

文章编号 :1001 - 2486(2005)06 - 0093 - 04

# 涡轮泵故障检测的频段能量比 SOM 算法<sup>\*</sup>

胡茑庆, 邱忠, 谢光军, 胡雷

(国防科技大学 机电工程与自动化学院, 湖南 长沙 410073)

**摘要:**为了解决缺少故障样本情况下的涡轮泵健康状态判别问题, 分析了涡轮泵振动信号的频谱, 提取了频段能量比作为其故障检测特征, 并讨论了自组织映射的竞争学习原理及聚类结果的 U-矩阵表示, 提出了一种基于频段能量比的自组织映射故障检测算法, 并实现了该算法最佳匹配神经元的选择和权重向量的自适应更新。通过某型液体火箭发动机历史试车数据的验证, 结果表明, 健康涡轮泵数据利用该算法聚类时仅存在一个类别, 相邻神经元距离小于 0.1; 反之, 故障涡轮泵数据利用该算法聚类时明显存在两个或多个类别, 且相邻神经元的最大距离大于 0.1。因此, 基于频段能量比的 SOM 算法能有效地判别涡轮泵的健康状况。

**关键词:**液体火箭发动机; 涡轮泵; 故障检测; 自组织映射; 频段能量比中图分类号: V434<sup>+</sup>.21 文献标识码: A

## Frequency-band-energy-ratio-based SOM Algorithm for Turbopump Fault Detection

HU Niao-qing, QIU Zhong, XIE Guang-jun, HU Lei

(College of Mechatronics Engineering and Automation, National Univ. of Defense Technology, Changsha 410073, China)

**Abstract** In order to detect the turbopump fault short of fault samples, the spectrums of turbopump vibration signals were analyzed, and the frequency band energy ratio was selected as the fault feature of those signals. After SOM competitive learning theory and U matrix description of clustering results were discussed, the frequency-band-energy-ratio-based SOM algorithm for turbopump fault detection is presented, and the selection of the best matching unit (BMU) and the adaptive upgrade of their weight vectors are also realized in this algorithm. With a liquid rocket engine (LRE) historical test data, this algorithm is validated. These results show that there is only one class when the algorithm is used to healthy turbopump vibration data, and the distance between the neighboring neuron is less than 0.1; while there are two or more classes when the algorithm is used for faulty turbopump vibration data, and the distance between the neighboring neuron is greater than 0.1. Therefore the algorithm can effectively detect the turbopump fault.

**Key words:** liquid rocket engine; turbopump; fault detection; self-organizing mapping; frequency band energy ratio

涡轮泵是泵压式液体火箭发动机用于输送推进剂的重要组件, 一旦发生故障, 将严重影响发动机的工作, 甚至导致重大事故。由于工作在极端的物理条件下, 具有较高的故障发生率<sup>[1]</sup>, 而振动又是涡轮泵故障的主要原因<sup>[2]</sup>。因此, 针对涡轮泵的振动信号, 国内外研究并发展了相应的健康监控算法及系统, 如谢光军等研究了自适应阈值的涡轮泵实时故障检测算法<sup>[3~5]</sup>, 并针对我国某型液体火箭发动机构建了涡轮泵故障检测系统<sup>[6,7]</sup>, 并通过发动机点火试车考核, 取得了成功。实时故障检测已经在很大程度上提高了发动机的可靠性和安全性, 但为了进一步核对实时故障检测的结果, 杜绝存在安全隐患的涡轮泵交付使用, 需要针对地面试车振动数据进行试验后分析, 以便为液体火箭发动机的不分解交付提供更可靠的依据。

因为某型液体火箭发动机故障样本缺少, 难以利用有监督的算法对其试验数据进行分析。SOM (self-organizing map, 自组织映射) 作为一种无监督竞争学习网络<sup>[8]</sup>, 在数据聚类、知识获取、过程监控等领域得到了广泛的应用。涡轮泵振动信号的频谱可以提供许多有价值的信息<sup>[9]</sup>。但是, 若直接利用

<sup>\*</sup> 收稿日期 2005-07-01

基金项目: 国家 863 高技术研究发展计划资助项目(2005AA722070); 国家自然科学基金资助项目(50375153)

作者简介: 胡茑庆(1967—), 男, 教授, 博士。

SOM 对频谱数据聚类效果并不十分理想。为此,本文首先分析了涡轮泵振动数据的频谱特点,提取了频段能量比作为故障检测的特征,研究了SOM原理和U-矩阵可视化显示,提出了基于频段能量比的SOM故障检测算法。实验结果表明,该算法能有效地检测涡轮泵故障。

## 1 振动信号分析与特征选择

### 1.1 振动信号频谱分析

利用FFT算法对液体火箭发动机30次试车的涡轮泵轴向振动等7路加速度信号进行分析时,发现在健康状况下,涡轮泵频谱非常稳定(见图1),10s处与100s处的频谱中频率分布基本相似;而涡轮泵在发生故障前后,频谱发生较大变化(见图2),10s处(正常)与100s处(故障)的频谱分布存在明显差异。同时由图1的左图和图2的左图可以发现,不同试车台次正常频谱的差别较大。

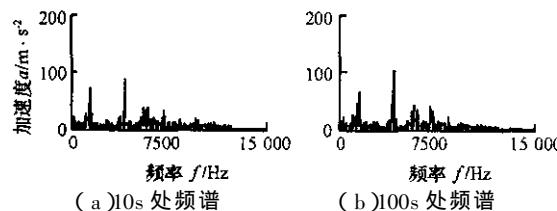


图1 健康涡轮泵的频谱

Fig.1 Spectrums of healthy turbopump

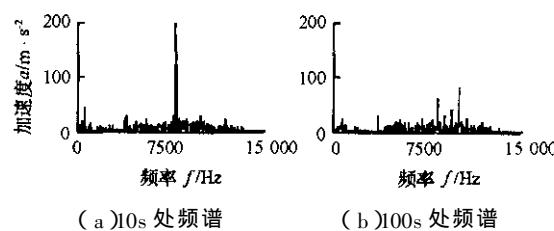


图2 故障涡轮泵的频谱

Fig.2 Spectrums of faulty turbopump

### 1.2 故障特征选择

虽然频谱各频率的分布存在稳定性。但是涡轮泵振动信号存在频带宽,随机噪声比较强的特点,在整个稳态过程中,某个频率分量的幅值还可能出现较大的变化,因此,直接从频谱来进行状态判别很困难。进一步分析发现,涡轮泵处于健康状态时,从进入稳态一直到接近关机,只要转速基本不变,其频率分布特性都基本保持稳定,而且 $6X$ 、 $12X$ 等主频幅值较大。因此,利用转速信号,作了频段能量比分析:

$$\lambda = \frac{\sum_{i=a}^b A_i^2}{\sum_{i=0}^n A_i^2} \quad (1)$$

其中,  $\lambda$  为频段能量比;  $A_i$  为各频率分量幅值;  $a, b$  为频段范围;  $n$  为频率上限。

考虑到维数不是很高,而且要尽量保留原始频谱的信息,所以在做频段能量比的时候,使用的不是转频  $X$  的倍频,而是  $\frac{1}{2}X$ ,即将FFT频谱划分为不同的频段:  $[\frac{n-1}{2}X, \frac{n}{2}X]$ ( $n$  为自然数,  $X$  为转频),计算该频段能量在整个能量中的比值。频段能量比可以大大降低特征向量的维数,而且在一定程度上消除了随机噪声的影响。图3分别为两次试车不同时刻的频段能量比对比分析,图3左图为某次正常试车不同时刻的频段能量比,可见稳定工况下频段能量比基本相似,通过正常试车数据的分析,发现健康的涡轮泵都具有这一特性。图3右图为某次试车涡轮泵发生故障时的频段能量比,可以发现,频段能量比变化较大,而且不同故障的试车数据都如此。可见,频段能量比稳定性可以作为涡轮泵健康状态判别的依据。

## 2 SOM原理与算法实现

### 2.1 SOM原理

SOM是Kohonen于1981年提出的,结构如图4所示,由输入层和输出层(竞争层)组成,输入层和输出层各个神经元之间实现完全相互连接。输出层神经元的数目从几十到几千不等,每个神经元可以用一个  $d$  维权向量  $m = [m_1, \dots, m_d]$  来表示,其中  $d$  等于输入向量的维数。

SOM网络的竞争层神经元对输入模式的响应,最后仅一个神经元成为竞争的胜者,并对那些获胜

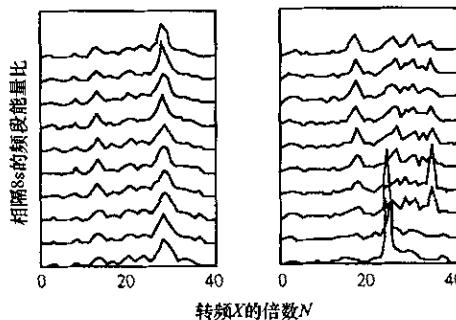


图 3 能量比变化  
Fig.3 Change of energy ratio

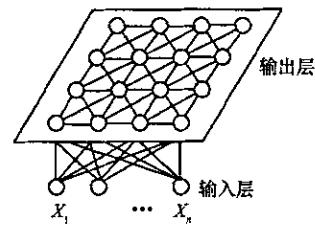


图 4 SOM 网络结构  
Fig.4 The structure of SOM

神经元有关的各权重朝着更有利其竞争的方向调整,即以获胜神经元为圆心,对近邻的神经元表现出兴奋性侧反馈,而对远邻的神经元表现出抑制性侧反馈,通常使用“墨西哥草帽”函数对神经元侧反馈进行计算。应用侧反馈原理,在每个获胜神经元附近形成一个“聚类区”。学习的结果是使竞争层神经元趋于有序,邻近的神经元具有相似的权重向量。

## 2.2 U - 矩阵

神经网络的训练结果并不能直接观察到,而是要借助一定的方法才可以得到可视化的结果,SOM常用的是U-矩阵方法。其基本原理是:对于SOM网络竞争层的每个神经元,都拥有一个二维坐标,分别计算每个神经元与相邻神经元权向量之间的距离,并取这些距离值的平均值或者最大值作为该神经元的第三维坐标,即神经元的高度,在这里使用的是二维显示,所以神经元的高度使用灰度表示。这样就可以得到训练结果的灰度图,也称为认知地图,从灰度图上可以清楚地观察聚类的结果。

## 2.3 频段能量比 SOM 算法实现

将稳态数据分成 $n$ 段进行频段能量比分析,得到不同时刻的频段能量比 $x_i$ :

$$\mathbf{x}_i = [x_i^1, x_i^2, \dots, x_i^m]$$

对整个稳态工况进行处理后,得到 $n$ 个样本,将其作为样本集 $X$ ,提交给SOM网络进行学习。

学习过程可以分为两个阶段:

(1)选择最佳匹配神经元(BMU)

SOM使用迭代训练。在每一次训练中,挑选一个样本 $x$ ,然后使用某种距离函数计算它与SOM所有权向量的距离,其权向量与输入向量距离最小的神经元即为最佳匹配神经元(用 $c$ 表示):

$$\| \mathbf{x} - \mathbf{m}_c \| = \min_i \{ \| \mathbf{x} - \mathbf{m}_i \| \} \quad (2)$$

这里 $\|\cdot\|$ 表示某种距离度量,样本归一化时,一般使用欧氏距离。

(2)权重向量的自适应更新

输入向量 $x$ 被提交给SOM网络后,获胜神经元 $c$ 及其邻近神经元的权重向量向输入向量趋近。在 $x$ 被多次提交后,邻域 $N_{ct}$ 内的神经元将通过学习而拥有彼此相似的权重向量。权重向量 $m$ 更新规则如下:

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) + \alpha(t) h_{ci}(t) [\mathbf{x}(t) - \mathbf{m}_i(t)] \quad (3)$$

这里 $t$ 表示时间, $x(t)$ 表示时刻 $t$ 随机抽取的输入向量, $h_{ci}(t)$ 表示近邻函数, $\alpha(t)$ 表示学习率。

学习完成后,利用训练结果进行U-矩阵可视化分析。

## 3 算法验证

对火箭发动机30次近期试车数据(试车时间为120~500s,氢泵转速约40 000r/min,氧泵约20 000r/min),进行了频段能量比的SOM聚类分析,某次健康涡轮泵的U-矩阵图见图5,仅存在单个类别,所有神经元与相邻神经元权向量距离明显小于0.1(右侧图标为最大距离)。其它正常试车U-矩阵图与之类似。

而某次发生故障的涡轮泵,其U-矩阵图见图6,明显存在分界面且聚成两类,距离大于0.1。另外两次发生故障的试车也是如此。

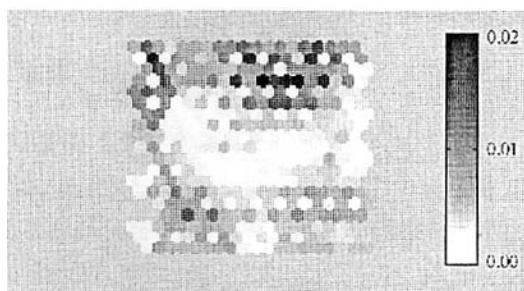


图5 涡轮泵正常的U-矩阵图

Fig.5 U-matrix of healthy turbopump

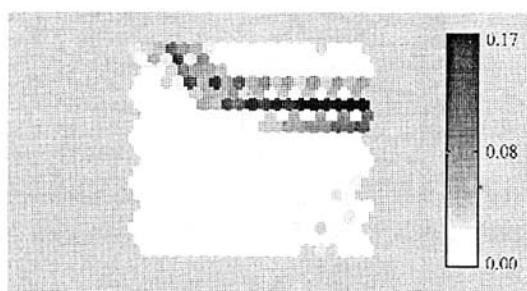


图6 涡轮泵故障的U-矩阵图

Fig.6 U-matrix of faulty turbopump

因此,当U-矩阵图只存在单类且距离小于0.1,就判为健康。而U-矩阵图存在两类(多类),或者最大距离超过0.1,则认为发生故障;该算法对“红线关机”不能发现的某次试车涡轮泵叶片断裂故障,其U-矩阵图为两类且距离超过0.1,判为故障,这与研制单位后来拆检的结论一致。可见频段能量比的SOM故障检测方法确实能够对涡轮泵状态进行确认。

#### 4 结 论

(1)在稳态工况下,健康的涡轮泵频谱相对稳定,频段能量比的变化小;涡轮泵发生故障时,频谱改变,频段能量比变化大。

(2)使用SOM分析表明,健康状态的涡轮泵振动数据,U-矩阵图仅存在单个类别,且相邻神经元距离明显小于0.1,故障情况下,U-矩阵图存在多个类别,相邻神经元距离大于0.1。

(3)使用基于频段能量比的SOM故障检测方法,对试车数据进行分析,3次试车的不同故障均被检测到。

该方法只能判断涡轮泵状态是否健康,还不能做到故障隔离;而且距离阈值0.1是在数据分析基础上得到的,需要进一步验证。

#### 参 考 文 献 :

- [1] Davidson M, Stephens J. Advanced Health Management System for the Space Shuttle Main Engine[J]. AIAA - 2004 - 3912, 2004.
- [2] Fiorucci T R, Lakin II D R, Reynolds T D. Advanced Engine Health Management Applications of the SSME Real-time Vibration Monitoring System [J]. AIAA - 2000 - 3622.
- [3] 谢光军,胡嵩庆,温熙森,等. 涡轮泵系统实时故障检测的短数据均值自适应阈值算法[J]. 推进技术,2005,26(3).
- [4] Xie G J, Qiu Z, Qin G J, et al. Real-time Turbopump Health Monitoring System Based on Vibration Measurement [A]. In: T. D. WEN ed. 6<sup>th</sup> International Symposium on Test and Measurement (ISTM) [C], Beijing: International Academic Publishers/World Publishing Corporation, 2005: 2286 - 2290.
- [5] 谢光军,李俭川,胡嵩庆,等. 涡轮泵系统实时故障检测的多特征参量自适应阈值综合决策算法[J]. 中国机械工程,2005(13):1184 - 1187.
- [6] Xie G J, Hu N Q, Wen X S, et al. Health Monitoring System of Turbopump [A]. 41<sup>th</sup> AIAA/ASME/SAE/ASEE Joint Propulsion Conference and Exhibit [C], AIAA - 2005 - 3948.
- [7] 谢光军,胡海峰,秦国军,等. 液体火箭发动机涡轮泵健康监控系统[J]. 国防科技大学学报,2005(3):40 - 44.
- [8] Kohonen T. Self-organizing Map [M]. Third edition, Spring, Berlin: Heidelberg, 2001.
- [9] 王慧. 基于振动参量的涡轮泵健康状态判别方法的研究[D]. 中国航天科技集团公司博士学位论文,2003.



