

文章编号: 1000-8055(2005)02-0303-06

基于神经网络和D-S证据理论的发动机 磨损故障融合诊断

陈 果

(南京航空航天大学 民航学院, 江苏 南京 210016)

摘要: 运用了4种最常用的滑油分析技术——铁谱分析、光谱分析、颗粒计数分析及理化指标分析,同时结合发动机试车台监测数据,提出运用神经网络和D-S证据理论对发动机试车状态进行融合诊断的方法。首先依据各种分析方法的标准磨损界限值,将原始数据进行了预处理,统一转换成故障征兆的布尔值;其次,建立各子神经网络的拓扑结构,并依据专家经验建立各子系统的输入征兆与故障论域的映射关系,从而得到各子神经网络的训练样本,对各网络进行成功训练后,利用神经网络实现各子网络的诊断并得到中间诊断结果;然后,将每种方法的神经网络诊断结果作为对各种故障模式的基本概率分配值,利用D-S证据理论,实现对神经网络的诊断结果的融合,从而得到最终的融合诊断结果;最后,运用算例表明了本文方法的有效性。

关键词: 航空、航天推进系统; 发动机; 故障诊断; 磨损; 数据融合; 神经网络; D-S证据理论

中图分类号: V 233.7

文献标识码: A

Fusion Diagnosis of Engine Wearing Fault Based on Neural Networks and D-S Evidence Theory

CHEN Guo

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

Abstract: Four common oil analysis techniques, namely Ferrography analysis, Spectrometric analysis, Particle count analysis, and Oil chemical-physics analysis, were used together with the engine test data to develop the fusion diagnosis method of engine wearing fault based on Neural Networks (NN) and D-S evidence theory. Firstly, according to standard wear limit, original data were transformed into BOOL value. Then, each sub-NN structure was established, and their training samples were obtained based on expert experience. After each sub-NN was trained successfully, the intermediate diagnosis results were obtained through each sub-NN. Finally, the NN diagnosis results are used as the basic probability distribution value to each fault mode, and the D-S evidence theory is applied, and the final fusion diagnosis results are obtained. An example was used to verify the method presented in this paper.

Key words: aerospace propulsion system; engine; fault diagnosis; wear; data fusion; Neural Networks (NN); D-S evidence theory

收稿日期: 2004-03-13; **修订日期:** 2004-06-23

作者简介: 陈果(1972-),男,四川武胜人,南京航空航天大学民航学院副教授,主要从事航空发动机磨损状态监测与故障智能诊断、数据融合、神经网络与遗传算法、图像处理及模式识别等领域研究




图1 基于神经网络和D-S 证据理论的发动机磨损故障融合诊断系统流程图

Fig 1 Fusion diagnosis of engine wearing fault based on neural networks and D-S evidence theory

油样分析方法由于对机械磨损故障检测的灵敏性和有效性,已成为机械故障诊断的主要技术手段之一。油样分析方法各有所长,而单一分析技术的诊断准确率均有限^[1],对多种油样分析方法进行融合诊断对于提高机械系统磨损故障的诊断精度具有十分重要的意义。然而,如何充分利用各种诊断方法的诊断信息,提高故障诊断的准确率,则是故障融合诊断的本质所在。目前已有许多学者对多种油样分析方法的融合诊断进行了研究^[2,3]。

本文结合神经网络和D-S 证据理论,针对某弹用航空发动机试车台试验中发动机磨损故障诊断问题,提出基于神经网络和D-S 证据理论的融合诊断方法,实现发动机磨损故障的融合诊断,从而为发动机的实验评估和改进设计提供更加准确可靠的决策依据。

1 发动机磨损故障融合诊断流程图

发动机磨损故障融合诊断的基本思路是首先给定发动机磨损故障的故障域,即最常见的也是最重要的磨损故障类型,然后,通过融合每种油样分析方法对故障域的诊断结果,最终得到更为重要准确和可信的诊断结果。图1 为发动机磨损故障融合诊断的流程图。发动机磨损故障融合诊断将故障的定位、定性和定因融为一体,并针对多种分析方法实现故障诊断。下面对融合诊断的各模块进行详细的说明。

2 原始征兆数据的预处理

由于各种分析方法得到的诊断数据,不论是数值还是量纲,均不相同,所以为后续分析处理带来了困难。有鉴于此,在进行融合诊断之前,必须要对原始征兆进行预处理。其处理的方法是依据将各种

方式诊断原始数据与各种诊断方法的标准界限值相比较, 正常值范围内的为0, 反之则为1, 从而将原始征兆数据转换为0 和1 的布尔值。

铁谱数据的原始数据为各类磨粒的百分比, 通过预先处理后得到的结果应为: ①球状磨粒大量(S_{F1}); ②层状磨粒大量(S_{F2}); ③疲劳磨粒大量(S_{F3}); ④切削磨粒大量(S_{F4}); ⑤严重滑动磨粒大量(S_{F5}); ⑥红色氧化物磨粒大量(S_{F6}); ⑦黑色氧化物磨粒大量(S_{F7})。

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, 由于摩擦副的结构和材质不同, 故选取的元素将不一样)。通过预处理后, 光谱数据变为①Fe 元素浓度超标(S_{S1}); ②Cr 元素浓度超标(S_{S2}); ③Ni 元素浓度超标(S_{S3}); ④Mo 元素浓度超标(S_{S4}); ⑤V 元素浓度超标(S_{S5}); ⑥Cu 元素浓度超标(S_{S6}); ⑦Zn 元素浓度超标(S_{S7}); ⑧Al 元素浓度超标(S_{S8}); ⑨Ti 元素浓度超标(S_{S9})。

颗粒计数器得到原始数据为各档尺寸(即5~15 μm , 15~25 μm , 25~50 μm , 50~100 μm 及100 μm) 以上颗粒数。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, 即原始数据通过预处理后得到的结果为: ①污染度超标(S_{C1})。

理化分析得到的原始数据包括250 $^{\circ}\text{C}$, 200 $^{\circ}\text{C}$, 100 $^{\circ}\text{C}$, 0 $^{\circ}\text{C}$, -40 $^{\circ}\text{C}$ 及-54 $^{\circ}\text{C}$ 下的运动粘度, 冷凝点, 闪点, 酸值, 杂质含量和水分含量。根据理化指标与发动机故障模式的对应关系, 通过预处理后的结果为: ①运动粘度超标(S_{P1}); ②杂质含量超标(S_{P2}); ③其他理化指标超标(S_{P3})。

试车台监测的原始数据为: 滑油消耗率、滑油箱内压强、滑油增压泵出口压强、后腔滑油温度等,

根据试车台监测数据与发动机故障模式的对应关系, 通过预处理后的结果为: ①滑油消耗率大(S_{T1}); ②滑油箱内压强高(S_{T2}); ③滑油增压泵出口压强低(S_{T3}); ④后腔滑油温度高(S_{T4})。

3 神经网络的单项诊断

由于神经网络具有超强的非线性映射能力, 同时具有较强的泛化特性, 因此广泛应用于故障诊断和模式识别领域, 而BP 神经网络在故障诊断领域应用最为广泛, 故本文采用3 层BP 神经网络来实现对单项油样分析数据的诊断。

神经网络的单项诊断系统包括: 铁谱子网络、光谱子网络、颗粒计数子网络、理化分析子网络及试车台数据子网络。其中子网络的输入为各种原始征兆通过预处理后得到的布尔值, 各子网络的输出均为最终的故障模式。根据分析, 确定发动机磨损故障的故障模式为: ①系统正常(F_1); ②轴承磨损失效(F_2); ③轴承疲劳失效(F_3); ④齿轮疲劳过载(F_4); ⑤齿轮胶合或擦伤(F_5); ⑥滑油污染度超标(F_6); ⑦滑油理化分析超标(F_7); ⑧密封失效(F_8)。

表1~ 表5 分别根据领域专家的经验知识得到的各子诊断网络的训练样本。其中表1 为铁谱诊断子网络的训练样本^[4]; 表2 为光谱子诊断网络的训练样本; 表3 为颗粒计数子网络的训练样本; 表4 为理化分析子诊断网络的训练样本; 表5 为试车台子诊断网络的训练样本。

各子诊断网络的结构参数为: 铁谱为7-20-8, 光谱为9-10-8, 颗粒计数为1-8-8; 理化分析为3-8-8; 试车台数据为4-8-8。网络采用变步长学习, 训练精度0.01, 动量项系数0.9。为了提高神经网络的泛化能力, 在训练时需要将训练样本加上高

表1 铁谱子网络的训练样本

Table 1 Training samples of Ferrography diagnosis sub-NN

S_{F1}	S_{F2}	S_{F3}	S_{F4}	S_{F5}	S_{F6}	S_{F7}	F_{F1}	F_{F2}	F_{F3}	F_{F4}	F_{F5}	F_{F6}	F_{F7}	F_{F8}
0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0.5	0	0	0	0	0
0	1	0	0	0	0	0	0	0	0.6	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0.8	0.6	0	0	0.6	0
0	0	0	1	0	0	0	0	0.8	0	0	0.8	0.6	0	0
0	0	0	0	1	0	0	0	0	0	0	0.9	0	0.6	0.6
0	0	0	0	0	1	0	0	0	0	0	0	0	0.8	0
0	0	0	0	0	0	1	0	0	0	0	0	0	0	0.6

表2 光谱子网络的训练样本
Table 2 Training samples of SOA diagnosis sub-NN

S _{S1}	S _{S2}	S _{S3}	S _{S4}	S _{S5}	S _{S6}	S _{S7}	S _{S8}	S _{S9}	F _{S1}	F _{S2}	F _{S3}	F _{S4}	F _{S5}	F _{S6}	F _{S7}	F _{S8}
0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0.7	0	0	0.9	0	0	0
0	1	0	0	0	0	0	0	0	0	0.9	0	0	0.1	0	0	0
0	0	1	0	0	0	0	0	0	0	0.9	0	0	0.1	0	0	0
0	0	0	1	0	0	0	0	0	0	0.9	0	0	0.1	0	0	0
0	0	0	0	1	0	0	0	0	0	0.9	0	0	0.8	0	0	0
0	0	0	0	0	1	0	0	0	0	0.9	0	0	0.7	0	0	0
0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0
0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	0	0
0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0

表3 颗粒计数器网络的训练样本
Table 3 Training samples of Particle Count diagnosis sub-NN

S _{C1}	F _{C1}	F _{C2}	F _{C3}	F _{C4}	F _{C5}	F _{C6}	F _{C7}	F _{C8}
0	1	0	0	0	0	0	0	0
1	0	1	0	0	1	1	0	0

表4 理化分析子网络的训练样本
Table 4 Training samples of Oil quality testing diagnosis sub-NN

S _{P1}	S _{P2}	S _{P3}	F _{P1}	F _{P2}	F _{P3}	F _{P4}	F _{P5}	F _{P6}	F _{P7}	F _{P8}
0	0	0	1	0	0	0	0	0	0	0
1	0	0	0	1	1	1	1	0	1	0
0	1	0	0	1	0	0	1	0	1	0
0	0	1	0	0	0	0	0	0	1	0

表5 试车台监测数据诊断子网络的训练样本
Table 5 Training samples of Test-drive testing diagnosis sub-NN

S _{T1}	S _{T2}	S _{T3}	S _{T4}	F _{T1}	F _{T2}	F _{T3}	F _{T4}	F _{T5}	F _{T6}	F _{T7}	F _{T8}
0	0	0	0	1	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0	1
0	1	0	0	0	0	0	0	0	0	0	1
0	0	1	0	0	1	1	1	1	0	0	1
0	0	0	1	0	1	0	0	1	0	0	0

斯噪声, 从而增加训练样本的数量, 提高网络的模
式识别能力或泛化能力。本文所加的高斯噪声为 N

(0, 0.01)。



表6 5 种方法对 8 种故障模式的基本概率的分配
Table 6 BPA of eight fault modes of five methods

	系统 正常	轴承 磨损	轴承 疲劳	齿轮过 载疲劳	齿轮胶合 或擦伤	污染 超标	理化指 标超标	密封 失效
铁谱诊断	$F_{F1} * R_F$	$F_{F2} * R_F$	$F_{F3} * R_F$	$F_{F4} * R_F$	$F_{F5} * R_F$	$F_{F6} * R_F$	$F_{F7} * R_F$	$F_{F8} * R_F$
光谱诊断	$F_{S1} * R_S$	$F_{S2} * R_S$	$F_{S3} * R_S$	$F_{S4} * R_S$	$F_{S5} * R_S$	$F_{S6} * R_S$	$F_{S7} * R_S$	$F_{S8} * R_S$
颗粒计数诊断	$F_{C1} * R_C$	$F_{C2} * R_C$	$F_{C3} * R_C$	$F_{C4} * R_C$	$F_{C5} * R_C$	$F_{C6} * R_C$	$F_{C7} * R_C$	$F_{C8} * R_C$
理化指标诊断	$F_{P1} * R_P$	$F_{P2} * R_P$	$F_{P3} * R_P$	$F_{P4} * R_P$	$F_{P5} * R_P$	$F_{P6} * R_P$	$F_{P7} * R_P$	$F_{P8} * R_P$
试车台诊断	$F_{T1} * R_T$	$F_{T2} * R_T$	$F_{T3} * R_T$	$F_{T4} * R_T$	$F_{T5} * R_T$	$F_{T6} * R_T$	$F_{T7} * R_T$	$F_{T8} * R_T$

4 D-S 证据理论融合诊断

Dempster-Shafter (D-S) 证据理论^[5]是目前决策层融合中最常用的一种方法。它建立了广义 Bayes 理论, 根据人的推理模式, 采用与概率区间或不确定区间来决定多证据下假设的似然函数。

(1) 分辨框

如果定义代表某一事件的参数为 θ , 它的可能取值的集合为 Θ , 则称 Θ 为分辨框, Θ 的所有子集所构成的集合就是 Θ 的幂集, 记为 2^Θ 。

(2) 基本概率值

如果 Θ 是一个分辨框, 那么函数 $m : 2^\Theta \rightarrow [0, 1]$ 称为基本概率分布, 当:

① $m(\Phi) = 0$ (Φ 为空集); ② $\sum_{A \in \Theta} m(A) = 1$,

这里 A 为焦点, $m(A)$ 为基本概率值, 即 2^Θ 中全部元素的基本概率之和为 1。

对于任意假设而言, 其信任度 $Bel(A)$, $A \in 2^\Theta$ 定义为 A 中全部子集对应的基本概率之和, 即:

$$Bel(A) = \sum_{B \in A} m_i(B)$$

一般信任函数不具有可加性。

(3) D-S 证据理论的组合规则如下:

设 Bel_1 和 Bel_2 是相同框架 2^Θ 上的信任函数, 它们的基本概率分布为 m_1 和 m_2 , 焦点元素分别为 $A_1, \dots, A_k$ 和 $B_1, \dots, B_k$, 如果:

$$\sum_{A_i \cap B_j = \Phi} m_1(A_i) m_2(B_j) < 1 \tag{1}$$

则, 函数 $m : 2^\Theta \rightarrow [0, 1]$ 对于所有非空集 $A \subset \Theta$ 满足 $m(\Phi) = 0$, 且有:

$$m(A) = \frac{\left| \sum_{A_i \cap B_j = A} m_1(A_i) m_2(B_j) \right|}{\left| 1 - \sum_{A_i \cap B_j = \Phi} m_1(A_i) m_2(B_j) \right|} \tag{2}$$

此函数就是基本概率分布函数, 由 m 给定的信任函数称为 Bel_1 与 Bel_2 的正交和, 记为 $Bel_1 \oplus Bel_2$ 。对于多个信任函数的组合, 假设 $Bel_1, Bel_2, \dots, Bel_n$ 是相同框架 2^Θ 上的信任函数, 则 n 个信任函数的组合可写成:

$$\{[(Bel_1 \oplus Bel_2) \oplus Bel_3] \oplus \dots\} \oplus Bel_n \tag{3}$$

(4) 对于两重假设问题。设每个陈述对假设 A 的支持程度分别为 $m_1(A), m_2(A), \dots, m_n(A)$, 以及 $m_1(\theta), m_2(\theta), \dots, m_n(\theta)$, 且有:

$$\left. \begin{aligned} m_1(\theta) &= 1 - m_1(A) \\ m_2(\theta) &= 1 - m_2(A) \\ &\dots \\ m_n(\theta) &= 1 - m_n(A) \end{aligned} \right\} \tag{4}$$

由数学归纳法可以证明得到:

$$m^n(A) = 1 - \prod_{i=1}^n m_i(\theta) \tag{5}$$

由此可见, 针对某弹用航空发动机, 假设其故障模式均为两重假设, 则可以将 5 个神经网络对 8 种故障模式诊断结果与传感器的检测率相乘作为基本概率的分配, 文献[1]的研究表明: 铁谱诊断的检测率为 $R_F = 55\%$, 光谱为 $R_S = 36\%$, 理化分析为 $R_P = 21\%$, 颗粒计数分析为 $R_C = 33\%$ 。试车台测试数据所受的干扰小, 其检测率较高, 确定为 $R_T = 95\%$ 。因此, 可以得到基本概率的分配, 如表 6 所示。

5 算 例

为了验证本文方法的有效性, 下面列举一算例来进行解释。设铁谱原始数据为: 切削磨粒和严重滑动磨粒超标, 其他磨粒含量正常。则征兆向量为: $\{S_{F1}, S_{F2}, S_{F3}, S_{F4}, S_{F5}, S_{F6}, S_{F7}\} = \{0, 0, 0, 1, 1, 0, 0\}$; 光谱原始数据为: Cr 元素超标, 其他元素含量正常。则征兆向量为: $\{S_{S1}, S_{S2}, S_{S3}, S_{S4}, S_{S5}, S_{S6},$

表7 神经网络与D-S 证据理论融合诊断结果
Table 7 Fusion diagnosis results of NN and D-S evidence theory

	系统 正常	轴承 磨损	轴承 疲劳	齿轮过 载疲劳	齿轮胶合 或擦伤	污染 超标	理化指 标超标	密封 失效
铁谱诊断	0.000 7	0.146 8	0.000 0	0.000 0	0.534 8	0.101 4	0.001 5	0.085 7
光谱诊断	0.021 2	0.330 3	0.000 7	0.001 2	0.000 9	0.001 0	0.001 3	0.000 0
颗粒计数诊断	0.023 4	0.306 6	0.002 7	0.002 7	0.306 6	0.306 6	0.002 6	0.002 7
理化指标诊断	0.016 5	0.202 6	0.199 9	0.199 7	0.204 2	0.002 0	0.193 5	0.001 1
试车台诊断	0.068 7	0.813 2	0.021 1	0.014 2	0.819 2	0.000 0	0.000 0	0.721 3
融合诊断1(铁谱+ 光谱)	0.021 9	<u>0.428 6</u>	0.000 7	0.001 2	<u>0.535 2</u>	0.102 3	0.002 8	0.085 7
融合诊断2(铁谱+ 光谱+ 颗粒计数)	0.044 7	<u>0.603 8</u>	0.003 4	0.003 9	<u>0.677 7</u>	0.377 6	0.005 4	0.088 2
融合诊断3 (铁谱+ 光谱+ 颗粒计数+ 理化指标)	0.060 5	<u>0.684 1</u>	0.202 6	0.202 8	<u>0.743 5</u>	0.378 8	0.197 9	0.089 2
融合诊断4 (铁谱+ 光谱+ 颗粒计数+ 理化指标+ 试车台数据)	0.125 1	<u>0.941 0</u>	0.219 4	0.214 2	<u>0.953 6</u>	0.378 8	0.197 9	0.746 2

$S_{S7}, S_{S8}, S_{S9} = \{0, 1, 0, 0, 0, 0, 0, 0, 0\}$; 颗粒计数原始数据为: 污染度超标。则征兆向量为: $\{S_{C1}\} = \{1\}$; 理化指标原始数据为运动粘度偏低, 其他指标正常。则征兆向量为: $\{S_{S1}, S_{S2}, S_{S3}\} = \{1, 0, 0\}$; 试车台原始数据为后腔滑油温度高, 其他数据正常。则征兆向量为: $\{S_{S1}, S_{S2}, S_{S3}, S_{S4}\} = \{0, 0, 0, 1\}$ 。

表7 为5 种方法的神经网络单项诊断结果和多种方法的融合诊断结果。从计算结果可以得出2 个结论: ①融合诊断能利用多种分析方法的互补性, 发现系统更多的故障; ②融合诊断结果比单项诊断的准确率更高。随着参加融合的方法越多, 诊断的准确率越高, 如表7 中带下划线的数据。

6 结 论

- (1) 本文以某弹用航空发动机试车台试验中发动机磨损故障诊断问题, 选取4 种最常用的滑油分析技术——铁谱分析、光谱分析、颗粒计数分析及理化指标分析的分析结果, 同时结合发动机试车台数据, 一起作为故障诊断的征兆。
- (2) 建立和提出神经网络与D-S 证据理论融合诊断的框架与方法, 运用神经网络产生多种方法对故障模式的基本概率分配, 然后运用D-S 证据理

论的组合规则, 对多源信息进行融合诊断。
(3) 运用具体的算例表明了本文基于神经网络与D-S 证据理论的融合诊断方法进行验证, 结果表明本文方法的正确性和有效性。

参考文献:

[1] 虞和济, 韩庆大, 李沈, 等. 设备故障诊断工程[M]. 北京: 冶金工业出版社, 2001: 931~949.

[2] 赵方, 谢友柏, 柏子游. 油液分析多技术集成的特征与信息融合[J]. 摩擦学学报, 1998, 18(1): 45~52.

Zhao F, Xie Y B, Bai Z Y. Characteristics and Information Fusion of Multi-Technique Integration for Oil Analysis[J]. Tribology, 1998, 18(1): 45~52.

[3] 严新平, 谢友柏, 萧汉梁. 摩擦学故障种类诊断的D-S 信息融合研究[J]. 摩擦学学报, 1999, 19(2): 145~150.

Yan X P, Xie Y B, Xiao H L. Research on Data Fusion for Diagnosing Types of Tribological Failures by Dempster-Shafer[J]. Tribology, 1999, 19(2): 145~150.

[4] [美] Anderson D P. 磨粒图谱[M]. 金元生, 杨其明译. 北京: 机械工业出版社, 1987: 1~14.

Anderson D P. Wear Atlas [M]. Jin Y S, Yang Q M Translation. Beijing: Machine Industry Press, 1987: 1~14.

[5] 权太范. 信息融合神经网络-模糊推理理论与应用[M]. 北京: 国防工业出版社, 2002: 54~60.