

# 航空发动机诊断知识的动态获取与柔性诊断技术

陈 果<sup>1</sup> 宋兰琪<sup>2</sup> 文振华<sup>1</sup> 张占纲<sup>2</sup>

1. 南京航空航天大学, 南京, 210016

2. 空军装备研究院航空装备研究所, 北京, 100076

**摘要:** 针对军用航空发动机的状态监测与故障诊断问题, 研究了航空发动机的诊断知识动态获取模型及柔性诊断技术。建立了可扩展诊断样本库, 实现样本库中故障征兆和故障模式的动态增减, 以增加系统的柔性和可扩展性; 运用粗糙集理论对样本集进行处理, 实现冗余属性的约简、冗余样本的去除及样本冲突的消除; 用神经网络通过对处理后的样本集进行学习以动态获取知识, 将实际诊断样本输入到训练好的神经网络模型即可得到诊断结果。整个诊断过程具有充分的可扩展性和柔性, 当有新样本加入时, 按上述步骤进行处理即可实现诊断知识的动态获取和诊断。算例表明了方法的正确性和有效性。

**关键词:** 航空发动机; 故障诊断; 知识获取; 柔性; 粗糙集; 神经网络

**中图分类号:** TH165.3      **文章编号:** 1004 - 132X(2006)09 - 0923 - 04

## Knowledge Dynamic Acquisition and Flexible Diagnosis Technique of Aero - Engines

Chen Guo<sup>1</sup> Song Lanqi<sup>2</sup> Wen Zhenhua<sup>1</sup> Zhang Zhangang<sup>2</sup>

1. Nanjing University of Aeronautics and Astronautics, Nanjing, 210016

2. Aerospace Equipment Institute of Air force Equipment Academy, Beijing, 100076

**Abstract:** Aimed at the military aircraft aero - engine condition monitoring and fault diagnosis, the aero - engine diagnosis knowledge dynamic acquisition model and flexible diagnosis technique were studied. Firstly, a sample database which can be extended was established to accommodate the dynamic change of fault symptoms and fault modes, and flexibility of diagnosis system was increased greatly. Secondly, the sample set was pre - processed by Rough Sets (RS) theory, and the redundancies of samples' attributes and redundant samples were removed. Thirdly, Artificial Neural Network (ANN) was trained by the processed samples, and diagnosis knowledge was obtained. Finally, a practical diagnosis sample was input into trained ANN, and the results can be obtained. Whole diagnosis process has full flexibility and adaptability. When a new sample is added, above mentioned steps are repeated, and a new knowledge can be dynamically obtained. In the end, an example is used to verify the validity and correctness of the diagnosis model.

**Key words:** aero - engine; fault diagnosis; knowledge acquisition; flexibility; rough set (RS); neural network (NN)

## 0 引言

目前, 对航空燃气涡轮发动机故障诊断的研究主要集中在如下方面: 利用气路参数对发动机气路性能和传感器进行诊断<sup>[1,2]</sup>; 利用振动<sup>[3]</sup>、滑油<sup>[4]</sup>及孔探<sup>[5]</sup>信号对发动机机械性能进行诊断; 利用专家系统<sup>[6,7]</sup>或数据融合技术<sup>[8~10]</sup>对发动机进行综合性能评估和故障诊断。

对于航空发动机的状态监测与故障诊断, 目前总的发展趋势是, 将先进的人工智能技术(人工神经网络、专家系统、支持向量机等)运用于故障诊断中, 以解决经典数学建模困难的问题, 从而实现不确定的、模糊的和非线性的推理或映射, 最终解决经典数学不能解决或很难解决的问题。

运用人工智能技术进行智能诊断专家系统研

究, 知识的获取是关键, 因此收集大量的故障征兆和故障模式对应的样本至关重要。文献[11,12]提到利用试验、模拟和远程的方法来获取大量样本。但在实际使用过程中, 发动机的故障征兆经常会改变, 如在气路故障诊断中, 经常会增加传感器以测定更多的性能参数, 在基于光谱分析的磨损监测中, 作为故障征兆的光谱元素经常要进行取舍。另一方面, 故障模式也会随着发动机的使用而不断改变, 不同使用时期具有不同的故障模式, 因而样本库必须能适应这种变化, 即在建立诊断样本时, 需要实现故障征兆和故障模式的自由增减。然而, 实现样本库的征兆和故障模式的增减, 将使样本库产生不完备信息和冲突信息, 大大增加了样本的处理难度和智能诊断难度。在征兆和故障可扩展的样本下如何实现知识获取, 将

收稿日期: 2005 - 06 - 10

直接体现智能诊断专家系统的诊断性能。但目前的研究几乎均将样本的征兆和故障模式视为固定不变。

本文将建立航空发动机故障诊断知识的动态获取模型,以实现故障的智能柔性诊断,提高诊断系统对环境变化的适应能力和可扩展能力。要实现航空发动机故障模式的正确分类,需要融合发动机的性能、诊断和油样分析等参数,实现融合诊断,其核心问题是要考虑实际诊断过程中,当发动机待融合的分析方法和参数需要动态取舍时所产生的故障征兆的增减,以及新的故障出现导致样本库中故障模式发生动态改变时智能诊断专家系统知识的动态获取。其关键技术包括可扩展样本库技术、基于粗糙集理论的样本预处理技术及神经网络知识获取技术等。

### 1 可扩展样本库

基于神经网络的智能诊断专家系统中,知识的获取是通过对样本集的训练来完成的。因此,为了从变化的征兆和故障模式中动态获取诊断知识,首先需要构造可扩展样本库,该样本库能够对故障征兆和故障模式实现动态增减,从而增强专家系统对环境变化的适应能力,具体实施流程如图 1 所示。在具体实施过程中,首先在系统设置中对故障征兆进行设置,包括故障征兆的描述和编号,在故障设置中对故障模式进行设置,包括故障描述和编号。其次,采用数据访问对象(data access object,DAO)技术建立样本库,在样本库中,每个故障对应一张表,每张表的每个字段则对应故障征兆。因此,如果在系统设置中要增加一个故障征兆,则只需在样本库的所有表中增加一个字段即可,如果在系统设置中要增加一个故障模式,则只需在样本库中再新建一张表即可。

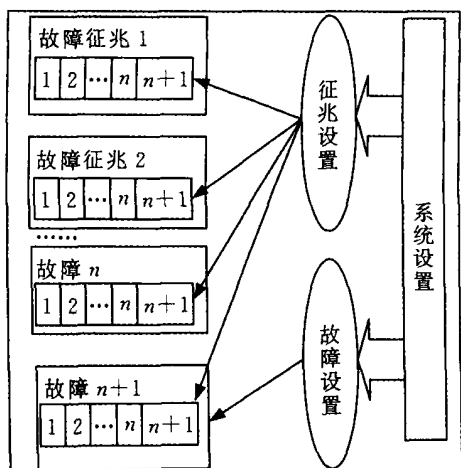


图 1 可扩展样本库的实施方案

### 2 基于粗糙集理论的样本预处理

由波兰学者 Pawlak<sup>[13]</sup>提出的粗糙集(rough set)理论具有很强的定性分析能力,即不需要预先给定某些特征或属性的数量描述的先验知识,只需直接从给定问题的描述集合出发,通过不可分辨关系和不可分辨关系类确定给定问题的近似域,从而找出问题中的内在联系规律。

#### 2.1 原始样本不完备信息的补齐

在获取样本多征兆特征时,由于测试和记录的原因,可能导致在某些实例记录(样本)上没有对应征兆特征的属性值,从而形成了原始样本的信息不完备性。显然,该征兆特征的属性值可能正常,也可能异常。因此,本文将缺损值作为一个特殊的取值(-1)考虑,来实现原始样本不完备信息的补齐。

#### 2.2 原始样本数据的离散

离散化本质上可归结为利用选取的断点来对条件属性构成的空间进行划分的问题,选取断点的过程也是合并属性值的过程,通过合并属性值,减少属性值的个数,减小问题的复杂度,这也有利于提高知识获取过程中所得到的规则知识的适应度。本文通过与标准诊断界限值进行比较,来实现对数据的离散。

#### 2.3 决策表属性的约简

原始样本数据库构成的决策表的属性,通常不可避免地具有冗余的征兆特征信息,这些多余的征兆特征不但使后续的故障识别变得复杂,而且也将降低识别精度。所以需要决策表的冗余属性进行约简以得到更为简洁的决策表。

约简的定义<sup>[14]</sup> 对于一给定的决策表  $S = (U, C \cup \{d\})$ , 条件属性集合  $C$  的约简是  $C$  的一个非空子集  $C'$ , 它满足:

$$(1) IND(C', \{d\}) = IND(C, \{d\});$$

$$(2) 不存在 C \subset C', 使 IND(C', \{d\}) = IND(C, \{d\}).$$

集合  $C$  的所有约简的集合记为  $RED(C)$ , 其交集为  $C$  的核  $CORE(C)$ , 它表示了决策表最重要的属性。

#### 2.4 基于规则置信度的样本冲突解决

通过决策表信息补齐、离散、属性约简后得到的决策表中,每条样本记录均对应于一条规则。这样可以求得规则的置信度<sup>[14]</sup>,即:

设决策表  $S = (U, C \cup \{d\})$ ,  $C$  是属性集合,  $\{d\}$  为决策属性集,决策规则  $A \rightarrow B$  的置信度为

$$CF(A \rightarrow B) = \frac{|X \cap Y|}{|X|} \quad (1)$$

$$X = \{x | x \in U, A_x\}, Y = \{x | x \in U, B_x\}$$

式中,  $A$  为规则的条件;  $B$  为规则的结论;  $A_x$  表示实例  $x$  的条件属性满足  $A$ ,  $B_x$  表示实例  $x$  的条件属性满足  $B$ , 即  $X$  是条件属性满足  $A$  的实例集合,  $Y$  是决策属性满足  $B$  的实例集合。

显然, 对于相互冲突样本, 其条件属性完全一样, 而决策属性不相同。根据规则置信度的计算可看出, 冲突样本的规则置信度将不相同, 它取决于有多少样本支持某规则。依据规则置信度, 去掉置信度低的规则及其支持的样本, 从而达到消除样本冲突的目的。

最后, 将条件属性和结论属性均相同的重复样本仅保留一个, 这样, 原始样本数据库通过上述处理后, 即可得到信息完备的、离散的、协调的诊断样本。

### 3 基于神经网络的知识获取和智能诊断

神经网络具有超强的非线性映射能力和容错性, 同时可通过对训练样本的学习来获取知识, 因而避免了传统专家系统知识规则的组合爆炸问题。其推理过程很简单, 只需将待诊断的样本输入到训练好的网络即可输出诊断结果。但是, 神经网络的知识获取依赖于训练样本, 如果训练样本特征过多, 样本冲突严重, 将导致网络很难收敛, 同时诊断精度将很低。本文将原始样本数据通过基于粗糙集理论的补齐、离散、属性约简及冲突消除后得到信息完备、离散的及相互协调的样本, 将其作为神经网络的训练样本, 从而大大提高了训练速度和诊断精度。

神经网络的模型通常采用三层前向神经网络<sup>[15]</sup>, 并运用 BP 算法进行训练学习。网络输入节点数由训练样本的征兆特征数确定, 网络输出节点数由故障模式的数目确定。

### 4 实例

为了验证本文提出的航空发动机柔性智能诊断系统的有效性, 同时说明本文诊断方法的流程, 下面用一模拟诊断实例进行分析。

设对某航空发动机的滑油进行了光谱分析, 获得了一组实例, 如表 1 中的样本 1 ~ 4 所示, 样本 5 ~ 7 为增加了问题征兆“发动机是否有明显征兆”。表 2 ~ 表 5 为对此原始样本库进行基于粗糙集理论处理后所得到的结果, 表中, FEC 和 CUC 分别代表 Fe 元素和 Cu 元素的浓度, FET 和 CUT 分别代表 Fe 元素和 Cu 元素的浓度梯度, 表中的值为对浓度值和浓度梯度值的判断结果(正

常、警告或超标)。计算过程如下:

(1) 补齐 表 1 中, 样本 1 ~ 4 中问题征兆的值空缺, 采用特殊值 - 1 进行补齐, 如表 2 所示。

表 1 某设备的铁谱和光谱分析结果与对应的设备故障模式

样本编号	光谱分析				提问	故障模式: 主轴承严重磨损
	FEC	FET	CUC	CUT	发动机是否没发现明显征兆	
1	0.5 = “警告”	1 = “异常”	- 1 = “未知”	- 1 = “未知”		0.7
2	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”		0.5
3	1 = “异常”	1 = “异常”	- 1 = “未知”	- 1 = “未知”		0.8
4	0 = “正常”	1 = “异常”	- 1 = “未知”	- 1 = “未知”		0.4
5	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	0 = “否”	0.1
6	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	0 = “否”	0.1
7	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	0 = “否”	0.3
8	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	1 = “是”	0.7

表 2 样本信息补齐结果

样本编号	光谱分析				提问	故障模式: 主轴承严重磨损
	FEC	FET	CUC	CUT	发动机是否没发现明显征兆	
1	0.5 = “警告”	1 = “异常”	- 1 = “未知”	- 1 = “未知”	- 1 = “未知”	0.7
2	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	- 1 = “未知”	0.5
3	1 = “异常”	1 = “异常”	- 1 = “未知”	- 1 = “未知”	- 1 = “未知”	0.8
4	0 = “正常”	1 = “异常”	- 1 = “未知”	- 1 = “未知”	- 1 = “未知”	0.4
5	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	0 = “否”	0.1
6	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	0 = “否”	0.1
7	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	0 = “否”	0.3
8	1 = “异常”	0 = “正常”	- 1 = “未知”	- 1 = “未知”	1 = “是”	0.7

表 3 样本信息约简结果

样本编号	光谱分析		提问	故障模式: 主轴承严重磨损
	FEC	FET	发动机是否没发现明显征兆	
1	0.5 = “警告”	1 = “异常”	- 1 = “未知”	0.7
2	1 = “异常”	0 = “正常”	- 1 = “未知”	0.5
3	1 = “异常”	1 = “异常”	- 1 = “未知”	0.8
4	0 = “正常”	1 = “异常”	- 1 = “未知”	0.4
5	1 = “异常”	0 = “正常”	0 = “否”	0.1
6	1 = “异常”	0 = “正常”	0 = “否”	0.1
7	1 = “异常”	0 = “正常”	0 = “否”	0.3
8	1 = “异常”	0 = “正常”	1 = “是”	0.7

表 4 样本信息置信度计算结果及冲突消除

样本编号	光谱分析		提问	故障模式: 主轴承严重磨损	置信度
	FEC	FET	发动机是否没发现明显征兆		
1	0.5 = “警告”	1 = “异常”	- 1 = “未知”	0.7	1
2	1 = “异常”	0 = “正常”	- 1 = “未知”	0.5	1
3	1 = “异常”	1 = “异常”	- 1 = “未知”	0.8	1
4	0 = “正常”	1 = “异常”	- 1 = “未知”	0.4	1
5	1 = “异常”	0 = “正常”	0 = “否”	0.1	0.67
6	1 = “异常”	0 = “正常”	0 = “否”	0.1	0.67
7	1 = “异常”	0 = “正常”	0 = “否”	0.3	0.33
8	1 = “异常”	0 = “正常”	1 = “是”	0.7	1

表 5 神经网络的训练样本

样本 编号	光谱分析		提问	故障模式: 主轴承严重 磨损
	FEC	FET	发动机是否发现 明显征兆	
1	0.5="警告"	1="异常"	- 1="未知"	0.7
2	1="异常"	0="正常"	- 1="未知"	0.5
3	1="异常"	1="异常"	- 1="未知"	0.8
4	0="正常"	1="异常"	- 1="未知"	0.4
5	1="异常"	0="正常"	0="否"	0.1
6	1="异常"	0="正常"	0="否"	0.1
8	1="异常"	0="正常"	1="是"	0.7

(2) 属性约简 从表 2 可看出, Cu 元素的浓度和增长率对诊断结果无影响, 因此是冗余征兆特征, 故将其约简, 结果见表 3。

(3) 置信度计算 按式(1) 计算样本形成的规则的置信度, 结果见表 4。

(4) 形成神经网络训练样本 最后根据样本处理结果, 形成神经网络的训练样本, 见表 5。

为了对比处理前后样本对神经网络诊断结果的影响程度, 利用表 3(处理前) 和表 5(处理后) 的样本作为神经网络的训练样本, 分别构造三层 BP 神经网络模型 5-30-3(处理前) 和 3-30-3(处理后), 神经网络的训练精度要求为  $10^{-5}$ , 最大训练步数为 1000。用 MATLAB 神经网络工具箱进行模拟, 结果表明, 对于未经过处理的样本, 网络 5-30-3 达到最大训练步数后, 其收敛精度只有 0.079, 而处理后的样本, 网络 3-30-3 仅用了 16 步就收敛到要求的训练精度  $10^{-5}$ 。由此可见, 对原始样本数据进行处理, 不仅可以减小神经网络结构的复杂性, 而且可以大大提高其收敛速度和诊断精度。

本文的航空发动机诊断知识动态获取与智能诊断模型已经应用于与某航空装备研究所联合开发的发动机滑油监控专家系统(engine oil monitoring expert system, EOMES) 中, 并得到了实际应用。

## 5 结论

(1) 为了提高航空发动机诊断系统的适应性、灵活性、可扩展性及可维护性, 提出了诊断知识的动态获取模型及柔性智能诊断新技术, 要求在柔性诊断过程中, 故障样本的征兆特征、故障模式可以动态改变。

(2) 采用 DAO 数据库技术, 建立了可扩展样本库, 以适应征兆和故障模式的增减。

(3) 采用粗糙集理论解决样本数据库中由于数据动态变化而产生的信息不完备、不确定及样本冲突等问题, 阐述了信息补齐、离散、属性约简和基于规则置信度的样本冲突消除。

(4) 将处理后的样本作为神经网络的训练样

本, 利用神经网络进行故障智能诊断。

(5) 算例验证了本文航空发动机诊断知识获取与柔性智能诊断技术的可行性和有效性。

## 参考文献:

- [1] Doel D L. Temper - a Gas Path Analysis Tool for Commercial Jet Engines. Transactions of the ASME Journal of Engineering for Gas Turbines and Power, 1994, 116(1): 82~89
- [2] 范作民, 孙春林, 林兆福. 发动机故障方程的建立与故障因子的引入. 中国民航学院学报, 1994, 12(1): 1~14
- [3] 杨建国, 孙扬, 郑严. 基于小波和模糊神经网络的涡喷发动机故障诊断. 推进技术, 2001, 22(2): 114~117
- [4] 左洪福. 发动机磨损状态监测与故障诊断技术. 北京: 航空工业出版社, 1995
- [5] Chen Guo. 3D Measurement and Stereo Reconstruction for Aeroengine Interior Damage. Chinese Journal of Aeronautics, 2004, 17(3): 149~151
- [6] 陈果, 左洪福. 基于知识规则的发动机磨损故障诊断专家系统. 航空动力学报, 2004, 19(1): 23~29
- [7] Torella G, Torella R. Probabilistic Expert System for the Diagnostics and Trouble-Shooting of Gas Turbine Apparatuses. AIAA 99-2842, 1999
- [8] 陈果, 左洪福, 杨新. 基于神经网络的多种油样分析技术融合诊断. 摩擦学学报, 2003, 23(5): 431~434
- [9] 陈果, 左洪福. 发动机磨损故障的集成神经网络融合诊断. 南京航空航天大学学报, 2004, 36(3): 278~283
- [10] 陈果. 航空发动机磨损故障的智能融合诊断. 中国机械工程, 2005, 16(4): 299~302
- [11] 屈梁生, 张海军. 机械故障诊断中的几个基本问题. 中国机械工程, 2000, 11(1-2): 211~216
- [12] 叶志锋, 孙建国. 应用神经网络诊断航空发动机气路故障的前景. 推进技术, 2002, 23(1): 1~4
- [13] Pawlak Z. Rough Sets. International Journal of Information and Computer Science, 1982(11): 1~10
- [14] 王国胤. 粗糙集理论与知识获取. 西安: 西安交通大学出版社, 2001
- [15] 吴今培, 肖建华. 智能故障诊断与专家系统. 北京: 科学出版社, 1997

(编辑 苏卫国)

作者简介: 陈果, 男, 1972 年生. 南京航空航天大学民航学院副教授、博士. 主要研究方向为航空发动机状态监测与故障智能诊断、专家系统、数据融合、神经网络与遗传算法、图像处理及模式识别、机械动力学. 获国家科技进步一等奖 1 项. 发表论文 30 余篇. 宋兰琪, 男, 1966 年生. 空军装备研究院航空装备研究所(原空军第一研究所)高级工程师. 文振华, 男, 1976 年生. 南京航空航天大学民航学院硕士研究生. 张占纲, 男, 1974 年生. 空军装备研究院航空装备研究所工程师。