

文章编号: 1000-8055(2008)01-0163-06

应用神经网络信息融合诊断航空发动机故障

赵世荣, 黄向华

(南京航空航天大学 能源与动力学院, 南京 210016)

摘 要: 研究了基于神经网络信息融合技术, 同时结合模糊集合论对发动机气路部件进行故障诊断的方法, 并以某型涡轴发动机为对象进行了仿真分析. 研究结果表明该方法的故障诊断过程相对简单, 对模型的精度要求不高, 能够降低虚警、误报、漏报等情况的发生.

关 键 词: 航空、航天推进系统; 航空发动机; 故障诊断; 神经网络; 信息融合

中图分类号: V263. 6

文献标识码: A

Fault diagnosis for aeroengine gas path components based on neural network multisensor data fusion

ZHAO Shi-rong, HUANG Xiang-hua

(College of Energy and Power Engineering,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: A fault diagnosis method for aeroengine gas path components, which was based on the technology of neural network multisensor data fusion and combined application of fuzzy logical theory, was studied in the paper. And this method was employed in simulation analysis of a given turbo-shaft engine. The whole diagnosis process of this method is simple and high accuracy of modeling is not required. Fault alarm, mistaken report and false positive can be reduced.

Key words: aerospace propulsion system; aeroengine; fault diagnosis; neural network; data fusion

现代航空发动机越来越复杂, 为了提高工作安全性, 降低维修成本, 对发动机进行状态监视和故障诊断逐步成了发展趋势^[1-3]. 进行状态监视和故障诊断一般要用多个传感器采集信号, 随着航空发动机性能不断提高, 采集的信号也越来越多, 发生信息矛盾及信息熵增的可能性大大增加, 以前对多个传感器采集来的信息往往是单独处理的, 很少对信息进行融合处理, 因此在诊断的可靠性和有效性上不高, 容易出现虚警、误报、漏报等情况^[3-4]. 由于航空发动机气路部件故障往往是潜在的且难以判断, 因此在航空发动机性能监控与诊断研究中占很重要的地位^[1-2, 5-6]. 文献[5]采用

故障方程法对某型涡轴发动机稳态气路故障进行了诊断, 由于故障方程法需要将故障模型线性化为所谓的故障方程, 从理论上讲其精度必受到一些损失; 此外该方法在使用中还存在测量参数的数量小于故障种类的问题^[1]. 本文研究了基于神经网络信息融合技术, 同时结合模糊集合论对发动机气路部件进行故障诊断的方法, 并以某型涡轴发动机为对象进行了仿真分析: 通过测试涡轴发动机各截面的温度、压力等参数, 利用改进 BP 神经网络进行信息融合, 从而准确诊断出故障部件. 此方法不存在故障方程法的上述不足, 诊断精度相对较高, 故障诊断过程相对简单.

收稿日期: 2006-12-11; 修订日期: 2007-07-11

作者简介: 赵世荣(1982-), 男, 江苏南京人, 硕士生, 研究方向: 航空发动机故障诊断, E-mail: zhaosr@nuaa.edu.cn.




图 1 基于神经网络多传感器信息融合技术的故障诊断框图

Fig. 1 Diagram of fault diagnosis based on neural network multisensor data fusion

1 基于神经网络信息融合技术的故障诊断原理及结构

基于神经网络多传感器信息融合技术的故障诊断框图如图 1 所示,其核心部分是一个“串联结构的神经网络-模糊推理融合系统”^[7],它是将模糊的概念结合于神经网络的各层中,可以充分发挥神经网络的模式识别、自适应学习优点和模糊推理对人的知识进行推理与决策的功能.多传感器信息融合对来自多个传感器的信息进行综合处理,从而导出新的、有意义的信息,而这种新信息是任何单一传感器所无法获得的,它表示了被监测目标对象的状态行为^[7-8].信息融合通常可分为数据层、特征层和决策层融合.基于神经网络多传感器信息融合技术的故障诊断方法是特征层属性级融合,是将人工神经网络引入信息融合之中,同时结合模糊集合论进行故障类型识别,其具体过程为:通过多传感器测试被诊断对象,求出每个传感器对各类故障的隶属度,将所有传感器的故障隶属度值矢量作为神经网络的输入,网络输出即为融合后各待诊部件属于故障的隶属度值矢量,再根据一定的判定规则进行故障部件的判定.

2 神经网络信息融合故障诊断算法

2.1 性能参数与测量参数的选取及故障样本的产生

本文以某型涡轴发动机为对象,研究基于神经网络信息融合技术的故障诊断方法.涡轴发动机的故障主要发生在压气机,燃气涡轮和动力涡轮,这三大部件也是决定发动机使用寿命的关键部件^[5-6].取压气机效率 η_c ,燃气涡轮效率 η_t 和动力涡轮效率 η_p 为性能参数.对于测量参数的选取,应取决于发动机结构形式和监控功能等因素,所选的测量参数应该能比较敏感地反映被监视部件的性能参数变化,并考虑测量的难易程度^[5].经分析后选取如下 7 个测量参数:压气机出口压力 p_{31} ,压气机出口温度 T_{31} ,动力涡轮导向器进口压

力 p_{43} ,动力涡轮导向器出口压力 p_{44} ,动力涡轮出口温度 T_{45} ,燃油流量 W_f ,燃气涡轮转速 N_g .

故障样本通常可以由实验数据或由发动机数学模型得到.由于实验数据中不可能包括所有故障模式及其严重程度,所以本文根据机理分析结合某型涡轴发动机部件级模型产生故障样本.在发动机模型中,对所选的性能参数分别乘以一个故障系数 α , α 是 0.95~1 之间的常数,等于 1 时发动机无故障.虽然航空发动机比较复杂,有多种多样的故障形式,但由于航空发动机是一个成熟的产品,发生故障的概率通常较小,而同时发生多个故障的可能性更小.尤其是采用状态监视系统的发动机,当一个故障发生后很容易被诊断出来,不至于同时产生几个故障,所以发动机测量参数的变化仅仅是由一、两个故障系数分量所引起的,而其它故障分量并未达到故障状态,对测量参数偏差的影响很小^[6].所以在高度、马赫数为零,一定总距的情况下,将涡轴发动机部件级模型的某一性能参数的故障系数减小到某一值,其他性能参数不变,让模型稳定运行于某一工作点,此时的输出就作为一个故障样本矢量.

2.2 特征提取

对发动机稳态进行故障诊断时,如果待诊样本是由传感器采集来的,由于受随机干扰(大多是白噪声)很严重,应先对信号进行预处理(如“时域同步平均处理”^[6]),然后再进行特征提取.最简单的特征提取方法是直接根据专家知识和经验来确定,但该方法过渡依赖专家经验,在某些情况下是不现实的.本文采用模糊理论进行故障特征提取,也就是通过求取故障样本隶属度的方法来提取故障特征,其关键是选择一个合适的隶属度函数.隶属度函数主要由传感器本身的工作特性及被测参数的特性而定,当涡轴发动机稳定运行于某一工作点时,各截面的温度、压力,转子转速,燃油量等参数应是确定数值,当某部件(压气机、燃气涡轮或动力涡轮)出现故障时,这些参数(部分或全部)一般会偏离正常范围,参数偏差越大的部件相对

来说出现故障的可能性就会变大.结合文献[9]的隶属度函数确定的一般性原则及文献[10-11]中的方法,定义隶属度函数 μ_{ij} 的分布如图 2 所示,

$$\mu_{ij} = \begin{cases} 1 & x_i \leq x_{0ij} - t_{ij} \\ - (x_i - x_{0ij} + e_{ij}) / (t_{ij} - e_{ij}) & x_{0ij} - t_{ij} < x_i \leq x_{0ij} - e_{ij} \\ 0 & x_{0ij} - e_{ij} < x_i \leq x_{0ij} + e_{ij} \\ (x_i - x_{0ij} - e_{ij}) / (t_{ij} - e_{ij}) & x_{0ij} + e_{ij} < x_i \leq x_{0ij} + t_{ij} \\ 1 & x_i > x_{0ij} + t_{ij} \end{cases} \quad (1)$$

式中, x_{0ij} 为发动机稳定运行于某一工作点时的标准测量参数; μ_{ij} 为传感器 i 测定被诊断部件 j 属于故障部件的隶属度; x_i 为传感器 i 的实际测量值; e_{ij} 和 t_{ij} 分别为测量参数的正常变化范围和极限偏差,一般根据经验确定.本文取故障系数 α 为 0.995 时各测量参数偏差的百分比为 e_{ij} , α 为 0.95 时各测量参数偏差的百分比为 t_{ij} .




图 2 隶属度函数分布

Fig. 2 Membership function's distribution

2.3 神经网络融合中心的构造

2.3.1 神经网络算法研究

目前主要有概率神经网络、BP 网络等用来对发动机既定的原型故障进行指示.但模式分类的网络一般不用在基于神经网络信息融合的故障诊断中,因为这类网络输出的是故障类别,这样就难以进行该算法中比较重要的人为“故障决策”过程.BP 神经网络具有良好的模式分类和非线性逼近能力,并且其输出是 0~1 之间的连续量,方便人为的“故障决策”处理,所以选该网络用于某型涡轴发动机的故障诊断.由于 BP 网络存在收敛速度慢、局部极值等缺点,实际应用中都采用改进的 BP 算法.某型涡轴发动机故障诊断所使用的训练样本不多(仅 160 个),并且对训练时间要求不高,但对网络的泛化能力比较关心,经分析比较后选择了用启发式学习算法改进的能复位的 BP 算法(又称为弹性梯度下降法).

其表达式如(1)式.选择此隶属度函数的好处是不仅实现了故障的特征提取,还实现了网络输入数据的归一化处理.

采用能复位的 BP 训练算法,其权值与阈值的调整公式为: $\Delta X = \text{delta } X \cdot \text{sign}(gX)$; 其中, X 为权值与阈值的函数, gX 为表现函数(一般用输出值与期望输出值的均方误差表示)的导数,初始化时 $\text{delta } X$ 为 0.由此式可见,该网络的权值修正取决于表现函数导数的符号,而与导数的数量级没有关系.其原理如下:权值变化的大小由不同的修正值决定,当前两次训练时表现函数导数的符号没有改变,权值和阈值的修正值增加 inc ; 反之,则减小 dec ; 如果导数为 0,则修正值不变.其中, inc 和 dec 分别为该算法修正值的增加量和减少量.这样调整的结果是,权值的变化呈振荡趋势,不过权值变化量逐步减小^[12].

2.3.2 神经网络信息融合

在某型涡轴发动机故障诊断中,采用能复位的 BP 网络有 7 个输入,分别是各测量参数属于故障的隶属度值;输出量有 3 个,对应 3 个被诊断部件;隐层层数设为 1.隐层神经元个数的确定一般采用试凑法,本文经过多次实验比较后选取 16 个隐层神经元.另外,进行 BP 网络信息融合时,学习效率取为 0.01,期望误差为 0.000 1.

2.4 故障判定原则设计^[10-11]

对神经网络融合后输出的各部件属于故障的隶属度值,采用基于规则的方法进行故障决策,其基本原则如下:

- 1) 判定的目标部件应具有最大的隶属度值;
- 2) 判定的目标部件的隶属度值要大于某一阈值.一般来说此值至少要大于待诊断部件个数的倒数,阈值越大诊断的可信度越高,只是该值取得过大时,容易出现故障漏报的情况.对于本文中的某型涡轴发动机故障诊断,经实验分析后发现此值取 0.6 比较合适;
- 3) 判定的目标部件和其他部件的隶属度值之差要大于某个门限.此门限的取值类似于基本原则 2),本文中取为 0.5.

3 仿真实验结果分析

在前文基于神经网络信息融合技术,同时结合模糊集合论对发动机气路部件故障诊断方法研究的基础上,以某型涡轴发动机为对象开展了以下仿真验证实验.

根据 2.1 节介绍的故障样本产生方法分别产生 3 组故障样本,其中“样本组 1”是总距分别为 14.71,14,13,⋯,1,0,故障系数分别为 0.99,0.98,0.955 的条件下得到的,共 160 个(包括每个总距下的正常情况).“样本组 2”与“样本组 1”的总距相同,故障系数分别为 0.985,0.97,0.96 的情况下产生的,共 144 个(不包括正常情况);“样本组 3”与“样本组 2”的故障系数相同,总距分别为 14.21,13.5,12.5,⋯,1.5,0.5,0 的情况下产生的,共 135 个.

对“样本组 1”提取故障特征后,输入到所设计的能复位的 BP 网络中进行训练,共训练 4738 步,耗时 29.8 s.表 1 是总距为 14.71 时的训练样本的故障特征,其中发动机正常的情况没有列出.表 2 是表 1 中的数据经神经网络信息融合后对应的隶属度输出.由表 2 中的数据可见故障部件的隶属度约为 1,而非故障部件的隶属度约为 0,训练结果是令人满意的.

对“样本组 2”和“样本组 3”分别提取故障特征后输入到训练好的网络中进行测试,这两组样本的测试结果是全部诊断正确.表 3 是“样本组 2”中总距为 14.71 的测试样本经神经网络信息融合后对应的隶属度输出.表 4 是“样本组 3”中总距为 14.21 的测试样本经神经网络信息融合后对应的隶属度输出.

表 1 总距为 14.71 时的训练样本故障特征
Table 1 Learning stylebook's fault characters of 14.71 collective pitch

故障系数	p_{31}	T_{31}	p_{43}	p_{44}	T_{45}	W_t	N_g	期望输出
压气机 0.99	0.057 0	0.080 7	0	0	0.241 5	0.343 9	0	1 0 0
压气机 0.98	0.146 4	0.294 3	0.069 1	0.069 1	0.678 4	0.894 6	0	1 0 0
压气机 0.955	0.210 5	0.442 2	0.148 2	0.148 2	0.980 1	1.000 0	0	1 0 0
涡轮 A 0.99	0.038 5	0	0	0	0.359 4	0.487 5	0	0 1 0
涡轮 A 0.98	0.114 5	0	0.132 8	0.132 8	0.919 2	1.000 0	0	0 1 0
涡轮 A 0.955	0.167 0	0	0.231 7	0.231 7	1.000 0	1.000 0	0.006 9	0 1 0
涡轮 B 0.99	0.184 7	0.000 7	0.088 7	0.088 7	0.118 2	0.319 9	0	0 0 1
涡轮 B 0.98	0.393 7	0.115 7	0.317 5	0.317 5	0.365 1	0.751 0	0.087 0	0 0 1
涡轮 B 0.955	0.537 5	0.192 9	0.474 9	0.474 9	0.531 9	1.000 0	0.156 1	0 0 1

注:1)“涡轮 A”表示燃气涡轮,“涡轮 B”表示动力涡轮,以下相同;

2)期望输出“1 0 0”表示压气机故障,燃气涡轮、动力涡轮无故障.

表 2 表 1 对应的隶属度输出
Table 2 Out membership value of talbe 1

	压气机 0.99	压气机 0.98	压气机 0.955	涡轮 A 0.99	涡轮 A 0.98	涡轮 A 0.955	涡轮 B 0.99	涡轮 B 0.98	涡轮 B 0.955
实	1.022 0	0.984 6	0.996 0	0.007 0	- 0.010 2	- 0.002 7	0.029 6	0.001 9	- 0.000 5
	- 0.027 1	0.022 6	0.000 6	0.992 2	1.012 9	0.995 3	- 0.000 6	- 0.007 8	0.002 2
	0.005 5	0.007 2	- 0.011 1	0.002 1	0.011 0	0.002 3	0.997 2	1.000 0	0.998 3
理	1 0 0	1 0 0	1 0 0	0 1 0	0 1 0	0 1 0	0 0 1	0 0 1	0 0 1

注:1)“实”表示网络的实际输出,2)“理”表示理想输出(以下相同)

表 3 “样本组 2”中总距为 14.71 的测试样本对应的隶属度输出
Table 3 Out membership value of “stylebook group 2”’s 14.71 collective pitch

	压气机	压气机	压气机	涡轮 A	涡轮 A	涡轮 A	涡轮 B	涡轮 B	涡轮 B
	0.985	0.97	0.96	0.985	0.97	0.96	0.985	0.97	0.96
	0.997 0	1.015 3	0.871 5	- 0.013 9	0.023 1	0.071 9	- 0.013 6	- 0.277 2	0.055 0
实	0.004 9	0.084 4	- 0.347 4	1.015 2	0.887 7	0.789 1	0.003 5	0.283 8	- 0.075 6
	0.000 9	0.086 3	- 0.119 8	- 0.001 5	- 0.061 3	- 0.200 1	1.004 1	1.025 3	0.954 3
理	1 0 0	1 0 0	1 0 0	0 1 0	0 1 0	0 1 0	0 0 1	0 0 1	0 0 1

表 4 “样本组 3”中总距为 14.21 的测试样本对应的隶属度输出
Table 4 Out membership value of “stylebook group 3”’s 14.21 collective pitch

	压气机	压气机	压气机	涡轮 A	涡轮 A	涡轮 A	涡轮 B	涡轮 B	涡轮 B
	0.985	0.97	0.96	0.985	0.97	0.96	0.985	0.97	0.96
	0.997 0	1.015 3	0.871 5	- 0.013 9	0.023 1	0.071 9	- 0.013 6	- 0.277 2	0.055 0
实	0.004 9	- 0.084 4	- 0.347 4	1.015 2	0.887 7	0.789 1	0.003 5	0.283 8	- 0.075 6
	0.000 9	- 0.086 3	- 0.119 8	- 0.001 5	- 0.061 3	- 0.200 1	1.004 1	1.025 3	0.954 3
理	1 0 0	1 0 0	1 0 0	0 1 0	0 1 0	0 1 0	0 0 1	0 0 1	0 0 1

由以上测试结果及表 1 至表 4 可以看出:从涡轮轴发动机部件截面的某一参数很难得出哪个部件有故障,但在待诊断部件截面的可测参数经过融合后,在本文这两组测试样本中故障识别的准确率达到了 100%,并且故障部件的隶属度约为 1,而非故障部件的隶属度约为 0,所以诊断的可信度比较高。也就是说融合后待诊部件的属于故障隶属度值和单个测量参数的隶属度值相比,增加了实际故障部件的隶属度分配值,相对减少了其他类型的隶属度分配值,提高了学习样本的正确识别率,改善了测试样本的识别性能。这也说明,信息融合能够能使不同信源的信息形成互补,从而减小了系统信息的不确定性,减轻了由于单一参数提供的信息量少而产生的误诊现象,进而能够获得对故障状态的最优估计与判断。

4 结 论

本文研究了基于神经网络信息融合技术,同时结合模糊集合论对发动机气路部件进行故障诊断的方法,并以某型涡轮轴发动机为对象进行了仿真分析。实验结果表明该方法的诊断准确率、诊断可信度都比较高。与采用“故障方程”法诊断的实例对比可以看出该方法精度高,整个故障诊断过

程相对简单。此外,由于采用了模糊理论进行故障特征提取,所以能够利用已有的经验知识提高故障诊断的实用性和准确性,并且还具有对模型的精度要求不高等特点。

参考文献:

[1] 范作民,孙春林,白杰. 航空发动机故障诊断导论[M]. 北京:科学出版社,2004.

[2] Roemer M J, Kacprzyński G J, Scholler M H. Improved diagnostic and prognostic assessments using health management information fusion[R]. IEEE:365-377,2001.

[3] 敖凯军,鲁浩,吴剑秋. 多传感器信息融合技术在发动机状态监控系统中的应用研究[J]. 传感器世界,2004,7:22-25.

AO Kaijun, LU Hao, WU Jianqiu. Application of multi-sensor information fusion technique in aircraft engine condition monitoring system[J]. Sensor World, 2004,7:22-25.

[4] 张雨,温熙森. 设备故障信息融合问题的思考[J]. 长沙交通学院学报,1999,15(2):22-29.

ZHANG Yu, WEN Xisen. The consideration on information fusion of equipment fault [J]. Journal of Changsha Communications University, 1999,15(2):22-29.

[5] 毛景立,李鸣,林健. 某型涡轮轴发动机稳态气路故障诊断方法[J]. 航空动力学报,2002,17(1):69-74.

MAO Jingli, LI Ming, LIN Jian. The research of gas path

- trouble diagnosing for a given turbo-shaft engine in the stable condition[J]. Journal of Aerospace Power, 2002, 17(1): 69-74.
- [6] 李建国, 李本威. 航空发动机故障诊断方程的求解及应用[J]. 燃气涡轮试验与研究, 2002, 15(2): 8-11.
LI Jianguo, LI Benwei. Solution and application of fault diagnosis equation[J]. Gas Turbine Experiment and Research, 2002, 15(2): 8-11.
- [7] 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.
- [8] 王江萍. 基于神经网络的信息融合故障诊断技术[J]. 机械科学与技术, 2002, 21(1): 127-130.
WANG Jiangping. Fault diagnosis technology based on neural network multisensor data fusion[J]. Mechanical Science and Technology, 2002, 21(1): 127-130.
- [9] 王浩, 庄钊文. 模糊可靠性分析中的隶属函数确定[J]. 电子产品可靠性与环境试验, 2000, 8(4): 2-7.
WANG Hao, ZHUANG Zhaowen. Determination of membership function in fuzzy reliability analysis[J]. Electronic Product Reliability and Environmental Testing, 2000, 8(4): 2-7.
- [10] 朱大奇, 于盛林. 电子电路故障诊断的神经网络数据融合算法[J]. 东南大学学报: 自然科学版, 2001, 31(6): 87-90.
ZHU Daqi, YU Shengli. Neural network data fusion algorithm of circuit fault diagnosis[J]. Journal of Southeast University, 2001, 31(6): 87-90.
- [11] 韩静, 陶云刚. 基于 D-S 证据理论和模糊数学的多传感器数据融合算法[J]. 仪器仪表学报, 2000, 21(6): 644-647.
HAN Jing, TAO Yuugang. Data fusion algorithm of multisensor based on D-S evidential theory and fuzzy mathematics[J]. Chinese Journal of Scientific Instrument, 2000, 21(6): 644-647.
- [12] 董长虹. Matlab 神经网络与应用[M]. 北京: 国防工业出版社, 2005.