

# 基于小波和模糊神经网络的涡喷发动机故障诊断\*

杨建国<sup>1</sup>, 孙 扬<sup>2</sup>, 郑 严<sup>2</sup>

(1. 哈尔滨工业大学 汽车工程学院, 山东 威海 264209; 2. 航天机电集团公司31所, 北京 100074)

**摘要:** 提出了一种基于小波和模糊神经网络的涡喷发动机故障诊断方法。即利用小波变换获取特征域, 取特征域上的峰值因子、脉冲因子、裕度因子、偏态因子、峭度因子及频谱最大值作为神经网络的输入, 并对神经网络的输入、输出进行模糊化处理, 以神经网络进行诊断。将该方法成功地应用于某型涡喷发动机的故障诊断, 结果表明, 该方法诊断效果明显。

**关键词:** 小波变换; 人工神经元网络; 模糊算法; 故障诊断; 涡轮喷气发动机

**中图分类号:** V231.92      **文献标识码:** A      **文章编号:** 1001-4055 (2001) 02-0114-04

## Fault diagnosis for turboengine based on wavelet and fuzzy neural network

YANG Jian-guo<sup>1</sup>, SUN Yang<sup>2</sup>, ZHENG Yan<sup>2</sup>

(1. School of Automobile Engineering, Harbin Inst. of Technology, Weihai 264209, China;  
2. The 31st Research Inst., Beijing 100074, China)

**Abstract:** A fault diagnosis method for turboengine based on wavelet and fuzzy network is presented. In this method, wavelet is used to extract fault characteristics and neural network is used to diagnose the faults; the inputs and outputs of the neural network are all memberships concretely, the inputs are the memberships of the crest factor, pulse factor, margin factor, bias factor, kurtosis factor and maximum spectrum on each characteristic domain, and the outputs are memberships of each fault. Applications on a turbo-engine show that the effect of this method is significant.

**Key words:** Wavelet transform; Artificial neural network; Fuzzy algorithm; Fault diagnosis; Turbojet engine

## 1 引言

现代发动机结构越来越复杂, 故障的影响因素众多, 甚至一些故障的机理尚不清楚, 这就导致了故障信号的非平稳性、故障的不确定性和故障与征兆之间的非线性对应关系。小波变换、神经网络和模糊诊断作为新技术, 在故障诊断领域越来越引起人们的重视, 其应用研究也越来越多。但目前的研究基本上只是它们各自独立地在故障特征提取或故障诊断中的应用, 在液体火箭发动机的故障诊断与检测中已有很多研究成果<sup>[1~4]</sup>。本文则将小波变换、神经网络或模糊诊断相结合, 应用于航空发动机故障诊断中。

## 2 诊断方法

### 2.1 总体构想

小波变换具有优良的时频局部化特性, 不仅适合于处理平稳信号, 尤其擅长处理非平稳信号<sup>[1~5]</sup>; 模糊聚类是处理不确定性的有效手段; 神经网络有强大的非线性映射能力及其自学习能力。因此将三者有机结合, 应用于涡喷发动机故障诊断, 将是一种较理想的方法。其总体构想是: 以小波变换(或小波包变换)结合FFT(快速傅立叶变换)作为神经网络的前处理器以提取故障特征; 将神经网络的输入和输出进行模糊化处理, 输入取为故障特征量的隶属度, 输出取为某组数据属于某类故障的隶属度。利用神经网络进行诊断。诊断系统如图1所示。

以上诊断系统的设计目的是: (1) 利用小波变换优良的时频局部化特性及FFT的频率高分辨率, 提取故障特征, 以显化故障信息, 小波变换还能很好适应

\* 收稿日期: 2000-06-14; 修订日期: 2000-09-10。基金项目: 航天工业总公司九五预研基金资助项目。

作者简介: 杨建国 (1964—), 男, 博士, 副教授, 研究领域为机械故障诊断、振动控制及转子动力学。

发动机故障信号的非平稳性; (2) 利用神经网络的非线性映射能力来处理发动机故障模式与故障特征之间的非线性映射关系; (3) 利用模糊数学的手段来处理发动机故障的不确定性。

## 2.2 故障特征提取

利用 FFT 提取故障特征是目前工程上旋转机械领域中最常采用也是最成熟的方法, 但是 FFT 处理含有冲击特征的信号效果极差。而利用小波变换处理

含有冲击特征的信号非常有效<sup>[6]</sup>。小波变换将信号分解到不同的尺度上(得到各尺度上时间信息), 使故障特征在某一或某些尺度(特征域)上得以显化。对各尺度上的时间信号实施 FFT, 还可以得到各尺度上的频谱, 从而将 FFT 和小波变换(及小波包变换)有机地结合起来<sup>[7]</sup>, 兼顾了平稳信号和非平稳信号的处理。小波变换算法如图 2 所示<sup>[7]</sup>。原始信号被分解到了各尺度上的单尺度重构信号  $a$  和  $d$  中。

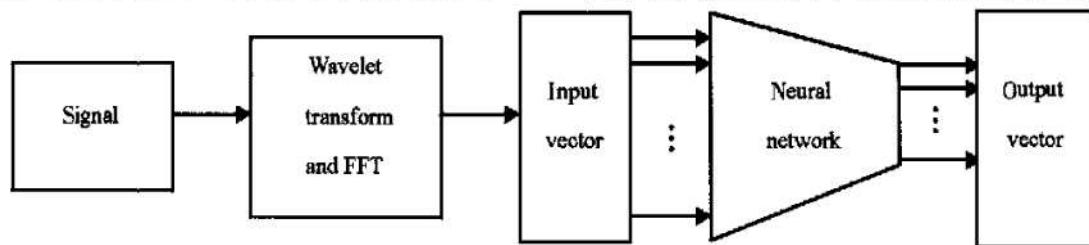


Fig. 1 Fault diagnosis system based on wavelet and fuzzy neural network

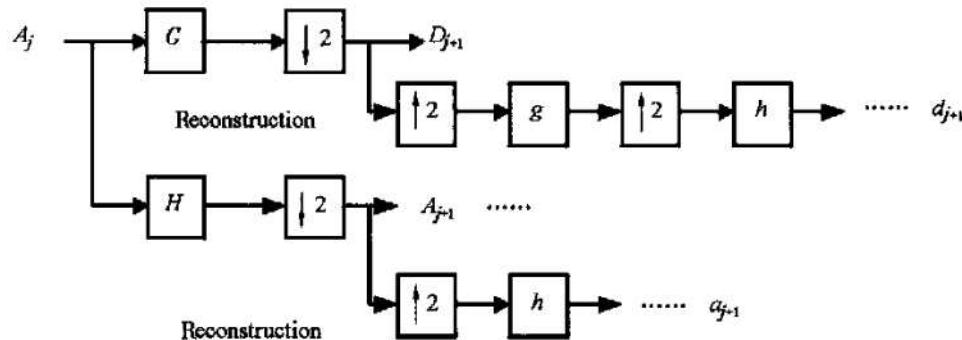


Fig. 2 Fault algorithm of wavelet decomposition and reconstruction from single scale

$\boxed{g}$ ,  $\boxed{h}$ ,  $\boxed{G}$ ,  $\boxed{H}$ : convolving with quadrature mirror filters  $g$ ,  $h$ ,  $G$  or  $H$

$\boxed{\downarrow 2}$ : keep one sample out of  $\boxed{\uparrow 2}$ : put one zero between each sample;

$A_j$ ,  $A_{j+1}$ : approximations at  $2^j$  and  $2^{j+1}$ ,  $D_j$ ,  $D_{j+1}$ : details  $2^j$  and  $2^{j+1}$

## 2.3 神经网络的输入特征量及其模糊化处理

根据具体问题选取小波分解(或小波包分解)后有代表性的尺度作为特征域, 但是如果以各特征域的直接结果作为神经网络的输入, 数据量过大, 将影响神经网络的泛化能力。本文采用对各特征域上信号(时间信号)进行二次特征因子提取的方法加以解决, 即取各特征域上有代表性的峰值因子  $C$ , 脉冲因子  $I$ , 裕度因子  $L$ , 偏态因子  $P$ , 峭度因子  $K$  及频谱最大值  $M$  为输入特征量。五个因子的计算公式分别为:

$$C = \max |x_n| / \sqrt{\frac{1}{T} \sum_{n=1}^N |x_n|^2 \Delta t} \quad (1)$$

$$I = \max |x_n| / \sqrt{\frac{1}{T} \sum_{n=1}^N |x_n| \Delta t} \quad (2)$$

$$L = \max |x_n| / \left\| \frac{1}{T} \sum_{n=1}^N \sqrt{|x_n|} \Delta t \right\| \quad (3)$$

$$P = \frac{\sqrt{N} \sum_{n=1}^N |x_n| \frac{1}{T} \sum_{n=1}^N |x_n| \Delta t}{\left\| \sum_{n=1}^N |x_n| - \frac{1}{T} \sum_{n=1}^N |x_n| \Delta t \right\|^2}^{3/2} \quad (4)$$

$$K = \frac{\left\| \sum_{n=1}^N |x_n| \frac{1}{T} \sum_{n=1}^N |x_n| \Delta t \right\|^4}{\left\| \sum_{n=1}^N |x_n| - \frac{1}{T} \sum_{n=1}^N |x_n| \Delta t \right\|^2}^{2/2} \quad (5)$$

式(1)~(5)中,  $x_n$  为某一样本信号的时间历程,  $N$  为所分析样本的数据点数,  $T$  为所分析样本的时间。

以半升柯西函数作为隶属度函数计算各输入特征量的隶属度, 公式为

$$\mu(x) = \begin{cases} 0 & (0 \leq x \leq a) \\ \frac{1}{1 + \alpha(x-a)^{-\beta}} & (x > a) \end{cases} \quad (6)$$

式(6)中,  $a$ ,  $\alpha$  和  $\beta$  为参数,  $\alpha > 0$ ,  $\beta > 0$ 。参数  $a$ ,  $\alpha$  和  $\beta$ , 采用如下方法确定: 规定正常状态时, 各特征因子的隶属度  $\mu = 0$ ; 报警状态时, 各特征因子的隶属度  $\mu = 0.5$ ; 危险状态时, 各特征因子的隶属度  $\mu = 0.8$ 。各状态的特征因子值由大量的实验数据获得。将这三组特征因子值及其对应的隶属度值代入式(6), 即可解出对应各特征因子的参数  $a$ ,  $\alpha$  和  $\beta$ 。

各特征量的隶属度作为神经网络的输入。

#### 2.4 神经网络输出的模糊化处理

传统的多层感知器用于模式分类, 在网络训练时其输出是二值的(0或1), 应用于未知的数据时, 取输出最大者为分类结果。这种方法分类结果明确, 但是难以处理分类边界模糊的数据<sup>[8]</sup>。传统的模糊分类方法, 不管根据最大隶属度原则还是阈值原则, 都有可能给出不符实际的诊断结果或漏诊<sup>[8]</sup>。让神经网络的输出反映某组数据属于某类的模糊隶属度, 从而利用神经网络对边界模糊的数据进行分类, 就弥补了上述不足。

选取夹角余弦函数作为隶属度函数计算神经网络输出的分类隶属度。设有  $m$  类故障, 则神经网络有  $m$  个输出。再设  $c_j$  为第  $j$  类模式的聚类中心, 则第  $i$  个模式属于第  $j$  类的隶属度为

$$\mu_j = \frac{\sum_{k=1}^M y_{ik} c_{jk}}{\sqrt{\sum_{k=1}^M y_{ik}^2 \sum_{k=1}^M c_{jk}^2}} \quad (7)$$

式中  $M$  为每一模式中特征参量的总数,  $y_{ik}$  和  $c_{jk}$  分别为第  $i$  个模式和第  $j$  类模式聚类中心  $c_j$  的第  $k$  个元素。  $c_{jk}$  由下式确定

$$c_{jk} = \frac{\sum_{s=1}^J y_{sk}}{J} \quad (8)$$

式(8)中  $J$  为第  $j$  类的模式数,  $y_{sk}$  为第  $j$  类第  $s$  个模式

的第  $k$  个元素。

### 3 某型涡喷发动机故障诊断

诊断系统的核心是一 BP 神经网络。网络的输入如下: 选择 Daubechies 小波 db10, 利用小波变换将时间历程信号分解至 3 层, 得到 4 个特征域, 计算 4 个特征域上的峰值因子  $C$ 、脉冲因子  $I$ 、裕度因子  $L$ 、偏态因子  $P$  和峭度因子  $K$  及其隶属度; 分别对 4 个特征域上的时间波形进行 FFT, 得到 4 个特征域上的频谱, 计算 4 个特征域上的频谱最大值  $M$  及其隶属度。将共获得的 24 个隶属度值作为神经网络的输入。网络的输出之一对应标准正常状态, 其它输出的数目随标准故障数据种类而定, 比如不平衡、不对中、碰撞、轴裂纹、轴承内外环剥蚀等故障。本文研究中考虑发动机试制中出现的轴裂纹、动静碰撞故障。神经网络选取单隐层 BP 网, 采用动量( $mc$ )-自适应学习率( $lr$ )调整算法对网络进行训练以提高训练速度。

网络参数取值如下: 动量因子  $mc = 0.75$ , 初始学习率  $lr_0 = 0.01$ , 终止误差  $E = 0.001$ , 为了比较训练及诊断效果, 隐层神经元数分别取 10, 20 和 30 三种情况。标准训练样本取自发动机台架试验的三组典型数据, 分别对应发动机正常工作及轴裂纹、动静碰撞故障。每种状态取 20 个样本进行训练。从收敛速度上看, 随隐层神经元数增加, 收敛速度加快。下面是利用这种方法对该型发动机的一个诊断实例, 三个振动信号  $x_1$ 、 $x_2$  和  $x_3$  由发动机研制单位提供, 不在训练样本之内, 分别对应发动机正常工作及轴裂纹、摩擦三种状态。表 1 是各特征域上输入隶属度函数参数, 表 2 是对应于信号  $x_1$ 、 $x_2$  和  $x_3$  的输入隶属度, 表 3 是诊断结果。为了比较, 表 4 给出了不对信号进行小波变换, 直接利用模糊神经网络进行诊断的结果。

Table 1 Parameters of input membership function on each characteristic domain

Characteristic domain	Characteristic variable	$a$	$\alpha$	$\beta$	Characteristic domain	Characteristic variable	$a$	$\alpha$	$\beta$
$d_1$	$M$	0.002	0.039	0.327	$d_3$	$M$	0.007	0.056	1.264
	$C$	2.883	21.39	1.175		$C$	3.081	0.548	2.000
	$I$	3.540	77.22	1.241		$I$	3.831	0.945	2.000
	$L$	4.122	107.8	1.248		$L$	4.503	1.399	2.000
	$P$	7.427	17.49	1.262		$P$	0.916	0.120	2.000
	$K$	3.001	2.277	1.314		$K$	3.502	1.875	2.000
$d_2$	$M$	0.007	0.062	1.273	$a_3$	$M$	0.056	0.586	1.254
	$C$	2.962	0.666	2.000		$C$	1.672	1.379	2.000
	$I$	3.705	1.043	2.000		$I$	1.865	2.062	2.000
	$L$	4.340	1.502	2.000		$L$	2.045	2.728	2.000
	$P$	0.713	0.072	2.000		$P$	0.030	0.189	1.233
	$K$	2.916	1.227	2.000		$K$	1.927	2.407	2.000

**Table 2 Input membership of wavelet and fuzzy neural network**

Signal	Characteristic domain	<i>M</i>	<i>C</i>	<i>I</i>	<i>L</i>	<i>P</i>	<i>K</i>
$x_1$	$a_3$	0.830 0	0	0	0	0.638 1	0.000 0
	$d_3$	0.578 0	0.479 9	0.472 3	0.464 4	0.249 4	0.442 6
	$d_2$	0.545 6	0.135 1	0.152 4	0.167 9	0.611 5	0.485 7
	$d_1$	0.785 8	0.618 7	0.592 2	0.589 1	0.655 2	0.512 4
$x_2$	$a_3$	0.010 9	0.406 8	0.452 9	0.483 6	0.730 8	0.290 6
	$d_3$	0.046 8	0.343 6	0.370 2	0.365 4	0.533 2	0.587 9
	$d_2$	0.019 1	0	0	0	0.396 4	0.171 6
	$d_1$	0.744 6	0	0	0	0	0
$x_3$	$a_3$	0.387 5	0.321 2	0.342 3	0.357 6	0.578 7	0.149 8
	$d_3$	0.534 6	0.185 0	0.184 8	0.179 9	0.010 3	0.008 4
	$d_2$	0.396 0	0.489 7	0.464 2	0.428 0	0.626 5	0.616 8
	$d_1$	0.781 9	0.092 1	0.037 4	0.032 4	0.016 8	0.001 2

**Table 3 Diagnosis result by wavelet and fuzzy neural network**

No. of hidden unit	Signal	Normal	Shaft crack	Friction	Result
10	$x_1$	0.920 0	0.601 8	0.679 7	Normal
	$x_2$	0.540 9	0.958 3	0.745 2	Shaft crack
	$x_3$	0.345 1	0.633 6	0.924 9	Friction
20	$x_1$	0.960 6	0.464 3	0.672 9	Normal
	$x_2$	0.543 0	0.972 1	0.703 9	Shaft crack
	$x_3$	0.226 4	0.542 4	0.962 8	Friction
30	$x_1$	0.940 1	0.649 0	0.656 0	Normal
	$x_2$	0.547 6	0.958 5	0.747 2	Shaft crack
	$x_3$	0.361 9	0.599 1	0.937 0	Friction

**Table 4 Diagnosis result by fuzzy neural network**

Signal	Normal	Shaft crack	Friction	Result
$x_1$	0.911 1	0.751 4	0.765 1	Normal
$x_2$	0.683 6	0.908 0	0.791 8	Shaft crack
$x_3$	0.736 4	0.763 6	0.920 8	Friction

诊断结果表明, 利用小波变换和模糊神经网络相结合的方法正确地诊断出了故障, 直接利用模糊神经网络的方法也能正确地诊断出故障, 但效果不如前者明显。由此可见, 有机地结合小波变换、模糊聚类和神经网络来诊断涡喷发动机的运行状态, 是一种行之有效的方法。

比较隐层神经元数为 10, 20 和 30 三种情况, 见表 3。20 个隐层神经元的诊断效果要好于其它两种, 在其它事例中也有类似的发现。所以, 尽管随着隐层节点数的增加, 网络的收敛速度加快, 但考虑诊断效果, 隐层神经元数取 20 为宜。

## 4 结 论

本文提出的涡喷发动机故障诊断方法, 将小波变

换、FFT、模糊聚类和神经网络四者有机地结合起来, 充分利用各自的长处, 很好地适应了发动机故障信号的非平稳性、故障模式与故障特征之间的非线性映射关系以及故障的不确定性等特点。通过对某型涡喷发动机的初步应用表明, 该方法能够准确地诊断其运行状态及故障, 效果显著。该方法的关键是积累大量的发动机正常信号及标准故障信号, 对神经网络进行充分地训练。在计算速度要求较高的场合, 可考虑略去小波变换环节, 直接采用模糊神经网络进行故障诊断。

## 参 考 文 献:

- [1] 杨尔辅, 张振鹏. 小波分析及其在推进系统健康监控中的应用[J]. 推进技术, 1997, 18(1).
- [2] 黄敏超, 张育林, 陈启智. 神经网络在液体火箭发动机故障检测中的应用( iv) 非线性辨识技术[J]. 推进技术, 1999, 20(1).
- [3] 黄敏超, 张育林, 陈启智. 神经网格在液体火箭发动机故障检测中的应用( ④) 模式识别技术[J]. 推进技术, 1999, 20(2).
- [4] 程惠涛, 黄文虎, 姜兴渭. 基于灰色模型的故障预报技术及其在空间推进系统上的应用[J]. 推进技术, 1998, 19(3).
- [5] Rioul O, Vetterli M. Wavelet and signal processing[J]. IEEE SP Magazine, 1991: 14~ 38.
- [6] 杨建国, 夏松波, 须根法. 基于小波的周期信号中瞬态冲击特征提取[J]. 航空动力学报. 1999, 14(4): 343~ 347.
- [7] 杨建国. 小波变换及其在涡喷发动机故障诊断中应用的研究[D]. 哈尔滨工业大学, 1999.
- [8] 许云飞, 贾民平, 重秉林, 等. 旋转机械振动故障诊断的一种模糊神经网络方法的研究[J]. 振动工程学报, 1996, 9(3): 213~ 219.

(编辑: 王居信)