

文章编号: 1000-6893(2002) 02-0155-03

# 基于概率神经网络的发动机故障诊断

叶志锋, 孙建国

(南京航空航天大学 能源与动力学院, 江苏 南京 210016)

## PROBABILISTIC NEURAL NETWORKS BASED ENGINE FAULT DIAGNOSIS

YE Zhi-feng, SUN Jian-guo

(College of Energy and Power, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

**摘 要:** 用反向传播神经网络(BPNN)和概率神经网络(PNN)对航空发动机若干原型故障进行定性的诊断, 并将仿真结果进行了比较。仿真结果表明, 当测量参数不包含噪声或噪声较小时, 两种网络都具有很高的诊断准确率; 当测量参数的噪声较大时, 则概率神经网络的诊断准确率远大于反向传播神经网络, 显示了概率神经网络较强的诊断鲁棒性。此外, 概率神经网络能够充分利用故障先验知识, 并考虑代价因子的作用, 从而把误诊断可能带来的损失减小到最低程度。

**关键词:** 神经网络; 航空发动机; 故障诊断; 视情维护

中图分类号: V263.6 文献标识码: A

**Abstract:** In this paper, both back-propagation neural networks (BPNN) and probabilistic neural networks (PNN) are applied to qualitative aero-engine prototype fault diagnosis, and the simulated results are compared with each other. The simulated results show that when the measurements do not contain any noise or the noises are comparatively small, the success rates of diagnosis of both BPNN and PNN are quite high; when noises rise, the success rate of PNN is much higher than that of BPNN.

**Key words:** neural networks; aero-engine; fault diagnosis; unscheduled maintenance

早期典型的故障诊断工具是基于一个发动机气动热力学数学模型而展开的<sup>[1,2]</sup>, 它能够辨识各部件的性能损耗, 探测多故障及对部件性能退化进行量化。这种系统充分利用了发动机的模块化(单元体)结构, 将某一工况下的测量参数与同一工况下无故障的参考值(来自模型)相比较, 产生差值, 当这个差值超过事先统计确定的系统不可靠的极限时, 即产生诊断结果。该方法的局限性主要表现为当模型精度不够, 或者测量信号中存在噪声和偏置时, 诊断准确率将大大降低。

20 世纪 80 年代末, 神经网络开始应用于航天及航空发动机的状态监视和故障诊断研究中。神经网络因其强大的非线性映射能力和并行处理能力, 非常适合于解决发动机的故障诊断问题, 特别是作为快速的即时诊断工具。现在, 神经网络已被认为是解决发动机故障诊断问题最具潜力的工具之一, 并已获得一些成功的实际应用<sup>[3]</sup>。

本文以 PW4000 涡扇发动机为对象, 对其常见的若干个原型故障分别用 BPNN 和 PNN 进行定性的诊断, 并将仿真结果进行了比较和讨论。

## 1 概率神经网络

概率神经网络(PNN)<sup>[4]</sup>是一种可用于模式分类的神经网络, 其实质是基于贝叶斯最小风险准则发展而来的一种并行算法, 目前已在雷达、心电图仪等设备中获得应用。与 BPNN 相比较, 其主要优点为: ①快速训练, 其训练时间仅仅略大于读取数据的时间; ②无论分类问题多么复杂, 只要有足够多的训练数据, 可以保证获得贝叶斯准则下的最优解; ③允许增加或减少训练数据而无需重新进行长时间的训练。

贝叶斯理论提供了一种最优的分类方法, 由于它无可辩驳的理论基础, 常常作为一种分类器的标准对其它的分类方法进行评估。为简单起见, 这里考虑两个故障模式  $a$ 、 $b$  的诊断问题。设待诊断的测量向量为  $X$ , 按照贝叶斯最小风险准则, 有下列诊断规则:

$$\left. \begin{array}{l} X \text{ 属于 } a, \text{ 若 } H_a L_a f_a(X) > H_b L_b f_b(X) \\ X \text{ 属于 } b, \text{ 若 } H_a L_a f_a(X) < H_b L_b f_b(X) \end{array} \right\} \quad (1)$$

式中:  $H_a$ 、 $H_b$  分别为  $X$  属于  $a$ 、 $b$  的先验概率;  $L_a$ 、 $L_b$  分别为对  $a$ 、 $b$  故障进行误诊断的代价因子;  $f_a(X)$ 、 $f_b(X)$  分别为  $X$  属于  $a$ 、 $b$  的条件概率密度函数。 $f_a(X)$  可以从训练样本中获得

$(f_b(\mathbf{X}) \text{ 同理})^{[4]}$

$$f_a(\mathbf{X}) = \frac{1}{(2\pi)^{p/2}\sigma^p} \frac{1}{N_a} \cdot \prod_{i=1}^{N_a} \exp\left[-\frac{(\mathbf{X} - \mathbf{X}_{ai})^T(\mathbf{X} - \mathbf{X}_{ai})}{2\sigma^2}\right] \quad (2)$$

式中:  $p$  为待分类的向量  $\mathbf{X}$  及训练向量的维数;  $N_a$  为故障模式  $a$  的训练样本的数量;  $\mathbf{X}_{ai}$  为故障模式  $a$  的第  $i$  个训练向量;  $\sigma$  为平滑参数。

如果对所有训练向量和待诊断向量进行模归一化, 则有

$$[\mathbf{X} - \mathbf{X}_{ai}]^T(\mathbf{X} - \mathbf{X}_{ai}) = -2(\mathbf{X}^T\mathbf{X}_{ai} - 1) \quad (3)$$

考虑到

$$H_a = N_a / N_{\text{total}} \quad (4)$$

这里  $N_{\text{total}}$  为训练样本的总数, 式(2) ~ 式(4)代入式(1)后, 对故障模式  $a$  的诊断规则变为(故障模式  $b$  同理)

$\mathbf{X}$  属于  $a$ , 若

$$L_a \prod_{i=1}^{N_a} \exp\left[\frac{\mathbf{X}^T\mathbf{X}_{ai} - 1}{\sigma^2}\right] > L_b \prod_{i=1}^{N_b} \exp\left[\frac{\mathbf{X}^T\mathbf{X}_{bi} - 1}{\sigma^2}\right] \quad (5)$$

实现上述 2 种模式分类算法的概率神经网络如图 1 所示。网络共分 4 层, 分别为输入层、模式层、求和层及决策层。输入层接受输入向量并进行规格化; 模式层的响应函数为

$$Y_{ai} = \exp\left[\frac{\mathbf{X}^T\mathbf{X}_{ai} - 1}{\sigma^2}\right] \quad (6)$$

求和层将模式层中同一模式的输出求和并乘以代价因子; 决策层则选择求和层中输出最大者对应的故障模式为诊断结果。当故障样本的数量增加时, 图中模式层神经元将随之增加。而当故障模式多于 2 种时, 则求和层神经元将增加。所以, 随着故障先验知识的积累, 概率神经网络可以不断横向扩展, 故障诊断的能力将不断提高。




图 1 概率神经网络

Fig. 1 Probabilistic neural networks

## 2 故障诊断神经网络的结构

(1) 输入信号的选择 为了使诊断网络获得准确的发动机信息, 应选择精度高, 稳定性好并容易测量的信号作为诊断网络的输入。对 PW4000 发动机来说, 下列 8 个参数可被选择作为网络的输入信号: 喷口燃气温度  $T_{49}$ , 供油量  $W_f$ , 高压轴转速  $N_2$ , 低压轴转速  $N_1$ ,  $P_{25}$ ,  $T_{25}$ ,  $T_3$  及  $P_3$ 。为了使网络的参数具有相同的数量级以保证计算精度, 所有的网络训练数据和诊断数据均应以其增量的百分比表示。

(2) 被诊断的原型故障 共有 12 种最常见的故障被选择作为诊断的原型故障(即故障模式)。这些故障包括: ① 风扇性能退化; ② 低压压气机性能退化; ③ 高压压气机性能退化; ④ 高压涡轮性能退化; ⑤ 低压涡轮性能退化; ⑥ 防喘放气门泄漏; ⑦ 起动放气门泄漏; ⑧ 风扇出口面积改变; ⑨ 核心机出口面积改变; 10 涡轮机匣冷却阀误开启; 11 高压压气机静子叶片调节不到位; 12  $P_{49}$  指示故障。

所以, BPNN 和 PNN 用作该发动机故障诊断时, 需要有 8 个输入节点和 13 个输出节点(其中一个作为无故障的输出)。经过多次试算, BP 网络的中间层取 12 个神经元, 此时 BP 网络训练速度较快, 精度亦能满足要求。上述网络经过训练后, 只要测量参数送入网络的输入层, 网络的输出就是相应的故障诊断结果。

## 3 仿真诊断结果及讨论

本文利用文献[5]提供的 PW4000 发动机的上述 12 种原型故障的影响系数矩阵作为故障样本对网络进行训练, 即每一种故障对应的测量参数变化的百分比(影响系数矩阵中的一行)作为一个样本, 所有样本的集合构成了样本空间。假设历史上每种故障只发生过一次, 即 12 种故障的先验概率相同。PNN 训练过程中没有考虑各种故障的代价因子  $L$  的影响(均取 1), 平滑参  $\sigma$  取 0.1(后面的仿真诊断表明, PNN 的诊断准确率对平滑参数不敏感)。

为了检测 2 种网络对故障的诊断准确率, 可以利用训练后的网络对仿真故障进行诊断。仿真需要的含有噪声的传感器测量数据通过下式获得

$$\text{传感器数据} = \text{纯净数据} + KDb_{\text{rand}} \quad (7)$$

式中:  $K$  为噪声幅度控制参数;  $D$  为传感器散射度的标准偏差<sup>[6]</sup>,  $b_{\text{rand}}$  为均值为 0、方差为 1 的正

态分布随机数向量。利用式(7)对每种故障及无故障情况分别产生 100 组带噪声的测量参数, 在未经任何预处理的情况下直接供 BPNN 及 PNN 进行诊断。诊断结果表明, 网络的诊断准确率主要受噪声幅度  $K$  的影响。表 1 为  $K = 0, 0.1, 0.2$  及  $0.4$  时 BPNN 及 PNN 两种网络的诊断准确率统计结果(即 100 次诊断中诊断准确的次数, 表中第 1 行数字 1~12 表示 12 种故障的序号)。表 1 表明, 当测量参数不包含噪声( $K = 0$ )时, 两种网络都可以达到 100% 的诊断准确率; 当噪声较小( $K = 0.1$ )时, PNN 保持 100% 的准确率, BPNN 亦具有很高的诊断准确率(平均 95.8%); 当测量参数的噪声较大( $K = 0.4$ )时, BPNN 只能达到平均 51.6% 的诊断准确率, 而 PNN 则保持了 91.5% 的高准确率。可见概率神经网络的诊断能力远大于反向传播神经网络, 显示了概率神经网络较强的诊断鲁棒性。仿真诊断结果还表明, 低压压气机性能退化、防喘放气门泄漏及核心机出口面积改变等 3 种故障的诊断准确率相对比较低。事实上, 正是这 3 种故障相互之间比较容易被误诊。

表 1 BPNN 及 PNN 两种网络在 100 次诊断中的准确率统计

Table 1 Success rates in 100 diagnoses of BPNN and PNN

噪声幅度	$K = 0$		$K = 0.1$		$K = 0.2$		$K = 0.4$	
	BPNN	PNN	BPNN	PNN	BPNN	PNN	BPNN	PNN
有故障								
1	100	100	100	100	80	100	36	100
2	100	100	96	100	68	98	59	87
3	100	100	93	100	66	100	41	98
4	100	100	100	100	92	100	55	97
5	100	100	98	100	70	100	61	100
6	100	100	93	100	68	97	61	70
7	100	100	90	100	64	99	47	88
8	100	100	99	100	65	100	44	94
9	100	100	94	100	71	99	62	84
10	100	100	95	100	60	100	45	100
11	100	100	99	100	68	100	31	92
12	100	100	99	100	90	100	77	96
无故障								
平均	100	100	95.8	100	71.6	99.4	51.6	91.5
%								

## 4 结 论

基于概率神经网络的故障诊断方法可以最大

程度地利用故障先验知识, 在贝叶斯最小风险准则下对发动机的单故障进行定性诊断。概率神经网络训练速度快, 在工程上容易实现, 而且对传感器测量噪声具有较强的诊断鲁棒性, 可以达到较高的诊断准确率。随着故障知识的逐渐积累, 网络可以不断扩张而进一步提高诊断准确率。

## 参 考 文 献

- [1] Doel D L. Temperature gas path analysis tool for commercial jet engines[J]. Transactions of the ASME J of Engineering for Gas Turbines and Power, 1994, 116(1): 82- 89.
- [2] Barwell M J. COMPASS: ground based engine monitoring program for general application[R]. SAE Technical Paper No. 871734, 1987.
- [3] Eustace R, Merrington G. Fault diagnosis of fleet engines using neural networks[A]. ISABE 95-708[C], 1995: 926 - 936.
- [4] Specht D F. Probabilistic neural networks[J]. Neural networks, 1990(3): 109- 118.
- [5] Volponi A J, Pold H D, Ganguli R, et al. The use of Kalman filter and neural networks methodologies in gas turbine performance diagnostics: a comparative study[A]. In: Proceedings of ASME TURBO EXPO 2000[C], Munich, Germany, 2000.
- [6] LU Pong-Jeu, Zhang Ming-Chuan, Hsu Tzu-Cheng, et al. An evaluation of engine faults diagnostics using artificial neural networks[A]. In: Proceedings of ASME TURBO EXPO 2000[C], Munich, Germany, 2000.

### 作者简介:



叶志锋(1962-) 男, 浙江人, 南京航空航天大学能源与动力学院副教授, 1986 年毕业于哈尔滨工业大学机械工程系, 2000 年赴澳大利亚 Newcastle 大学进修, 主要从事发动机控制、发动机故障诊断方面研究, Email: yezhifeng@263.net, 电话 025- 4892252。



孙健(1939-) 男, 上海人, 南京航空航天大学能源与动力学院教授、博士生导师, 1962 年毕业于南京航空航天大学飞机系, 1982- 1984 年赴美国 Columbia 大学进修, 主要从事发动机控制、飞/推综合控制及发动机故障诊断等方面研究, Email: jgspe@nuaa.edu.cn, 电话 025- 4893186。

(责任编辑: 李铁柏)