

Kohonen 网络在发动机故障诊断中的应用

范作民 白 杰 阎国华
(中国民航学院 机电系, 天津 300300)

摘要: 文中第一部分研究了利用 Kohonen 网络进行发动机故障诊断的特点与算法。并以 JT9D 发动机为例对算法的有效性进行了检验, 23 个故障样本的确诊率达到 87%。文中还以一个典型例子进行了详细分析。文中第二部分提出了利用 Kohonen 网络进行故障诊断结果排序的方法, 该方法有助于给出简明的诊断结论。文中第三部分提出了利用 Kohonen 网络提取故障样本群的代表性样本的方法。该方法对于经验故障方程的建立十分有用。研究表明, 自组织映射模型程序简单、应用方便, 诊断结果不受训练样本的病态影响, 特别是能够以非常简单而直观的方式揭示样本群的统计特性, 是一种适用于发动机分类故障诊断的较好的、具有特色的神经网络模型。

关键词: 神经网络; 航空发动机; 故障诊断; 模式识别

中图分类号: V 263. 6

文献标识码: A

1 前 言

人工神经网络在发动机故障诊断中的应用正在受到广泛的注意。目前研究得较多的是反向传输网络, 即 BP 网络。BP 网络的样本训练过程相当复杂而且极不灵活。BP 网络的另外两个缺点较少为人所注意, 即 BP 网络通常只能给出一个解以及 BP 网络的解受训练样本病态影响较大^[1]。另一种不需要教师的自组织映射模型即 Kohonen 网络^[2]可以克服这些缺点。Kohonen 网络在拓扑映照(模式识别)、样本排序、样本分类等方面有广泛应用。关于 Kohonen 网络的基本原理和算法可参看文献^[2]。本文的目的是讨论 Kohonen 网络在发动机分类故障诊断中的应用。

2 Kohonen 网络接近测度的设定 与连接权的调整

Kohonen 网络中的兴奋神经元 C 由权向量 w 最接近输入样本向量 x 的条件确定, 本文选取 w 与 x 的距离 d_c 作为接近测度:

$$d_c = \|w_c - x\| = \min_j \|w_j - x\| \quad (1)$$

式中: w_j 为神经元 j 与 x 的连接权。

Kohonen 网络训练过程的效率和稳定性与网络结构以及权值调节的具体方案密切相关。对于本文研究对象, 由程序调试结果得出如下方案: 输出平面的神经元个数对于二维输出最好不少于故障样本数的 10 倍; 对于一维输出, 不应少于其 3 倍。连接权的调整方法如下:

$$w_j(t+1) = w_j(t) + a(d)a(t)[x - w_j(t)] \quad (j \in N_c) \quad (2)$$

$$w_j(t+1) = w_j(t) \quad (j \notin N_c) \quad (3)$$

式中: t 为时间(训练次数), $a(d)$ 为距离 d_c 函数, 而 $a(d)$ 和 $a(t)$ 与 N_c 均为时间函数。取为:

$$a(d) = \exp\left[-R \times \left(\frac{r-r_c}{N_{\max}}\right)^2\right] \quad (4)$$

$$N_c(t) = N_{\max} \left(1 - \frac{t-1}{A}\right) \quad (5)$$

$$a(t) = B(1 - t/C) \quad (6)$$

式中: $N_{\max}$ 为输出平面最大的一维神经元个数, $R = 0.3 \sim 1.0$, $A = 30 \sim 150$, 而 $B = 0.5 \sim 1.5$, $C = 3 \sim 150$ 。

收稿日期: 1999-02-09; 修订日期: 1999-04-25

基金项目: 国家自然科学基金资助项目(59876046)

作者简介: 范作民(1933-), 男, 中国民航学院机电系教授

3 Kohonen 网络用于发动机故障诊断的特点

文献[1]中曾经指出, 利用BP 网络进行发动机故障诊断时, 应当对故障样本向量进行一些必要处理。这些观点对 Kohonen 网络仍适用。

下面以 JT9D 发动机的故障诊断问题为例, 说明 Kohonen 网络的应用特点。文献[4]给出了 JT9D 发动机的 23 个实际故障样本。利用已知的 18 个小偏差系数以及 Kohonen 网络进行诊断。只有 1 个样本未能被正确诊断(按诊断结果排序的前两名统计, 关于排序问题见后)。有 2 个故障样本的故障模式位于“第 2 名”, 其余 20 个样本的故障模式都位于诊断结果排序的“第 1 名”。以排序的前 1 名和前 2 名统计的确诊率分别为 87% 与 96%。下面以一个典型例子加以说明。被诊断的实际故障样本(记为 MX)为 $y = [0.20, -1.30, 18.20, 3.80]^T$ (JT9D 发动机高压涡轮第一级导向器叶片烧毁一片)。y 的 4 个分量分别为低压压气机转速、高压压气机转速、排气温度以及燃油流量。为说明清楚起见, 在下面的例子中不是用上面实例检验中所用的 18 个小偏差系数, 而是只用 5 个转动部件的 10 个小偏差系数作为已知故障模式进行诊断, 分别记为 M 1, M 2, M 3, M 4, M 5, M 6, M 7, M 8, M 9, M 0。根据给定的条件, 取输入层的神经元个数为 4, 而输出层的神经元分别按 10×10 的二维排列与个数为 30 的一维输出。将被诊断样本与已知故障模式放在一起进行学习训练。测量误差的标准差取为 $\sigma = (0.13, 0.13, 1.5, 0.7)^T$ 。对于二维输出与一维输出两种

方案, 分别得到如图 1 与图 2 所示的输出。




图 1 Kohonen 网络的二维输出

图中的 * 号表示对所有的输入都不兴奋的神经元。可以看到, 被诊断对象 MX 与训练样本中的 M 8 最为接近, 表明这是属于高压涡轮第一级导向器出口面积方面的故障。诊断结果与实际情况一致。实际上, 这一结果的正确性不难由被诊断故障样本向量与各已知故障模式向量之间的相似度(夹角余弦)来证实。在表 1 中给出了样本 MX 与已知的 10 个故障模式之间的加权相似度(其值在 1 至- 1 之间):

$$S_{u,v} = \frac{u^T v}{[(u^T u)(v^T v)]^{1/2}} \tag{7}$$

以及标准化加权距离(其值在 0 至 2 之间):

$$D_{u,v} = (u^* - v^*)^T (u^* - v^*) \tag{8}$$

式中: $u^* = \frac{u}{(u^T u)^{1/2}} ; v^* = \frac{v}{(v^T v)^{1/2}}$

可以看到与被诊断样本最接近的确实是 M 8。此外, 可以看到, 输出平面上的神经元是按相似度的代数值而不是绝对值分布的。



图 2 Kohonen 网络的一维输出

表 1 故障样本MX 与 10 个已知故障模式之间的加权夹角余弦和标准化距离

	MX	M 8	M 7	M 5	M 6	M 2	M 3	M 1	M 9	M 4	M 0
S_{ij}	1.000	0.989	0.916	0.873	0.560	0.236	- 0.143	- 0.260	- 0.406	- 0.496	- 0.704
B_{ij}	0.000	0.150	0.410	0.504	0.938	1.237	1.512	1.588	1.677	1.730	1.846

Kohonen 网络的输出不仅指出被诊断样本属于哪一种已知的故障模式, 而且还同时指出已

知的、作为训练样本的故障模式中有哪些是相似的(近似线性相关)。例如由图 1 可知已知故障模

式中的M 5,M 7 与M 8 的小偏差系数向量是相似的(这也可由表 1 看出)。相似样本的存在表明故障诊断结果应当具有多个解并且容易得到“病态”解。因此所得结果表明 Kohonen 网络具有良好的“抵抗病态”的能力,而这正是BP 网络的主要缺点。此外,与BP 网络比较,Kohonen 网络的程序编制与学习过程相当简单,新样本可以与已知的故障样本同时进行自学习组织而无需预先训练。对于所给出的例子,Kohonen 网络每诊断一个样本需时 1.5 秒(P II 350 机),BP 网络的训练过程需时几百秒,诊断需时则很短,但计算量显然远大于最小距离法或最大夹角余弦法。在现在的计算机计算速度下,Kohonen 网络与BP 网络的计算时间都不是主要问题。对于像这里讨论的简单分类诊断问题,采用两向量之间的夹角余弦或距离来进行判断是最简单的。但是 Kohonen 模型可以给出更为直观的以及更多的信息。最小距离法(表 1)只能指出被诊断对象与其他故障模式之间的距离,而不能给出所有样本之间的相互关系。在表 1 中,样本M 1 与M 9 紧靠在一起。实际上,它们之间的距离是 1.723,比它们分别与M X 之间的距离还大。但是在 Kohonen 网络的输出平面上,这

些关系就能清楚地反映出来。M 2 与M 3 的情况也是如此(它们之间的距离为 1.838)。

4 Kohonen 网络诊断结果的排序

Kohonen 网络的输出是二维平面上的拓扑结构,而不是定量的数值结果。这给故障诊断结果的整理有些不便。但是这一问题不难解决。Kohonen 网络的输出本身就存在着诊断结果定量评价的信息。例如,可以用输出平面上被诊断故障样本与各已知模式之间的几何距离 D_i 作为评价指标:

$$D_i = [(j - j^*)^2 + (k - k^*)^2]^{1/2} \tag{9}$$

式中: j^* 与 k^* 为被诊断样本在 Kohonen 网络输出平面上的坐标,而 j 与 k 分别为已知故障模式在 Kohonen 网络输出平面上的坐标。不仅如此,我们还可以利用 Kohonen 网络本身具有的样本排序功能(不需要另外编制排序程序)对 D_i 值进行排序(在这种情况下应当采用一维输出)。

在表 2 中给出了对于图 1 输出结果计算的 D_i 值及 Kohonen 网络排序(在本例中,是按 D_i 值从大到小排列的)。在第 4 节中所提到的故障诊断结果的排序,就是利用上述方法得到的。

表 2 故障诊断结果的排序

模式代码	M X	M 8	M 3	M 5	M 6	M 7	M 2	M 9	M 4	M 1	M 0
D_j	00	0.24	0.34	0.34	0.34	0.39	0.54	0.66	0.73	0.79	1.00

Kohonen 网络的排序结果

M 0 * * * M 1 * * M 4 * * M 9 * * M 2 * * M 7 * M 6 M 5 M 3 * * * M 8 * * * * M X

5 样本群中代表性样本的提取

Kohonen 网络还有一个特点,即位于输出平面中心附近(例如图 1 的样本M 6)的样本可以作为该样本群的代表性样本。如果记样本 j 与样本群中其他所有样本的相似度的平均值为该样本的平均相似度:

$$S_j = \frac{\sum_{k=1, k \neq j}^p S_{jk}}{p} \tag{10}$$

式中: p 为样本总数, S_{jk} 为样本 j 与样本 k 之间的相似度。则位于网络输出平面中心附近的一些样本也就是 S_j 值为最大的一些样本。

Kohonen 网络的这一性质可用于样本群中代表性样本的提取。作者在文献[5]中曾提出利用发动机的实际故障样本建立经验故障方程的概念。如果已知有多个样本,将存在一个代表性样

本。利用 Kohonen 网络提取代表性样本的优点是不需要建立专门的数学模型以及特别编制程序,并且十分直观。文献[4]中给出了JT9D 发动机与放气活门不能关闭或压气机引气有关的故障样本和小偏差系数。对于这些样本用 Kohonen 网络训练的结果示于图 3。可见B7 与C6 两个样本可以作为代表性样本,来代表整个样本群。图 3 的结果与按(10)式的计算结果基本一致,后者见表 3(表中只给出相似度较大的部分结果)。

此外,由图中还可以看到一个很有意思的事实,即B 字头与C 字头的两类样本在图中分别集聚在一起而不相掺混。表明这两类样本虽然都代表同一类故障,但是它们之间还是存在一定的特性差别。这是因为它们的来源确实不同。以极其简单而直观的方式揭示样本群的特征是 Kohonen 网络的一个突出优点。顺便指出,如果单独对这两类样本群的每一类进行处理,则B 字头样本

群的代表性样本将是B4,而C字头的将是C6。




图 3 JT9D 发动机放气故障样本群代表性样本的提取

表 3 JT9D 发动机放气故障样本群中各样本的平均相似度 (部分)

样本代码	B7	C6	B2	B3	C2	B4	C8	B1	C3	B8	B5
平均相似度	0.921	0.917	0.914	0.914	0.912	0.911	0.908	0.907	0.896	0.893	0.875

参 考 文 献

1 范作民 利用BP 网络进行发动机故障诊断的研究[J]. 中国民
航学院学报, 1996, (3): 1- 9

2 张立明编著. 人工神经网络的模型及其应用[M]. 复旦大学出
版社, 1993

3 范作民, 孙春林著. 航空发动机状态诊断[M]. 天津科技翻译
出版公司, 1996

4 John E. Hehtel, Performace Monitoring of Gas Turbine with
Inflight Data[R]. Flight Operations Engineering Report, No.
29, Appendix C, Pratt & Whitney A ircraft, 1976

5 范作民, 孙春林, 林兆福, 高海川. 发动机经验故障方程的建立
与应用[J]. 航空动力学报, 1991, 6(2): 121- 125

(责任编辑 王震华)

Application of Kohonen Network to Aeroengine Fault Diagnosis

Fan Zuomin, BaiJie, Yan Guohua

(Department of Aeronautical Mechanical and Electrical Engineering,
Civil Aviation Institute of China 300300, Tianjin)

Abstract Kohonen Network (Self-organizing Mapping Model) is applied to aeroengine fault diagnosis. The technique of sequencing diagnostic results and extracting typical samples from sample group is presented. Some examples of application of Kohonen Network to JT9D jet engine fault diagnosis are given. It is shown that Kohonen network is simple to compile program and easy to use, can provide correct diagnostic results for the abnormal samples. Especially it can reveal the statistical characteristics of samples clearly and directly. The method of extracting typical samples from sample group is useful for deriving the empirical engine fault equation.

Key Words: neural network; aeroengine; fault diagnosis; pattern recognition