



文章编号: 1003-8728(2005)09-1018-04

基于 D-S 证据理论的航空发动机磨损故障 智能融合诊断方法

文振华, 陈 果

(南京航空航天大学 民航学院, 南京 210016)

文振华

摘 要: 油样分析方法目前已成为航空发动机磨损故障诊断的重要手段, 但单一油样分析技术的诊断准确率均有限, 为了提高故障诊断的精度, 本文提出了基于 D-S 证据理论的发动机磨损故障智能融合诊断方法。首先用 BP 神经网络实现发动机磨损故障的单项智能诊断, 然后, 充分利用神经网络诊断结果, 用 D-S 证据理论实现了磨损故障的融合诊断。最后, 算例验证了本文方法的有效性。

关键词: 航空发动机; 磨损; 故障诊断; 数据融合; 神经网络; D-S 证据理论

中图分类号: O329; F201 **文献标识码:** A

An Intelligent Fusion Technique for Diagnosis of Engine Wear Fault Based on D-S Evidence Theory

WEN Zhen-hua, CHEN Guo

(Civil Aviation College, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

Abstract: Oil analysis technology has become a common technology in the filed of aero-engine wear fault diagnosis. The effectiveness of individual oil analysis technology, however, is limited in its accuracy. An intelligent fusion technique based on the Dempster-Shafer (D-S) evidence theory is proposed to improve the diagnosis accuracy. Firstly, the BP neural network is employed to carry out single aspect diagnosis; then the final conclusions are reached by combining the results of different diagnostic tools based on the Dempster-Shafer evidence theory. Examples show the validity of the technique proposed in this paper.

Key words: Aero-engine; Wear; Fault diagnosis; Data fusion; Neural network; D-S evidence theory

目前, 油样分析方法已经成为航空发动机的磨损故障检测的主要方法, 它包括铁谱分析法、光谱分析法、颗粒计数分析法及理化分析法。单一的一种方法在检测的准确性都有一定的局限性, 致使诊断的准确率不高。如果充分利用这几种方法的分析技术的诊断信息, 进行融合诊断, 使它们互相补充, 则能提高故障诊断的准确率。目前对数据融合算法和多种油样分析方法的融合诊断已经有许多专家和学者进行了研究^[1~5]。本文提出航空发动机磨损故障智能融合诊断技术, 先运用 BP 神经网络实现单一方法的智能诊断, 然后基于 D-S 证据理论, 对单一诊断的结果进行融合诊断, 以得到最后的更高精度的诊断结果。

1 航空发动机磨损故障融合诊断的流程图

本文提出的航空发动机磨损故障智能融合诊断基本思想是: 先将一些最常见的故障集作为一个故障域, 然后融合每一种油样分析方法在故障域中的诊断结果, 从而得出更为可信和准确的诊断结果。本文针对 4 种基本的油

样分析技术——铁谱分析、光谱分析、颗粒计数及理化分析。首先对每种油样分析方法, 建立于对应的子神经网络, 收集先验知识以得到网络的训练样本, 然后对网络进行训练, 对训练成功的网络, 输入待诊断的征兆数据, 即可得到单项的诊断结果。基于各子神经网络的诊断结果, 运用 D-S 证据理论对 4 个单项诊断结果进行融合, 最后得到融合诊断结果。具体流程如图 1 所示。

2 原始征兆数据的处理与输入

由于各种油样分析方法得到的诊断数据和量纲均不相同, 给后续的融合带来不便, 因此对原始征兆数据进行预处理, 转换为布尔值 0 和 1。转换依据就是: 将各种方法所测得的原始数据和与之相对应的标准界限值进行比较, 如果属于正常范围内的为 0, 否则为 1。

为了使训练出的网络有更好的泛化能力, 所以可以对现有的样本进行扩充, 即在原始训练样本中加入白噪声, 再将扩充后的样本数据进行归一化处理, 然后作为训练网络时的输入。

收稿日期: 2004-09-20

作者简介: 文振华 (1976-), 男 (汉), 湖北, 硕士研究生

E-mail: levinzhen@126.com

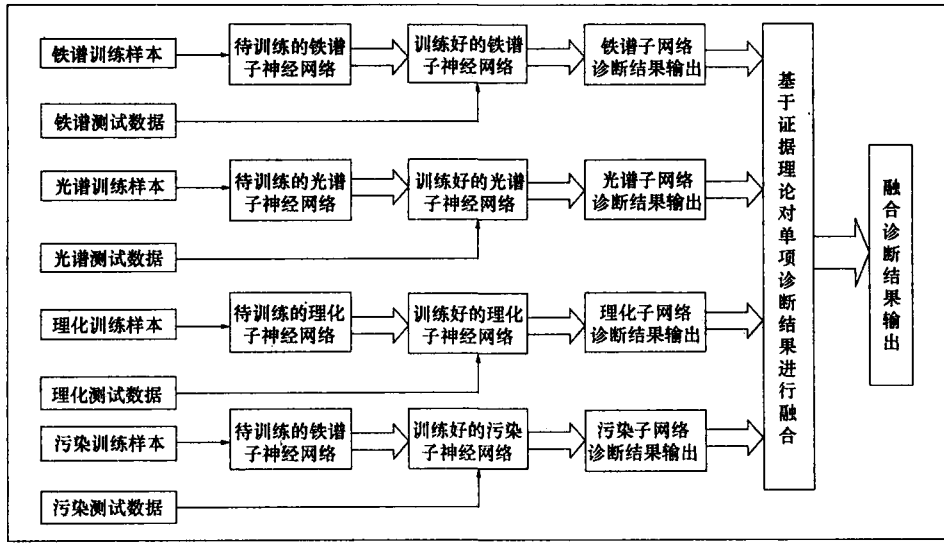


图 1 航空发动机磨损故障智能融合诊断系统流程图

3 基于 BP神经网络的故障智能诊断

3.1 BP神经网络

本文采用的是目前运用比较普遍的 BP网络进行单项故障诊断。在 BP网络中采用了 BP学习算法,其学习过程由正向传播和反向传播两部分组成,在正向传播过程中,输入模式从输入层经过隐层神经元的处理后,传向输出层,每一层神经元的状态只影响下一层神经元状态。如果在输出层得不到期望的输出,则转入反向传播,此时误差信号从输出层向输入层传播并沿途调整各层向连接权值和阈值。以使误差不断减小,直到达到精度要求。

3.2 基于神经网络的磨损故障单项智能诊断

BP神经网络用于发动机磨损故障诊断需要遵循的步骤:

(1) 首先根据诊断对象的特点划分其故障类型,获取故障信息,然后选取对故障比较敏感的一些参数为信号的特征参数作为 BP网络的输入单元。

(2) 根据诊断对象的特点构造 BP网络的结构即输入节点个数、隐层数、输出节点个数等。

(3) 用已知诊断的结果作为样本数据对网络进行训练,调整数值矩阵、阈值矢量。对网络进行训练,如果训练不成功,需要改变网络结构参数。

(4) 将待检征兆数据输入到训练成功的网络中,计算输出向量。输出向量的结果最接近哪种故障类型就认为它属于此类。

本文针对某军用航空发动机的磨损故障诊断问题,经过研究分析,将磨损故障模式总结为:系统正常 (F_1);轴承载磨损失效 (F_2);轴承疲劳失效 (F_3);齿轮疲劳过载 (F_4);齿轮胶合或擦伤 (F_5);润滑油污染度超标 (F_6);润滑油理化分析超标 (F_7);

因此,所建立的 4 个子网络——铁谱子网络、光谱子网络、颗粒计数子网络及理化分析子网络,其输出节点数均为

7。对于铁谱子网络而言,它的输入向量为各类元素的磨粒的百分比,球状磨粒大量 (S_{F1});层状磨粒大量 (S_{F2});疲劳磨粒大量 (S_{F3});切削磨粒大量 (S_{F4});严重滑动磨粒大量 (S_{F5});红色氧化物磨粒大量 (S_{F6});黑色氧化物磨粒大量 (S_{F7}),因此铁谱子网络的输入节点数为 7;对于光谱子网络,选取 Fe、Cr、Ni、Mo、Cu、V、Zn、Al 及 Ti 元素的浓度作为光谱诊断的原始数据(对于其他机械,由于摩擦部位的结构和材料不同,故选取的元素将不一样)。通过预处理后,光谱数据变为 Fe 元素浓度超标 (S_{S1});Cr 元素浓度超标 (S_{S2});Ni 元素浓度超标 (S_{S3});Mo 元素浓度超标 (S_{S4});V 元素浓度超标 (S_{S5});Cu 元素浓度超标 (S_{S6});Zn 元素浓度超标 (S_{S7});Al 元素浓度超标 (S_{S8});Ti 元素浓度超标 (S_{S9}),因此光谱子网络的输入节点数为 9;对于颗粒计数子网络,由于具体尺寸档的颗粒数目与发动机的故障模式无法对应,所以只能得到油样污染度是否超标的结论,即网络输入向量为:污染度超标 (S_{C1}),所以对于颗粒计数子网络,输入节点数为 1;对于理化分析子网络,输入向量为:运动粘度超标 (S_{P1});杂质含量超标 (S_{P2});其他理化指标超标 (S_{P3}),故可以设定输入节点数为 3。

最后通过设定各子网络的其他参数,如隐层数,学习率,误差等,就完成了了一个子网络的设计初始化工作。然后是用各自训练样本数据对相应的子网络进行训练,最后是用待测数据进行诊断,即可得到单项的诊断结果。网络训练样本限于篇幅,在此从略。

4 基于 D-S证据理论的融合诊断

4.1 D-S证据理论^[4]

D-S理论建立了一个非空集合,称为辨识框架,用来描述构成整个假设空间的所有元素的集合,它由互斥且穷举的元素组成。定义了一个集函数 $m: 2^{\Omega} \rightarrow [0, 1]$ 且满足:

- (1) $m(\phi) = 0$
- (2) $m(A) = 1$

其中 m 称为这个辨识框架上的基本可信度分配 (BPA), $m(A)$ 表示证据对 A 的支持程度。

对于任何命题集, D-S理论还提出了信任度函数 (Belief Function) 的概念: $Bel(A) = \sum_{B \subset A} m(B)$, ($\forall A \subset \Omega$) 即意味着 A 的信任度函数为 A 中的每个子集的信度值之和。Bel函数也称为下限函数, 它表示了对 A 的全部信任。但对于一个命题的信任, 单靠信任度函数来描述是不够完整的, 它不能反映出对于命题 A 的怀疑程度, 于是引入了另外一个函数似然函数, 定义为: $Pl(A) = 1 - Bel(\bar{A})$, ($\forall A \subset \Omega$, Pl 函数也称为上限函数或不可驳斥函数。表示了对于命题 A 不假的信任程度。通俗地讲就是命题 A 似乎可能成立的一个不确定性度量。显然: $Pl(A) \geq Bel(A)$, 对于所有的 $A \subset \Omega$ 。

4.2 合成法则^[2]

对于不同的证据, 因其来源不同, 具有不同的基本可信度分配函数源, Dempster提出的是采用正交和合并数据, 如对于 n 个信任度函数 Bel_i , 它们各自对应的基本可信度分配函数 (BPA) 为 m_n , 则有合并后的信任度函数为:

$$Bel = Bel_1 \oplus Bel_2 \oplus \dots \oplus Bel_n, \text{ 对于子集 } A \text{ 的 BPA 则为}$$

$$m(A) = m_1 \oplus m_2 \oplus \dots \oplus m_n = \frac{1}{1 - k_{A_i B_j C_l \dots=A}} m_1(A_i) \cdot m_2(B_j) \cdot m_3(C_l) \dots \quad (1)$$

式中: $k = \sum_{A_i B_j C_l \dots=A} m_1(A_i) \cdot m_2(B_j) \cdot m_3(C_l) \dots$, 为一个正交化的常数, 它的大小反映出对于同一个假设, n 个证据之间的冲突程度, 系数 $1/(1 - k)$ 称为归一化因子, 它可以避免把概率值分配给空集。

Yager合成公式^[2]: 由公式 (1) 可以看出, 如果当 $k=1$, 分母为零, 这个式子没有办法使用。或者当 $k > 1$ 的时候, 即证据冲突程度很高, 常得出有悖于常理的结果^[2]。Yager认为: 既然我们对冲突的证据无法作出合理的抉择, 就应将其归入未知邻域。因此提出了一个新的合成公式, 把支持证据冲突的那部分概率全部赋给了未知领域。Yager改进后的公式 (对于两个证据源) 为

$$\begin{cases} m(\phi) = 0 \\ m(A) = \sum_{A_i B_j=A} m_1(A_i) \cdot m_2(B_j) & A \in X \\ m(X) = \sum_{A_i B_j=X} m_1(A_i) \cdot m_2(B_j) + k \end{cases} \quad (2)$$

与公式 (1) 相比, 去掉了归一化因子 $1/(1 - k)$, 将反映冲突程度的因子在合成后赋给了 $m(X)$ 。当 $k=0$ 时, Yager合成公式和 D-S证据理论的合成公式是一样的。虽然 Yager提出的合成公式能合成高度冲突的证据, 但是由于对冲突的证据是完全否定的, 因此在证据源多于二个时, 合成结果有时并不理想。可以参看文献 [2]。在文献 [3] 中, 引入证据对的平均支持程度 $q(A) = \frac{1}{n} \sum_{1 \leq i \leq n} m_i(A)$, 然后把证据冲

突的概率 k 按这个比例分配给 A , 也就是将证据冲突概率按各个证据平均支持程度的加权分配。这样使得合成结果更为理想。其合成公式为

$$\begin{cases} m(\phi) = 0 \\ m(A) = \sum_{A_i B_j C_l \dots=A} m_1(A_i) \cdot m_2(B_j) \cdot m_3(C_l) \cdot \dots + k \cdot q(A) \\ k = \sum_{A_i B_j C_l \dots=A} m_1(A_i) \cdot m_2(B_j) \cdot m_3(C_l) \cdot \dots \end{cases} \quad (3)$$

4.3 D-S证据理论在磨损故障融合诊断中的应用

在前面提到的合成公式中, 认为证据都是有效的, 但是在故障诊断领域中, 诊断方法都有一定的局限性, 对于某种故障模式会显得无能为力。例如: 理化分析对于润滑油污染度是否超标就无法判断, 其单项诊断的结果为 0, 并不意味着真正的润滑油污染度没有超标, 而是因为这种方法没有能力去检验或判断。对于这种故障模式来说, 理化分析的诊断结果是无效的。这样的单项诊断结果一旦引入, 将在融合的过程中往往引起很大的冲突程度。因此, 本文引入了一个方法有效性矩阵:

	铁谱分析	光谱分析	污染分析	理化分析
系统正常	1	1	1	1
轴承磨损失效	1	1	1	0
轴承疲劳失效	1	1	0	1
齿轮疲劳过载	1	1	0	1
齿轮胶合或擦伤	1	1	1	0
润滑油污染度超标	0	0	1	0
润滑油理化分析超标	0	0	0	1

在该矩阵中, 值为 1 的表示该方法对于检测此类故障模式有效, 其单项诊断结果将在最后的融合诊断中考虑, 如果值为 0, 表示该方法对于检测此类故障模式无效, 也就是该方法的诊断结果没有决定权, 则在融合和计算冲突程度的过程中不予考虑其诊断结果。这样可以减小证据之间的冲突程度, 使得融合的结果更为合理。此外方法有效性矩阵的引入不仅使我们可以清楚地看到各种诊断方法的局限性, 也便于算法的软件实现。

在故障诊断的领域中, 诊断的结果有它的特殊性, 往往故障模式不是单独出现, 一种故障征兆可能对应着好几种故障同时发生, 例如在铁谱分析中, 故障征兆数据 {0, 0, 0, 1, 0, 0, 0} 对应的轴承磨损失效和齿轮胶合或擦伤的概率均为 0.8 左右。在进行融合前, 我们建立的一个辨识框架必须满足 $\sum_{A \subset \Omega} m(A) = 1$, 显然单项诊断的结果不适于建立一个辨识框架。因此, 我们需要对单项的诊断结果做一下处理。在这里, 对于最终故障模式的判定, 不再采用集中融合所有的故障模式的方法, 而是参照方法有效性矩阵和单项诊断结果, 对于每一种故障模式各建立一个辨识框架, 按照文献 [3] 提出的合成公式 (3) 逐一融合。

例如: 对于故障征兆数据 {0, 0, 0, 1, 0, 0, 0}, 铁谱诊断结果为轴承磨损失效的概率是 0.8 那么它同时也就认定了不是轴承磨损这种故障模式的概率是 0.2。依次可以列

出其他方法对轴承磨损失效和不是轴承磨损失效这一故障模式的诊断结果。然后进行融合,得到该故障模式发生概率。

5 算例

为了验证本文算法的有效性,本文列举一算例进行验证。设铁谱分析的故障征兆数据为 (0, 0, 0, 1, 0, 0, 0);光谱分析的故障征兆数据为 (0, 1, 0, 0, 0, 0, 0, 0, 0);污染分析的故障征兆数据为 (1);理化分析的故障征兆数据 (0, 0, 1)。各个子神经网络的单项诊断结果见表 1。

表 1 各个子神经网络的单项诊断结果

Table with 6 columns: 铁谱分析, 光谱分析, 污染分析, 理化分析, 融合诊断. Rows include: 系统正常, 轴承磨损失效, 轴承疲劳失效, 齿轮疲劳过载, 齿轮胶合或擦伤, 润滑油污染度超标, 润滑油理化分析超标.

下面分别对于轴承磨损失效和齿轮胶合或擦伤故障模式进行融合分析。其中轴承磨损失效故障为小冲突融合,其结果见表 2;齿轮胶合或擦伤故障为大冲突融合,其结果见表 3。从融合结果可以看出,当证据出现大冲突时,融合结果将在二者中间,当证据出现相互支持(小冲突)时,融合结果比二者均大。这显然符合实际情况。按此方法依次可以得到其他几种故障模式的最后融合结果,如表 1 所示。由表中可以看出:在引入方法有效性矩阵后,并对每一种故障模式单独融合判断,不考虑无效检测方法的单项诊断结果,所得出的结果更为合理可靠。

表 2 小冲突融合实例

Table with 6 columns: 铁谱分析, 光谱分析, 污染分析, 冲突程度, 融合结果. Rows include: 轴承磨损失效, 非轴承磨损失效.

表 3 大冲突融合实例

Table with 6 columns: 铁谱分析, 光谱分析, 污染分析, 冲突程度, 融合结果. Rows include: 齿轮胶合或擦伤, 非齿轮胶合或擦伤.

6 结论

(1) 结合神经网络和 D-S证据理论,提出了航空发动机磨损故障智能融合诊断方法,总结了融合诊断框架。

(2) 对常用的 4 种油样分析方法——铁谱分析、光谱分析、颗粒计数及理化分析,建立了基于神经网络的单项智能诊断。

(3) 在单项智能诊断的基础上,基于改进的 D-S证据理论,实现了多源信息的融合,提高了诊断的精度和可靠性,最后用具体算例验证了本文方法的合理性。

[参考文献]

[1] 郝英,彭鸿博. D-S证据理论及其在滑油故障诊断中的应用 [J]. 中国民航学院学报, 2003, 21(3): 41~44
[2] 孙全,叶秀清,顾伟康. 一种新的基于证据理论的合成公式 [J]. 电子学报, 2000, 28(8): 117~119
[3] 李弼程,王波,魏俊. 一种有效的证据理论合成公式 [J]. 数据采集与处理, 2002, 17(1): 33~36
[4] 张淑清,邓红,王艳玲. D-S证据理论在数据融合中的应用及改进 [J]. 传感技术学报, 2003, (1): 78~81
[5] 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 [J]. 摩擦学学报, 2003, 23(5): 431~434
[6] 梁华,杨明忠,陆培德. 用神经网络预测摩擦学系统磨损趋势 [J]. 摩擦学学报, 1996, 16(3): 267~271
[7] 严新平,谢友柏,李晓峰,萧汉梁. 一种柴油机磨损的预测模型与试验研究 [J]. 摩擦学学报, 1996, 16(4): 358~366
[8] Yager R R. On the Dempster-Shafter framework and new combination rules [J]. Information Sciences, 1987, (41): 93~137
[9] Kai G. Architecture and design of a diagnostic information fusion system [J]. Artificial Intelligence for Engineering Design, Analysis and Manufacturing, 2001, (15): 335~348
[10] Yager R R. Fuzzy modeling for intelligent decision making under uncertainty [J]. IEEE Trans on SMC, Part B, 2000, 30(1): 60~70
[11] 滕召胜,罗隆福,童调生. 智能检测系统与数据融合 [M]. 北京:机械工业出版社, 2000