

文章编号: 1000-8055(2002)05-0533-05

基于自组织拓扑映射图的 发动机故障诊断研究

朱家元¹, 邓振挺², 张恒喜¹, 屈裕安¹

(1 空军工程大学 工程学院, 陕西 西安 710038;

2 空军驻成都地区军事代表局, 四川 成都 610041)

摘要: 根据 SOM 自组织网络的高维数据矢量量化、快速聚类、信息融合和拓扑映射等特征, 建立了发动机故障诊断可视拓扑映射图模型, 给出了映射模式误差测度和拓扑误差测度, 并通过拓扑映射图对发动机故障进行诊断, 获得了很好的效果。同时, 进一步通过建立的故障模式的测量参数灰度图, 可以清晰地观察到故障模式矢量特征、测量参数相关性特征、参数变化趋势, 并可进行更深层次故障机理分析。

关键词: 神经网络; 自组织拓扑映射图; 航空发动机; 故障诊断

中图分类号: TP183; TP277

文献标识码: A

Aeroengine Fault Diagnosis Based on Self-Organizing Topology Maps

ZHU Jia-yuan¹, DENG Zhen-ting², ZHANG Heng-xi¹, QU Yu-an¹

(1 Air Force Engineering University, Xi'an 71038, China;

2 Department of Air Force Military Acquisition in Chengdu, Chengdu 610041, China)

Abstract: This paper proposes a visualized aeroengine fault diagnosis system mode based on self-organizing topology map which combines vector quantization, fast clustering, information fuse and topology preservation, estimation of topographic error and quantization error is also given. And then this method is applied to aeroengine gas path fault diagnosis. The results show that this diagnosis mode is effective and rational. Furthermore, the paper has set up component visualized gray plane in which characteristics of fault vector, correlation of measured parameters and tendency of components can be observed easily, and also we can analyze inherence of faults by this approach.

Key words: neural network; self-organizing topology map; aeroengine; fault diagnosis

1 前言

近年来, 发动机状态检测和故障诊断技术发展迅速。目前应用于航空发动机的故障诊断方法很多, 如基于故障方程的诊断方法, 基于知识推理

的专家系统、模糊诊断、小波分析、机器学习等, 这些方法的运用推动了故障监控与诊断能力的提高。

人工神经网络以其强大的并行处理机制、任意函数的逼近能力、学习能力, 以及自组织和自适应

收稿日期: 2001- 11- 14; 修订日期: 2002- 01- 28

作者简介: 朱家元(1974-), 男, 湖南东安人, 空军工程大学工程学院博士生, 主要从事装备发展规划与管理、智能信息决策与控制研究

应能力等在建模、决策、预测、控制和故障诊断等领域得到了广泛的应用。其中,研究较多的是BP网络。但是BP网络收敛速度慢而且易陷入局部极小值,特别是BP网络通常只能给出一个解,受训练样本病态影响较大。而SOM (Self-Organizing Map)神经网络具有很好的矢量量化功能、快速聚类能力和信息融合能力,特别是能够把高维数据拓扑保留映射到二维空间,形成拓扑映射图^[3]。在映射图中,特征相似的矢量靠得比较近,数据的映射点(即模式矢量)具有类样本代表性。同时,映射图易于可视化,通过直观就可以观察到整个数据区域大体的分布情况和样本特征,比较适合于参数多、特征复杂的航空发动机故障诊断。因此,本文根据SOM网络原理,运用可视化方法建立发动机故障诊断拓扑映射图模型进行故障诊断。

2 SOM 自组织神经网络

2.1 SOM 网络原理

SOM网络由输入层和输出层两层组成。如果输入 n 维样本用矢量 x^p 表示, $p=1,2,\dots,N$,共有 N 个样本,每个 n 维样本的分量 x_i^p 与输入层的第 i 个神经元相联, x_i^p 与输出层第 j 个神经元之间的权设为 μ_{ij} ,输出为由 n_1 个权矢量构建的二维空间映射平面。输入样本矢量 x^p 与权矢量 m_j ($j=1,2,\dots,n_1$)匹配的程度,用欧氏距离 d 表示:

$$d(x^p, m_j) = \|x^p - m_j\| \quad (1)$$

其中:

$$x^p = (x_1^p, x_2^p, \dots, x_n^p)^T$$

$$m_j = (\mu_{1j}, \mu_{2j}, \dots, \mu_{nj})^T$$

如果在输出层中有一个神经元(即模式矢量)与 x^p 匹配最好,记为 c ,则:

$$d(x^p, m_c) = \min_j d(x^p, m_j) \quad (2)$$

其中, m_c 所对应的输出为:

$$y_c = \min_j y_j$$

然后对权 m_j 进行修正。

$$m_j(t+1) = m_j(t) + \alpha(t) h_{bj}(t) [x - m_j(t)] \quad (3)$$

其中: $\alpha(t)$ 为学习率; $h_{bj}(t)$ 为邻域函数,采用高斯函数。

$$h_{bj}(t) = \exp \left[- \frac{\|r_b - r_j\|^2}{2\sigma^2(t)} \right] \quad (4)$$

其中: r_b 和 r_j 分别是输出单元 b 和 j 在映射平面的位置, σ 反映了邻域的范围。

修正后的权矢量即为输入样本矢量对应的模式矢量,为了检验网络训练精度,采用输入样本矢

量与映射模式矢量的平均量化误差作为测度。映射模式误差测度为:

$$\epsilon = \frac{1}{N} \sum_i \|X_i - M_c\| \quad (5)$$

其中: N 是输入样本数, M_c 是各自对应的模式矢量。

拓扑映射是SOM网络的显著特征,但拓扑误差的计算比较复杂。Villmann^[4]采用基于Voronoi矢量的拓扑函数作为拓扑误差测度,具有较好的精度。但是在样本映射稀疏和密集区域的计算极不灵活,而且对样本要求苛刻。本文通过权衡计算精度、速度和样本广泛适用性,在这里采用以下方法计算拓扑误差。

假设:设输入空间 $M \subset R^n$,对于 N 个样本, $X_i \in M$ ($i=1,2,\dots,N$)。在空间 M 中,通过线性划分,具有最近欧氏距离的两个样本矢量是邻接的(即邻接样本矢量);在SOM网络中,样本矢量 $X_i \in M$ 对应的两个最近权矢量 w_i 和 w_j (设样本矢量 X_i 映射的最近权矢量为 w_i ,距它第二最近的模式矢量权值为 w_j)也包含在空间 M 中。根据假设,在映射图中,而一些样本矢量值在 X_i 与 w_j 之间的样本映射到 w_i ,同时其它样本矢量的映射到 w_j 。如果邻接的样本矢量的映射权矢量对应的神经元 n_i 与 n_j 在拓扑映射图是邻接的,则局部映射邻接,即拓扑保留,如果不邻接,则不具有局部连续,即出现拓扑误差。拓扑误差测度计算公式如下:

$$\epsilon = \frac{1}{N} \sum_{k=1}^N u(X_k) \quad (6)$$

当:

$$u(X_k) = \begin{cases} 1 & \text{邻接样本矢量的映射矢量不邻接} \\ 0 & \text{邻接样本矢量的映射矢量邻接} \end{cases}$$

2.2 自组织拓扑映射图可视化

SOM网络能把多类传感器获得的高维数据拓扑映射到二维空间,根据这个特点,可将网络的输出信息用可视化的方式显示出来。方法是将由输出的权值矩阵形成的拓扑映射图显示成灰度图象,图中每个结点(即映射模式矢量点)由灰度值表示,灰度值对应于权值空间中结点与其近邻结点间的距离。结点像素亮度的降低,表示距离增大。通过这种表示,在网络输出层中,由暗色区域隔开的区域代表一个不同特征的类。对于完全可分的输入信息,其特征映射将被分到不同类型的区域。如果输入数据的分类信息是已知的,则可以

对输出结点附以特定的类别标记,从而可以对其它输入信息进行正确的归类识别。而且对于映射图中的样本矢量可以进一步分析参数特征。因此,通过可视化拓扑映射图可以直接观察到高维数据的特征,非常有利于特征复杂的航空发动机的状态识别、故障诊断及各参数相关性和趋势分析。

3 发动机故障诊断拓扑映射图分析模型

采用 SOM 网络进行故障诊断,网络的输入既可以是多维故障征兆矢量,也可以是发动机测量参数小偏差值,这需要根据不同的诊断方式和诊断对象决定。在这里采用模块方式建立故障诊断拓扑映射图模型。本文将整个故障诊断分析模型分为五个序列链接的独立模块。采用独立模块后,既可以顺序分析,又可以根据需要跳过一些模块,提高故障诊断的效率。第一个模块是参数初始化模块,为了减少输入矢量中不同参数绝对数值大小对网络计算的影响,需对各参数维进行归一化预处理,同时初始化网络权值;第二个模块是二维映射拓扑模块,即设定输出层网格的形状和规模。不同的设定网格大小对拓扑映射图特征和网络训练精度影响较大,通常根据输入矢量数和参数维数量进行设定;第三个模块是学习模块,通过训练模块对故障样本进行特征识别,获得形成拓扑映射图的权值矩阵;第四个模块是故障特征可视化分析模块,包括映射图可视化和参数关联性

分析可视化。第五个模块是故障诊断模块。输入新的故障到网络,通过它的映射点与故障模式矢量的距离进行故障识别,故障识别测度由它的参数矢量与最近模式矢量的欧氏距离决定。

4 基于可视拓扑映射图的发动机故障诊断

在这里以气路故障诊断为例。本文选取表征测量参数不同变化趋势的发动机稳态测量参数值与基值得偏差作为网络的输入矢量,取相对应的发动机故障模式为网络拓扑映射图中的映射模式矢量。输入矢量共 9 个,为某型涡扇发动机机载测量参数值与其基值的偏差。包括: 低压和高压换算转速偏差 (ΔN_{1R}) 和 (ΔN_{2R})、风扇内涵出口总压偏差 (ΔP_{23})、风扇外涵出口静压偏差 (ΔP_{s13})、压气机出口总压偏差 (ΔP_{31})、涡轮排气压力偏差 (ΔP_{65})、风扇外涵出口总温偏差 (ΔT_{13})、涡轮排气温度偏差 (ΔT_{65})、燃油总管压力偏差 (ΔP_t)。根据输入矢量的变化,可能产生不同故障模式,这里取表征发动机气路部件性能变化的主要 11 个参数,包括: 风扇和压气机效率下降量 ($\Delta \eta$) 和 ($\Delta \eta$)、燃烧室效率下降量 ($\Delta \eta$)、高、低压涡轮效率下降量 ($\Delta \eta_{it}$) 和 ($\Delta \eta_{it}$); 风扇和压气机流通能力的变化量 (ΔW_{R}) 和 (ΔW_{CR})、高压和低压涡轮流通能力的变化量 (ΔW_{ht}) 和 (ΔW_{lt}); 外涵道压力损失的变化量 ($\Delta \sigma_{13}$) 和燃油系统流量变化量 (ΔW_{fb})。

通常,在实验数据中很难包括所有的故障模

表 1 发动机故障变化量为 3% 时的输入矢量样本 ($N_2 = \text{Const}$)

Table 1 Training set for aeroengine fault diagnosis in which fault pattern varieties is 3% ($N_2 = \text{Const}$)

	ΔN_{1R}	ΔN_{2R}	ΔP_{23}	ΔP_{s13}	ΔP_{31}	ΔP_{65}	ΔT_{13}	ΔT_{65}	ΔP_t
$\Delta \eta$	- 0.3043	0	- 0.1774	- 0.2237	- 0.2383	- 0.1877	- 0.0060	0.0009	- 0.0951
$\Delta \eta_c$	0.0017	0	0.0926	0.1234	0.0360	0.0926	0.0900	0.1586	0.1620
$\Delta \eta_b$	0.0360	0	0.0489	0.0617	0.0540	0.0514	0.0514	0.0583	0.1414
$\Delta \eta_{it}$	0.2571	0	0.3137	0.3703	0.3746	0.3189	0.3120	0.3411	0.4114
$\Delta \eta_{lt}$	- 0.1431	0	- 0.0463	- 0.0926	0.0017	- 0.0463	- 0.0909	0.0720	0.0283
ΔW_{R}	0.1774	0	- 0.1543	- 0.1929	- 0.2126	- 0.1646	0.0034	0	- 0.0849
ΔW_{CR}	- 0.3017	0	- 0.2417	- 0.2649	- 0.4371	- 0.2623	- 0.2357	- 0.1294	- 0.2263
ΔW_{ht}	0.1731	0	0.1749	0.2031	- 0.3497	0.1800	0.1783	0.1697	0.2109
ΔW_{lt}	- 0.5186	0	- 0.4191	- 0.5606	- 0.4363	- 0.4269	- 0.4766	- 0.1980	- 0.3497
$\Delta \sigma_{13}$	- 0.0626	0	0.2443	0.1980	0.0694	- 0.0309	0.1363	0.0377	0.0129
ΔW_{fb}	- 0.1654	- 0.4886	- 0.4886	- 0.1363	- 0.1491	- 0.2374	- 0.1466	- 0.0763	- 0.1286

式和其严重程度,而根据发动机数学模型,可以建立发动机故障模拟器,模拟不同状态和调节规律下所有诊断故障。因此,本文通过发动机故障模拟器来获取故障样本。以风扇效率下降的故障模式为例,考虑发动机气路部件故障形成的逐渐性、故障模拟器的计算误差、测量系统的误差,选取地面不加力状态、 $N_2 = 100\%$ 、风扇效率下降 3%,发动机模型计算出的测量参数值与基值得偏差值作为风扇效率故障模式的样本输入矢量,同理,可以获得其它 10 个故障模式的样本输入矢量,见表 1。

故障诊断过程如下:

(1) 网络学习的初始邻域设定为整个映射网格平面的 $1/2$, 拓扑邻域为矩形, 初始学习率为 0.3, 学习率随网络迭代时间动态下降。

(2) 对样本输入矢量进行归一化预处理, 同时初始化网络权值。

(3) 建立拓扑映射图网格, 设定输出层网格数为 12×12 。

(4) 采用 SOM 网络进行学习, 通过学习获得故障模式拓扑映照图, 如图 1 所示, 在图中每一个故障模式对应相应的位置, 当新的测量参数偏差矢量输入时, 通过映射的位置即可判断故障模式 (右边为映射模式矢量之间的距离灰度表)。

(5) 分别输入 11 个新故障到拓扑映射图中进行故障诊断, 新故障样本是发动机以地面不加力状态、 $N_2 = 100\%$ 、11 个故障模式的故障变化量为 3.5% 的测量参数偏差矢量作为诊断测试输入矢量, 故障诊断图如图 2。




图 1 发动机故障模式拓扑映射图

Fig 1 Aeroengine fault pattern topology map

诊断分析:

(1) SOM 网络故障样本训练稳定后, 样本矢量与映射的模式矢量平均量化误差为 0.002; 拓

扑误差为 0, 即映射图具有完全拓扑保留性。

(2) 从图 2 中, 可以清晰的观察到, 11 个不同的故障模式映射到 11 个不同的区域, 说明 SOM 网络对于参数多、特征复杂的发动机故障模式具有良好的分类识别能力, 即在 11 个故障模式中的任一个故障模式变化量为 3.5% 程度时, 根据测得的测量参数偏差矢量映射到拓扑映射图中的位置, 就可以判定是哪一个气路部件发生故障。故障判断标准: 由新故障的测量参数偏差矢量在拓扑映射图中对应的映射矢量与各个故障模式映射矢量之间的距离决定, 距离之最近的故障模式映射矢量即为所属故障模式 (距离灰度图见图 1 右)。

(3) 从图 2 中可以看到, 11 个新故障都正确识别。




图 2 发动机故障诊断拓扑映射图

Fig 2 Aeroengine fault diagnosis topology map

我们继续对算例发动机状态的故障变化量 2.5%, 4% 和 4.5% 的情况进行了故障诊断, 前两个状态诊断率为 100%, 而后者对个别故障模式诊断率稍低, 说明以一种状态作为 SOM 网络学习样本进行故障诊断的范围具有区间性, 但这并不影响 SOM 网络自组织拓扑映射图模型的故障诊断能力。我们通过建立了不同发动机状态的分层 SOM 网络自组织拓扑映射图模型, 成功的解决了以上问题。

下面进一步对故障模式的参数特征进行分析。对于每种故障模式的测量参数偏差值按映射图上的故障模式映射位置显示成单测量参数灰度图, 即测量参数偏差值由灰度值表示, 按颜色的亮色到暗色, 数值逐渐降低。通过单参数灰度图, 我们可以观察到所有故障模式的测量参数偏差的变化趋势, 变化趋势一致的测量参数具有较强的相关性。其中, 图 3 与图 4 的测量参数偏差矢量在大




图 3 风扇内涵出口总压偏差
Fig 3 Total pressure bias of gas generator gray plane




图 6 燃油总管压力偏差
Fig 6 Fuel pipe pressure bias gray plane

部分故障模式中具有强关联; 图 5 与图 6 的测量参数偏差矢量在局部故障模式中具有较强的相关性。

5 结束语

本文根据 SOM 自组织网络原理, 建立了发动机故障诊断可视拓扑映射图模型, 并通过拓扑映射图对发动机气路故障进行诊断, 获得了很好的效果。同时, 进一步建立了故障模式的测量参数偏差灰度图, 通过图, 可以清晰地观察到模式矢量特征、测量参数相关性特征、测量参数偏差变化趋势, 而且据此, 可以进行更深层次分析故障机理。

参考文献:

[1] 孙斌, 张津 BPN 在涡扇发动机气路故障诊断中的应用[J]. 航空动力学报, 1998, 13(1): 323- 326
[2] 张立明 人工神经网络的模型及其应用[M]. 上海: 上海复旦大学出版社, 1994
[3] Vesanto J. SOM -Based Data Visualization Methods[J]. Intelligence Data Anal, 1999, 3(2): 111- 126
[4] Vilhmann Th, Der R, Martinetz Th. A New Quantitative Measure of Topology Preservation in Kohonen's Feature Maps [A]. The IEEE International Conference on Neural Networks [C]. Orlando, Florida, U SA, 1994: 645- 648




图 4 风扇外涵出口静压偏差
Fig 4 Pressure of by-pass air duct gray plane




图 5 涡轮排气温度偏差
Fig 5 Exhaust temperature of turbine gray plane

(责任编辑 吴一黄)