

应用自组织网络识别火箭发动机泄漏故障^{*}

于达仁, 王建波, 王广雄

(哈尔滨工业大学 能源科学与工程学院, 黑龙江 哈尔滨 150001)

摘要: 以一个典型的泵压式液体火箭发动机(LRE)为对象, 针对发动机的几种泄漏故障, 先用主成分分析法对泄漏故障的原始样本进行降维, 然后利用降维的样本, 用自组织网络对泄漏故障进行识别, 仿真结果表明, 这一方法能对泄漏故障进行很好的识别。

关键词: 液体推进剂火箭发动机, 泄漏故障; 故障诊断; 人工神经元网络

中图分类号: V430 **文献标识码:** A **文章编号:** 1001-4055(2001)01-0047-03

Leak fault identification of rocket engine using self-organizing feature map network

YU Da-ren, WANG Jian-bo, WANG Guang-xiong

(School of Energy Science and Engineering, Harbin Inst. of Technology, Harbin 150001, China)

Abstract: Some kinds of leak fault were analyzed in liquid rocket engine. The method of principle component analysis was used to reduce the dimension of the original samples, which can represent the leak. And then input the low-dimension samples, the self-organizing feature map network can identify the leak fault. The simulating results show that the approach is feasible and effective.

Key words: Liquid propellant rocket engine; Leak fault; Fault diagnosis; Artificial neural network

1 引言

液体火箭发动机的泄漏故障由于其危害性大, 且容易发生, 越来越受到重视。90年代以来, 在泄漏的自动检测、检测系统和实时仿真方面, 均进行了研究^[1~3]。人工神经元网络具有高度非线性动力学特性, 并具有并行处理能力和用硬件实现的可能性。近年来, 人工神经元的技术在液体火箭发动机健康监控领域取得一定的进展^[4~8]。本文利用自组织网络来识别液体火箭发动机在主级工况下发生的泄漏故障。具体做法: 先对泄漏故障模式进行主成分分析(Principle Component Analysis, PCA), 得到新的泄漏故障模式样本群, 然后以这个样本群作为自组织网络的输入向量, 从而来识别泄漏故障。

2 火箭发动机泄漏故障的识别

2.1 问题的提出

进行液体火箭发动机泄漏故障的识别, 必须选取合适的监测参数, 构成泄漏故障模式特征。由于各特征由观测得到, 其中必然含有噪声的干扰, 因此采用较多的特征量, 一则会因被考虑的因素过多而提高识别精度, 另一方面又会因噪声干扰的增强而损失识别精度。为此, 我们采用主成分分析法先对泄漏故障的模式特征进行优化, 重构泄漏故障的模式特征, 然后利用自组织特征映射网络, 对泄漏故障进行自动识别。

2.2 主成分分析基本原理

主成分分析法可以在保证数据信息损失最小的前提下, 经线性变换和舍弃一小部分信息, 以少数新的综合变量取代原始采用的多维变量。同时考虑各参数分量之间的相关性, 进而提取输入数据中参数变化的同线性。这种同线性蕴含了输入数据的故障累积和随机波动等信息。主成分分析法以正交变换对输入空间进行压缩, 可用于故障特征的提取。

* 收稿日期: 2000-03-27; 修订日期: 2000-05-08; 基金项目: 哈尔滨工业大学校管航天基金资助项目 (960241049)。

作者简介: 于达仁 (1966—), 男, 博士, 教授, 研究领域为动力系统建模、控制和故障诊断。

记原变量 x_1, x_2, \dots, x_p , 主成分分析后得到的新变量 y_1, y_2, \dots, y_m ($m \leq p$), 称 y_1, y_2, \dots, y_m 张成的空间为 m 维主超平面。用原样本群点 N_1 在主超平面上的投影近似地表达原样本群点。简洁地说, 在 m 维主超平面上, 第一主分量 y_1 一定对应于数据变异最大的方向, 即原样本群点在第一主轴上投影的散差为最大

$$V(y_1) = \max\{V(y_i), i=1, \dots, m\}$$

对于第二分量 y_2 以及 y_3, y_4, \dots, y_m , 依次有

$$V(y_1) \geq V(y_2) \geq \dots \geq V(y_m)$$

因此可以认为, y_1 是携带原数据信息最多的一维变量, m 为主超平面保留原数据信息量最大空间的维数。

2.3 自组织网络结构

自组织网络结构一般有两层组成, 其结构见图 1。第一层为输入层次, 它接收输入样本; 输入样本(模式)为 x_i ($i=1, 2, \dots, n$); 第二层为竞争层, 它对输入样本进行分类, 网络的输出 o_j ($j=1, \dots, m$) 取值 {0, 1}, 当第 j 个输出神经元为 1 时, 表示此时样本属于第 j 类; 当第 j 个输出神经元为 0 时, 表示此时样本不属于第 j 类。这两层次的神经元之间进行全互连连接, 权连接包含了 $n \times m$ 个, 即 $W = [W_1 \ W_2 \ \dots \ W_m]^T$ 表示第 i 类的聚类中心。

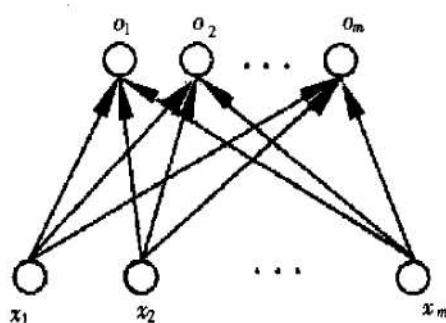


Fig. 1 Basic structure of self-organizing network

针对上述结构, Kohonen 提供了自组织网络的学习算法^[6]。该算法通过寻找最优参数矢量集合来对输入模式集合进行分类。输出层的各单元对输入模式响应的权利的竞争是通过“侧抑制”来实现的。Kohonen 算法定义了胜者神经元的邻域, 同时将邻域中的神经元权矢量向输入样本靠拢。具体的学习算法如下:

(1) 初始化权值, 输入以学习样本矢量 x , 计算它与竞争层中所有神经元的距离

$$d_i = \sum_{j=1}^n (x_j(t) - W_{ij}(t))^2 \quad (1)$$

(2) 选取 d_i 最小的神经元为胜者神经元, 其权值矢量系数 W_{ij} 按下面修正

$$\begin{aligned} W_{ij}(t+1) &= W_{ij}(t) + a(t) \times h_{ii'}(\sigma(t)) \\ &\quad \times (x_i(t) - W_{ij}(t)) \end{aligned} \quad (2)$$

其中, $h_{ii'}$ 定义了一个胜者神经元的高斯邻域范围, $\sigma(t)$ 为 t 时刻高斯函数的方差。

$$h_{ii'} = \exp \left[-\frac{(i-i')^2}{2\sigma^2(t)} \right] \quad (3)$$

根据这一特性, 把网络的输出对应于火箭发动机各种泄漏故障类型, 那个网络节点输出为 1, 即表明发生了所对应类型的泄漏故障。

2.4 泄漏故障自动识别算法

考虑到现有发动机监控系统所采用监测参数, 选择的 5 个可测参数为发动机的氧化剂流量 n_{O_2} , 燃料流量 n_{H_2} , 涡轮泵的转速 n , 燃气发生器压力 p_b 和推力室压力 p_e 。为此构造了 PCA+ 自组织网络的泄漏故障自动识别算法如下:

(1) 获得泄漏故障的模式 $x = [n_{\text{O}_2}, n_{\text{H}_2}, n, p_b, p_e]$;

(2) PCA 降维处理: 计算数据表 $(x_i)_{n \times p}$ 的自相关矩阵 R 。由 R 可求出 p 个正实特征根为

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p > 0 \quad (4)$$

称 $\lambda_i / \sum_{i=1}^p \lambda_i$ 为 x 中第 i 个分量 x_i 对整体方差的贡献率。贡献率越大, 该分量越重要。一般从 $\lambda_1, \lambda_2, \dots, \lambda_p$ 中选取 m 个 λ ($m < p$), 使下式成立。

$$\sum_{i=1}^m \lambda_i / \sum_{i=1}^p \lambda_i > 85\% \quad (5)$$

上式表示 x 中前 m 个分量的方差已占整体方差的 85% 以上。所对应的特征矢量 u_1, u_2, \dots, u_m 称为主轴, 它们标准正交。

第 h 主成分为

$$y_h = \sum_{j=1}^p u_{hj} x_j, h = 1, 2, \dots, m \quad (6)$$

(3) 自组织网络模式聚类: 以各主成分 y_h 作为网络的输入, 进行泄漏故障的识别。

3 仿真分析

泄漏故障发生的不同位置引起的不同组件参数的改变, 在仿真时, 假设泄漏故障是突变故障, 对于管

道泄漏, 泄漏量用该推进剂组元的总流量的一定比值给出; 对于燃气腔泄漏, 泄漏量用燃气腔压力的一定比值给出^[3]。

采用 401×5 个样本数据, 将待识别泄漏故障模式 x 经过 PCA 变换, 得到低维空间的泄漏故障效应, 构成新的样本群, 把再新的样本群作为神经网络的输入, 就可以识别故障。以燃烧室前的氧化剂管路为例, 第 1 主成分的贡献率为 77.17%, 第 2 主成分的贡献率为 15.25%, 则两者的贡献率总和大于 85%, 因此可以抽取第 1 主成分和第 2 主成分作为自组织特征映射网络的输入矢量。这样泄漏故障特征被降到二维, 那么故障模式的可分离性在图上可以清晰地表达出来。

选取 5 种泄漏工况来训练自组织网络, 输入层为 2 个神经元, 输入矢量为主成分变换后的第 1 主成分和第 2 主成分; 输出层采用 5 个神经元, 每个神经元对应不同的工况; 在迭代学习了 500 步以后, 网络训练的结果见图 2。图中“○”表示各种不同泄漏故障的聚类中心。

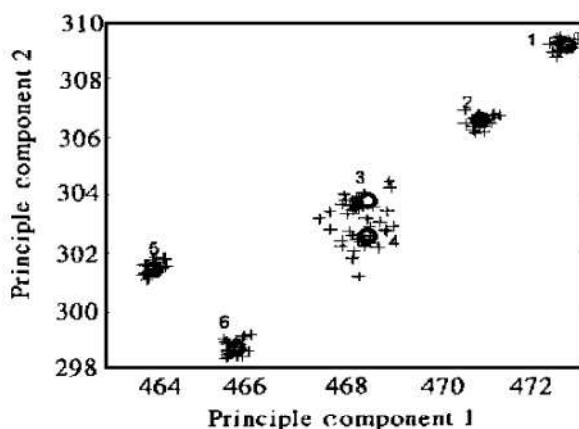


Fig. 2 Training result of the self organizing network

- 1) Normal
- 2) Oxidizer leak before main chamber
- 3) Oxidizer leak after pump
- 4) Gas leak of main chamber
- 5) Fuel leak before gas generator
- 6) Fuel leak before main chamber

由图中也可以看出, 采用自组织网络可以对发动机的泄漏故障模式进行很好的聚类。在仿真中, 发现不经过主成分变换, 直接进行模式聚类, 由于考虑因素太多和噪声的干扰, 不能很好地识别出燃烧室的燃

气泄漏, 误判断为燃烧室前氧化剂管路的泄漏; 而采用 PCA 变换后就能够识别此故障, 因此在进行泄漏故障诊断之前, 进行主成分变换来精简特征是很有必要的。

再选取一些样本进行对网络验证, 输出层的那个神经元输出为 1, 这个样本就对应着这个神经元所描述的泄漏故障。

4 结 论

自组织网络可以识别液体火箭发动机的泄漏故障, 仿真表明, 这一方法式行之有效的。应用主成分分析法可以对泄漏故障的模式进行降维, 有利于自组织网络的学习样本简化, 可以提高学习速度, 还可以进行特征简化, 有利于故障的分离。

参考文献:

- [1] Gary W, Hunter D B, Makel E D, et al. A hydrogen leak detection system for aerospace and commercial applications [R]. AIAA 95-2645.
- [2] Makel D B, Jansa E D, Bickmore T W. Automated propellant leak detection [R]. AIAA 93-2590.
- [3] 王建波, 于达仁, 王广雄. 液体火箭发动机泄漏故障实时仿真 [J]. 推进技术, 1999, 20(5).
- [4] Wu Jianjun, Zhang Yulin, Chen Qizhi, et al. Fault detection and diagnosis based on neural networks for liquid rocket propulsion system [R]. AIAA 95-2350.
- [5] 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(I) 非线性辨识技术 [J]. 推进技术, 1999, 20(1).
- [6] Kohonen T. An introduction to neural computing [J]. Neural Networks, 1998 (1): 3~ 16.
- [7] 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(②) 模式识别技术 [J]. 推进技术, 1999, 20(2).
- [8] 杨尔辅, 张振鹏, 刘国球, 等. 应用 BP-ART 混合神经网络的推进系统状态监控实时系统 [J]. 推进技术, 1999, 20(6).

(编辑: 盛汉泉)