在例 5 中, ES 并没有判断出 LED 故障的存在, 但认为有存在 HEDA 故障的可能性, 可能是由于产气速率没有达到 LED 故障判断值下限, 并且存在少量  $C_2H_2$  的缘故. 同时, 由于存在过量的  $H_2$ , 而其他可燃气体含量很少, ANN 判断出 LED 故障, 并排除了存在 HEDA 故障的可能性. ESANN 的输出结果是正确的.

在我们的测试过程中, 曾发生 ANN 和 ES 都判断正确, 但综合输出结果不正确的情况. 这种情况非常少见, 对此, 我们将作进一步跟踪研究.

综上所述, ESANN 系统诊断故障的准确率明显优于 ES 与 ANN 单独诊断时的准确率.

## 4 结 论

ANN 采用的对单个故障诊断具有最优性能的 3 隐层网络结构, 通过选择合适方法进行样本训练, 使之具有更高的诊断可靠性和精确度, 并且可被新样本经验值重新训练. 故障的综合诊断输出利用了 ANN 和 ES 各自的优势, 测试结果表明, ESANN 可得到比 ES 和 ANN 单独使用时更精确的诊断结果.

专家系统和人工神经网络的结合是实现模拟人类智能思维的必由之路, 但对它们的开发是一个长期的渐进的过程, 需要不断创新和完善.

## 参考文献:

- [1] 丁晓群, Lin 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.
- [2] 杨启平, 薛五德, 兰之达. 变压器故障人工智能诊断系统的研究 [J]. 高电压技术, 2003, 29(3): 12~15.
- [3] Zhang Y, Ding X, Liu Y, et al. An Artificial Neural Network Approach to Transformer Fault Diagnosis [J]. IEEE Trans. on PWRD, 1997, 11(4): 1836~1841.
- [4] 徐文, 王大忠, 周泽群, 等. 结合遗传算法的人工神经网络在电力变压器故障诊断中的应用 [J]. 中国电机工程学报, 1997, 17(2): 109~112.
- [5] Liu C E, Ling J M, Huang C L. An Expert System for Transformer Fault Diagnosis Using Dissolved Gas Analysis [J]. IEEE Trans. on Power Delivery, 1993, 18(1): 231~238.