

# 基于神经网络的液体火箭发动机故障检测系统\*

黄敏超 张育林 冯 心

(国防科技大学航天技术系 长沙 410073)

**摘 要** 提出和建立了一种用于液体火箭发动机(LRE)故障检测的神经网络系统,这种系统包括两层:第一层由WTA(Winner-Take-All)神经网络组成,WTA网络用于检测发动机故障输出模式;第二层由BP(Back-Propagation)神经网络组成,BP网络利用第一层的输出结果作为输入显示故障大小。文中对LRE故障检测进行了数值仿真,仿真结果验证了神经网络故障检测系统的优越性能。

**关键词** 液体火箭发动机; WTA神经网络; BP神经网络; 故障检测

**分类号** V434.1

液体火箭发动机是一个复杂的系统。由于人工神经网络具有高度非线性、高度容错和联想记忆等优点,因而人工神经元技术应用于LRE故障检测越来越受到极大的重视<sup>[1,2]</sup>。WTA神经网络是一种执行优选算法的网络结构<sup>[3]</sup>。文献[4]基于神经网络内积特性,提出了一种适用于样本空间为 $\{-1, 0, 1\}^n$ 的快速学习算法。该算法对样本空间的划分是依靠定向而不是超平面,因而学习过程没有迭代循环;另外,通过对神经元作用函数的选取使神经网络具有极强的容错能力。本文又以文献[4]为基础,学习方法采用变结构神经网络学习算法,并对WTA网络的模式匹配进行分析,使样本空间扩展到任意实数空间。Rumelhart等人于1985年提出了多层神经网络反向传播算法。BP网络反传算法应用十分广泛,用它训练好的神经网络工作时不仅“智力”高,而且反应速度快,但是它在学习时存在着收敛速度慢和局部极小的问题。针对这些问题,在神经网络学习时改变学习速度,加快了系统收敛速度;引入噪声使系统误差跳出局部极小。我们用WTA神经网络和BP神经网络组成一个故障检测系统,WTA网络用于故障检测,BP网络用于故障大小显示。数值仿真结果表明,本文建立的神经网络系统能在很短时间内检测出LRE故障,并显示故障大小。

## 1 神经网络故障检测系统

图1(a)是神经网络故障检测系统的结构图,WTA神经网络针对所有故障,每个BP

\* 国家自然科学基金资助  
1993年10月5日收稿

神经网络对应一种故障。WTA 神经网络输入是发动机故障输出模式  $\bar{P}$  和  $C$  ( $C$  为选定常数), 输出用  $m$  维向量  $[y_1, \dots, y_{\frac{m}{2}}, y_{\frac{m}{2}+1}, \dots, y_m]$  ( $y_i \in \{0, 1\}$ ,  $m$  为偶数) 表示, 其中  $y_1, \dots, y_{\frac{m}{2}}$  以二进制形式表示故障种数,  $y_{\frac{m}{2}+1}, \dots, y_m$  以二进制形式表征故障大小, 这样, WTA 神经网络可以检测  $2^{\frac{m}{2}} - 1$  种故障, 每种故障大小的值域为  $[1, 2, \dots, 2^{\frac{m}{2}-1}]$ 。我们可以得到以下变换

$$Y_1 = \sum_{i=1}^{\frac{m}{2}} 2^{\frac{m}{2}-i} y_i$$

$$Y_2 = \sum_{i=\frac{m}{2}+1}^m 2^{m-i} y_i$$

式中  $Y_1$  表示某种故障发生,  $Y_2$  表征故障大小。调用第  $Y_1$  个 BP 神经网络, 输入  $Y_2$ , BP 网络输出  $Y_2$  就是系统显示的故障大小。

## 1.1 WTA 模型及快速学习算法

### 1.1.1 WTA 模型

图 1 (b) 是 WTA 神经网络模型的结构, 输入层的神经元数为  $n$ , 中间层即 WTA 层的神经元数为  $h$ , 输出层神经元数为  $m$ 。由于从输入层到中间层是完成输入模式  $\bar{X}$  ( $x_1, x_2, \dots, x_n$ ) 与所有存储模式  $\bar{W}_i$  ( $W_{i1}, W_{i2}, \dots, W_{in}$ ),  $i=1, 2, \dots, h$  之间相似度的判测, 因此  $h$  也是存储模式的数目。也就是说, 中间层每一个神经元都与一个存储模式相对应。  $n, h$  和  $m$  都是 WTA 网络的结构参数, 除此之外, 网络的结构参数还有: 输入层第  $j$  个神经元与中间层第  $i$  个神经元之间的互连权值  $W_{ij}$ , 中间层第  $i$  个神经元与第  $j$  个神经元之间的互连权值  $T_{ij}$ , 输出层第  $i$  个神经元与中间层第  $j$  个神经元之间的互连权值  $H_{ij}$ ,  $T_{ij}$  的取法特点是, 每个神经元的自连权值最大, 且为正值, 而与其他神经元的互连权值皆为负值, 正因为如此, 当中间层神经元进行状态演变时, 只有初始值最大的神经元才有稳定输出值, 所有其他神经元将趋于零。

WTA 网络中间层节点的作用函数选取

$$f_1(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

输出层节点的作用函数选用

$$f_2(x) = \begin{cases} \frac{\theta}{1 + e^{-x}} - \frac{\theta}{2}, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

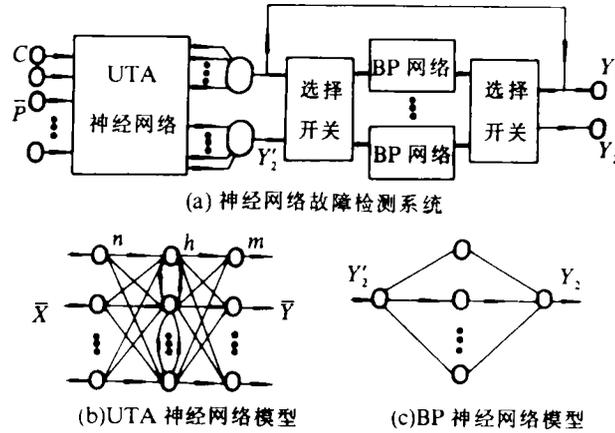


图 1

式中  $\theta$  为选定常数。

### 1.1.2 WTA 网络匹配方式

设  $U_N$  是  $N$  维样本空间,  $\bar{X} = (x_1, x_2, \dots, x_n) \in U_N$  是  $U_N$  中的一个样本, 其中  $\bar{X}$  的每个分量  $x_i$  取为实数。样本  $\bar{X}$  输入 WTA 网络后首先与存储模式进行匹配, 匹配方式对 WTA 网络的分辨性能有很重要的作用, 本文考虑以下几种匹配方式。

(1) 数量积法

$$r_i = \frac{\bar{W}_i \bar{X}}{|\bar{W}_i| |\bar{X}|}$$

式中  $\bar{W}_i = (W_{i1}, W_{i2}, \dots, W_{in})$  为权系数, 即存储模式,  $r_i$  是  $\bar{X}$  和  $\bar{W}_i$  的匹配度,  $|\bar{W}_i|$  和  $|\bar{X}|$  表示  $\bar{W}_i$  和  $\bar{X}$  的模。

(2) 指数相似法

$$r_i = \frac{1}{n} \sum_{k=1}^n \exp \left[ - \frac{3(x_k - W_{ik})^2}{4S_i^2} \right]$$

式中  $n$  为 WTA 网络输入节点数,  $S_i$  为选定常数。

(3) 绝对值指数法

$$r_i = \exp \left[ - \sum_{k=1}^n |x_k - W_{ik}| / S_i \right]$$

(4) 最大最小法

$$r_i = \frac{\sum_{k=1}^n \min[x_k, W_{ik}]}{\sum_{k=1}^n \max[x_k, W_{ik}]}$$

(5) 算数平均最小法

$$r_i = \frac{\sum_{k=1}^n \min[x_k, W_{ik}]}{\frac{1}{2} \sum_{k=1}^n [x_k + W_{ik}]}$$

(6) 几何平均最小法

$$r_i = \frac{\sum_{k=1}^n \min[x_k, W_{ik}]}{\sum_{k=1}^n \sqrt{x_k W_{ik}}}$$

从以上 6 种匹配方式可以看出, 由于我们分析的输入模式的分量  $x_i > 0$ , ( $i=1, 2, \dots, n$ ), 所以, 有  $0 < r_i \leq 1$  ( $i=1, 2, \dots, h$ )。

### 1.1.3 算法的过程

WRA 网络实际上是输入样本  $\bar{X} = (x_1, x_2, \dots, x_n)$  到输出样本  $\bar{Y} = (y_1, y_2, \dots, y_m)$  的一个非线性映射, 样本  $\bar{X}$  经过匹配函数  $\psi$  对其作用后, 向中间层输入向量  $\bar{R} = (r_1, r_2, \dots, r_h)$

$$r_i = \psi(\bar{X}, \bar{W}_i), \quad i = 1, 2, \dots, h \quad (1)$$

令

$$r = \max_{1 \leq i \leq h} r_i \quad (2)$$

若  $c \leq r \leq 1$  ( $c$  一般取为  $0.8 \sim 1.0$ ), 表示学习样本接近某个存储模式, 即神经网络“已知”当前样本, 不需要再学习, 取下一个样本重新学习。若  $r < c$ , 则表示神经网络需要学习当前样本, 增加一个中间层神经元, 设置权值  $W_{k+1,j}$  ( $j=1, \dots, n$ ) 和  $H_{i,k+1}$  ( $i=1, \dots, m$ ) 来记忆当前样本, 取

$$\bar{W}_{h+1} = \bar{X} \quad (3)$$

由于  $\bar{W}_{h+1}$  存储模式的最佳匹配度为 1, 则中间层点  $h+1$  的输出值为

$$x_{h+1} = f_1(r_{h+1}) = f_1(1) = 1$$

这个中间层点值  $x_{h+1}$  传播到输出层, 令  $y_i$  等于期望输出  $d_i$ , 则有

$$d_i = f_2(H_{i,h+1}x_{h+1}) = f_2(H_{i,h+1})$$

即

$$H_{i,h+1} = -\ln\left(\frac{\theta - 2d_i}{\theta + 2d_i}\right) \quad (4)$$

式中  $i=1, 2, \dots, m, \theta - 2d_i > 0$ . 式(1)~(4)构成了 WTA 模型的学习过程的全部算式。

#### 1.1.4 算法的实施步骤

上面的 WTA 算法可以由下列几个步骤予以实现。

1) 用第一个样本训练结构为  $\{n, l, m\}$  的神经网络; 2) 输入样本对  $\bar{X}$  和  $\bar{D} = [d_1, d_2, \dots, d_m]$ ; 3) 输入样本与存储模式进行匹配:  $r = \max\{\psi(\bar{X}, \bar{W}_i)\}$  ( $i=1, 2, \dots, h$ ), 若  $c \leq r \leq 1.0$ , 转 2); 4) 中间层增加一个神经元, 用最新样本训练结构为  $\{n, h+1, m\}$  的神经网络,  $h \leftarrow h+1$ , 转 2)。

### 1.2 BP 神经网络学习算法简介

神经网络结构见图 1 (c). 节点的作用函数采用 S 型函数 (Sigmoid)

$$O_{i,k} = \frac{\theta_{i,k}}{1 + \exp(-\beta_{i,k} Net_{i,k})} \quad (5)$$

式中  $\theta_{i,k}$  为节点输出的饱和值,  $\beta_{i,k}$  为 S 型作用函数的斜率,  $O_{i,k}$  为第  $k$  层第  $i$  节点的输出,  $Net_{i,k}$  为第  $k$  层第  $i$  节点的内部状态或称输入, 由下式给出

$$Net_{i,j} = \sum_j W_{i,j,k} O_{j,k-1} + t_{i,k} \quad (6)$$

式中  $W_{i,j,k}$  为第  $k-1$  层第  $j$  点对第  $k$  层第  $i$  节点的权系数,  $t_{i,k}$  为第  $k$  层第  $i$  节点的阈值。

对于每一个输入的模式样本, 误差定义为

$$E_p = \sum_j (d_{p,j} - O_{p,j,n})^2 / 2 \quad (7)$$

而对于全部学习样本, 系统的误差定义为

$$E = \sum_p \sum_j (d_{p,j} - O_{p,j,n})^2 / 2P \quad (8)$$

式中  $p$  为训练样本数,  $d_{p,j}$  为第  $p$  个样本第  $j$  个分量的期望输出。

神经网络学习过程就是调整权系数和神经元节点结构参数的过程。为了使  $E_p$  尽快地下降, 一般选取调整量与负梯度成比例, 即

$$\Delta_p U = -\eta \frac{\partial E_p}{\partial U} \quad (9)$$

式中  $U \in [W_{i,j,k}, t_{i,j,k}, \theta_{i,k}, \beta_{i,k}]$  代表神经网络结构参数,  $\eta \in [\eta_1, \eta_2, \eta_3, \eta_4]$  为相应学习步长,  $\Delta_p U$  是针对一个输入样本的神经网络结构参数调整量。在实际学习过程中发现, 比较好的方法是每次取一组样本, 分别求出其中每个样本所对应的  $\Delta_p U$ , 而每次调整量取它们的平均值

$$\Delta U = \sum_p \Delta_p U / P \quad (10)$$

在实现这种神经网络时，我们发现：1) 若学习速度取为定值，初期的系统误差收敛速度慢，而且一定的学习速度对应着一定的收敛精度，为此，引入变学习步长  $\eta = C_1 (C_2 l + C_3)$  ( $C_1, C_2, C_3$  为常数， $l$  为迭代次数)， $C_1$  一般取为 10~30， $C_2$  和  $C_3$  为 0.01~0.5，从学习步长的公式可以看出，开始几步，学习速度非常大，不过很快又降至  $C_3$ 。2) 系统误差在局部最小值或某稳定点或在这些点之间振荡，不管经历了多少次迭代，系统误差都会停留在某个较大的值上。为了避免系统误差陷入局部极小，本文在式 (10) 每个方程右边加上一个随机噪声序列  $n(t)$ ，即

$$\Delta U(l+1) = -\eta \frac{\partial E}{\partial U} + n(t) \quad (11)$$

数值仿真表明：在神经网络学习过程中，当误差函数  $E$  变大时加载一个均匀分布的随机数  $n(t)$ ，学习总会跳出局部极小。当求出  $\Delta_p U$  以后，由公式 (11) 就可算出神经网络结构参数每次的调整量，有关  $\Delta_p U$  的详细计算公式，现已有标准算法[6]，本文在此不再赘述。

## 2 故障检测

### 2.1 故障模式

LRE 系统故障检测的首要问题是系统的基本故障模式，这里只考虑了喷注器阻塞和泵效率下降两种故障模式。在液体火箭发动机的地面试车中，可获得的测量参数有：泵后压力 ( $P_{o2}, P_{f2}$ )、燃烧室压力 ( $P_c$ )、供应系统总流量 ( $m_o, m_f$ )、副系统流量 ( $m_{o2}, m_{f2}$ ) 和泵的转数 ( $n$ )，这些测量参数构成输入模式

$$\bar{P} = [P_{o2}, P_{f2}, P_c, m_o, m_f, 100m_{o2}, 10m_{f2}, n]$$

发动机故障数据通过 Hopfield 神经网络模拟液体火箭发动机系统获得<sup>[7]</sup>。

### 2.2 WTA 工作算法

训练好的 WTA 神经网络可以直接用于故障检测，只是检测的故障误差较大，见图 2，假设介于样本 1 和样本 2 的某实际故障模式与样本 2 相匹配，但神经网络不能确定故障模式是介于 1~2，还是 2~3 之间。为了提高检测精度，在样本 1 和样本 3 中，我们让次匹配中间层神经元也向输出层传播，得到 WTA 神经网络次匹配模式输出。虽然次匹配输出没有经过学习，但由于当选定  $\theta = 2.1$  时，WTA 神经网络的容错能力极强，仍然可

表 1 匹配方式比较

匹配方式	可选匹配度
单位化数量积法	0.9999~1.0
指数相似法	0.95~1.0
绝对指数法	0.92~1.0
最大最小法	0.98~1.0
算术平均最小法	0.99~1.0
几何平均最小法	0.99~1.0

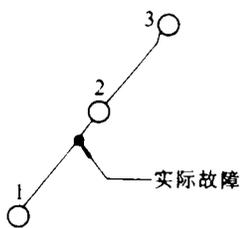


图 2 故障匹配分析

以得到次匹配模式学习时的输入,即若样本选得比较均匀,则样本1的学习输出也将激活,这就可以判定故障介于样本1~2.在输出1和2中选取表征故障严重的作为WTA神经网络输出,也即神经网络系统显示的故障比实际严重。

### 2.3 数值仿真

选用一个正常样本,11个泵效率下降和11个喷注器阻塞故障样本训练神经网络系统,WTA神经网络的输入层、中间层和输出层的神经元数分别为{9,23,8},两个BP神经网络结构都为{1,4,1}。分别以6种不同的匹配方式进行数值模拟,结果见表1,其中绝对指数法的可选匹配度最宽,其次是指数相似法、最大最小法,算术平均最小法和几何平均最小法,最窄的是数量积法。

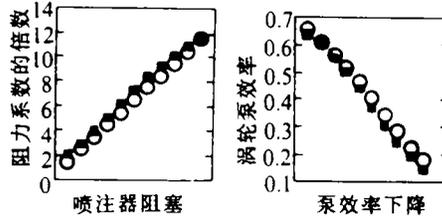


图3 数值仿真结果图

由于可选匹配越窄WTA网络的分辨率越差,因此,若仅用软件实现神经网络的功能,选用绝对指数法或指数相似法的WTA网络性能最佳。本文还分别选用11个不同于学习样本的泵效率下降和喷注器阻塞故障模式对绝对指数法的神经网络系统进行实验,实验结果见图3.效果还是比较好的。另外,只有一个很小的泵效率下降模式被确定为正常样本。这是属于早期检测问题,有待进一步研究。

## 3 结束语

本文建立的神经网络系统包括WTA网络和BP网络两层,WTA神经网络采用变结构神经网络学习算法,该算法学习速度很快,对于样本空间的选择没有特别限制,可用于实时学习。BP神经网络学习速度很慢,系统误差在学习时会陷入局部极小。采用变学习速度后,可以使BP网络学习速度加快;在神经网络中引入噪声能使系统误差跳出局部极小。神经网络系统能在短时间内成功地检测出LRE故障,并显示故障大小,可望用于LRE地面试车或上天故障检测。

## 参 考 文 献

- 1 B Whitehead, E Kiech, M Ali. Rocket Engine Diagnostics Using Neural Networks. AIAA-90-1892
- 2 B Whitehead, H Ferber, M Ali. Neural Networks Approach to Space Shuttle Main Engine Health Monitoring. AIAA-90-2259
- 3 Michael Lemmon, B V K Vijaya Kumar. Competitive Learning With Generalized Winner-Take-All Activation. IEEE Trans. Neural Networks, March 1992, 3 (2)
- 4 黄敏超,张育林. WTA神经网络快速学习算法. 中国自动化学会第九届青年学术年会, 1993
- 5 胡泽新等. 神经网络自适应控制系统研究. 控制与决策, 1992(5), 361~367
- 6 黄敏超,冯心,张育林. 应用神经网络识别液体火箭发动机的故障模式. 推进技术, 1993, (6): 32~38

(下转第88页)

## **The Design and Implementation of Graphical Specification Language in GSEIB**

Qi Zhichang Liu Chunlin Ning Hong

(The Department of Computer Science and Engineering, NUDT, Changsha, 410073)

### **Abstract**

SE information base is the kernel of an integrated SE environment. This paper presents a graphical software process and product specification language, a framework for SE project support, and the actual efforts at implementing the graphical specification subsystem. From the formal specification of a given SE project, a customized SE information base can be generated, which truly reflects and benefits the SE project.

**Key words** software engineering environment; software information base; graphical specification language

---

(上接第 60 页)

## **The Failure Detection System of Liquid Rocket Engine Based on Neural Network**

Huang Minchao Zhang Yulin Feng Xin

(The Department of Aerospace Technology, NUDT, Changsha, 410073)

### **Abstract**

A neural network system used for failure detection of a liquid rocket engine (LRE) is described and presented in this paper. The system includes two layers; the first processing layer consists of the winner-take-all (WTA) neural network used for LRE fault diagnosis; the second layer consists of the back-propagation (BP) neural network used for displaying the failure value with the output result of the first layer. In the paper, the failure detection simulation of a liquid rocket engine is given to show great advantages for the failure detection system of the neural network.

**Key words** liquid rocket engine; WTA neural network; BP neural network; failure detection