

基于人工噪声神经网络 BP 算法的 火箭发动机故障仿真与检测*

黄敏超 张育林 冯 心

(国防科技大学航天技术系, 长沙, 410073)

摘 要:研究了用于液体火箭发动机(LRE)故障仿真与故障检测的神经网络 BP(Back Propagation) 算法。在 BP 算法中采用了加噪声等技术来避免系统误差陷入局部极小, 训练出精度高(误差小于 0.02)的神经网络。试验表明:神经网络 BP 算法成功地用于故障仿真与故障检测。

主题词:液体推进剂火箭发动机, 故障诊断专家系统, 故障模拟, 故障检测, 噪声干扰
分类号: V434, V448.15

FAILURE SIMULATION AND DETECTION OF A LIQUID ROCKET ENGINE BASED ON ARTIFICIAL NOISE BP NEURAL NETWORK

Huang Minchao Zhang Yulin Feng Xin

(Department of Aerospace Technology, National
University of Defense Technology, Changsha, 410073)

Abstract: A BP (Back Propagation) neural network used in liquid rocket engine (LRE) failure simulation and detection was described. In order that the system error did not fall into partial minimum, additional noise was recommended in BP algorithm, and an accurate neural network was trained (with error below 0.02). It was shown that the BP neural network could be successfully employed in simulation and detection of LRE failures.

Keywords: Liquid propellant rocket engine, Fault diagnosis expert system, Fault simulation, Fault detection, Noise jamming

1 引 言

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,因而人工神经网络技术应用于 LRE 领域(如:故障实时仿真与故障实时检测)受到极大的重视^[1]。Rumelhart 等人于 1982 年提出了多层神经网络反向传播 BP 算法。这是一个有效的方法,用它训练好的神经网络工作时不仅“智力”高,而且反映速度快。但是它在学习时存在收敛速度慢和有局部极小的问题。本文针对这些问题,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。最后,本文基于泵压式液体火箭发动机正常和非正常姿态模拟获得的数据^[2],采用以上技术,用故障参数与发动机故障工作模式组成的样本对训练神经网络,得到了用于发动机故障仿真与故障检测的神经网络模型。

2 BP 学习算法

神经网络结构见图 1。节点的作用函数采用 S 型函数 (Sigmoid)

$$O_{i,k} = \frac{\theta_{i,k}}{1 + \exp(-\beta_{i,k} \text{Net}_{i,k})} \quad (1)$$

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, $\text{Net}_{i,k}$ 为第 k 层第 i 节点的内部状态或称输入,由下式给出

$$\text{Net}_{i,k} = \sum_j W_{i,j,k} O_{j,k-1} + t_{i,k} \quad (2)$$

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。

对于每一个输出的模式样本,误差定义为

$$E_p = \frac{1}{2} \sum_j (d_{p,j} - O_{p,j,n})^2 \quad (3)$$

而对于全部学习样本,系统的误差定义为

$$E = \frac{1}{2p} \sum_p \sum_j (d_{p,j} - O_{p,j,n})^2 \quad (4)$$

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。

以上两式中, $1/2$ 因子是为了使以后的数学表达式更简洁。将下标 p 省略,式 (3) 可以写成

$$E = \frac{1}{2} \sum_j (d_j - O_{j,n})^2 \quad (5)$$

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 尽快地下降,一般选取调整量与负梯度成比例,即

$$\Delta U = -\eta \frac{\partial E}{\partial U} \quad (6)$$

其中, $U = [W_{i,j,k}, t_{i,j,k}, \theta_{i,k}, \beta_{i,k}]$




图 1 神经网络模型

$\eta = [\eta_1, \eta_2, \eta_3, \eta_4]$ 为学习步长。

$$\text{设} \quad \delta_{i,k} = -\frac{\partial E}{\partial \text{Net}_{i,k}}; \quad \xi_{i,k} = -\frac{\partial E}{\partial O_{i,k}} \quad (7)$$

利用 (1) ~ (7) 式, E 有关学习参数的调整量可以表示为

$$\begin{aligned} \Delta W_{i,j,k} &= \eta_1 \delta_{i,k} O_{j,k-1} \\ \Delta t_{i,k} &= \eta_2 \delta_{i,k} \\ \Delta \theta_{i,k} &= \eta_3 \xi_{i,k} \left(\frac{O_{i,k}}{\theta_{i,k}} \right) \\ \Delta \beta_{i,k} &= \eta_4 \xi_{i,k} \left[O_{i,k} \left(1 - \frac{O_{i,k}}{\theta_{i,k}} \right) \text{Net}_{i,k} \right] \end{aligned} \quad (8)$$

(8) 式中除 $\delta_{i,k}$ 和 $\xi_{i,k}$ 之外的所有量均在前向通道计算得到, $\delta_{i,k}$ 和 $\xi_{i,k}$ 通过误差在神经网络反向传播上得到。

对于输出层

$$\delta_{i,n} = (d_i - O_{i,n}) O_{i,n} \left(1 - \frac{O_{i,n}}{\theta_{i,n}} \right) \beta_{i,n} \quad (9)$$

$$\xi_{i,n} = d_i - O_{i,n} \quad (10)$$

对于较低层

$$\xi_{i,k} = \sum_j \delta_{j,k+1} W_{j,i,k+1} \quad (11)$$

$$\delta_{i,k} = \xi_{i,k} O_{i,k} \left(1 - \frac{O_{i,k}}{\theta_{i,k}} \right) \beta_{i,k} \quad (12)$$

以上是针对每一个输入样本的 BP 算法。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

$$\Delta U = \frac{1}{p} \sum_p \Delta_p U \quad (13)$$

整个学习过程如下: 随机地给出一组数值作为权系数和神经元结构参数的起始值, 取一组样本, 依次将其中每一个样本作为网络输入, 计算网络输出值。一般来讲, 这时系统的误差很大, 这就说明, 必须调整权系数。将上述样本组的每一个样本所对应 $\Delta_p U$ 求出后, 由式 (13) 计算 ΔU , 并由此调整各量。这就是一次样本组输入的调整过程。调整后, 网络与所要求的仍会有差距, 需要再进行调整。重复上述过程, 直到满足学习精度要求。

对于最速下降方法, 可以想象, 学习步长 η 越大, 系统误差收敛越快, 但也可能引起振荡效应。为了抑制振荡, 在式 (13) 左边加一“惯性项”

$$\Delta U(l+1) = -\eta \frac{\partial E}{\partial U} + \alpha \Delta U(l) \quad (14)$$

其中, $l+1$ 表示第 $l+1$ 次迭代, α 为一比例因子, 适当的 α 值有益于抑制振荡, 但是学习时

间也会被延长。

在实现这种网络时,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 $\eta = C_1(C_2)^l + C_3(C_1, C_2, C_3 \text{ 为常数}, l \text{ 为迭代次数})$,解决了这个问题。(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(14)每个方程右边加上一个随机噪声 $n(t)$,即

$$\Delta U(l+1) = -\eta \frac{\partial E}{\partial U} + \alpha \Delta U(l) + n(t) \quad (15)$$

数值仿真表明:适当加载 $n(t)$,系统误差总会跳出局部极小。

3 故障仿真

3.1 故障仿真方法

液体火箭发动机的故障参数与其故障工作模式之间难以用数学表达式来描述。而这种表达式对发动机的故障控制又非常重要。神经网络由于其高度非线性为高维数、非线性、强干扰和不确定的复杂控制过程建模提供了新的途径^[3]。设

$$\bar{P}_k = f(\bar{\lambda}_k) \quad (16)$$

式中, $\bar{P}_k$ 为发动机的输出工作模式, $\bar{\lambda}_k$ 为故障参数组成的向量。

假设(16)式内部结构未知,仅知 $\bar{\lambda}_k$, $\bar{P}_k$ 的一系列测量值,则(16)式的非线性系统静态特性可以通过神经网络的输入和输出样本之间的非线性映射得到反映。把已知的输入输出测量值作为学习样本对,训练网络的权系数与神经元的结构参数,以使网络的输出对期望输出的误差小到符合要求,方可结束学习。所建神经网络模型为

$$\bar{P}_k = f(\bar{\lambda}_k, w_1, t_1, \theta_1, \beta_1) \quad (17)$$

其中, $w_1, t_1, \theta_1, \beta_1$ 为神经网络参数。

3.2 数据模拟

本文考虑了泵的效率下降和喷注器阻塞两种故障仿真。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),见图2,这些测量参数构成故障仿真的输出工作模式

$$\bar{p} = [p_{o2}, p_{f2}, p_c, m_o, m_f, 100m_{o2}, 10m_{f2}, n] \quad (18)$$

输出工作模式在异常情况下的数据是通过 Hopfield 神经网络模拟 LRE 系统获得^[1]。用于故障仿真的神经网络结构为 {1, 15, 8}。取 14 个表示输出工作模式随泵效率下降变化的样本对训练神经网络,




图2 液体火箭发动机系统图

达到一定精度停止学习,然后选用10个与训练样本不同的模拟值检验训练好的神经网络,仿真曲线如图3所见。同理,对于输出模式随喷注器阻力系数变化的曲线见图4。由图3和图4可见本文方法的有效性。

4 故障检测

4.1 故障检测系统

LRE系统故障检测的首要问题是系统的基本故障模式,这里主要考虑的故障有主、副系统管路阻塞和涡轮泵转数异常等。故障检测系统利用主、副系统的基本传感器测量信号。考虑到上天时的限制,测点有限,本文仅用泵的转数(n)、泵出口压力(p_{o2} , p_{t2})、燃烧室压力(p_c)和贮箱压力(p_o , p_f)构成LRE系统的故障模式,即

$$\bar{p} = [N, p_{o2}, p_{t2}, p_c, 10p_o, 10p_f] \quad (19)$$

利用神经网络系统对LRE这样的实时系统进行故障检测,必须解决的一个重要问题就是输入信号的预处理。输入信号预处理的基本目的在于取得传感器实时信号的本质特征。特征提取输入输出关系为

$$y_i = f\left(\sum_j w_{i,j}x_j - \theta_i\right) = \begin{cases} 1 & \sum_j w_{i,j}x_j > \theta_i \\ 0 & -\theta_i \leq \sum_j w_{i,j}x_j \leq \theta_i \\ -1 & \sum_j w_{i,j}x_j < -\theta_i \end{cases} \quad (20)$$

用于特征提取的神经网络学习实施步骤为

- (1) 输入结点处输入样本 $\bar{x} = (x_1, x_2, \dots, x_q)$;
- (2) 计算输出 y_i ;
- (3) 调整权系数 $w_{i,j}$;
- (4) 重复 (2) ~ (3) 直到偏差满足要求为止;
- (5) 转 (1) 取下一个样本。

基于以上分析,用于故障检测的人工神经网络在结构上分为两个层次。第一个层次用于对测量曲线的特征提取;第二层次为故障诊断层,利用第一个层次的输出结果作为输入进




图3 发动机故障模式随泵效率变化曲线




图4 发动机故障模式随喷注器阻力系数倍数的变化曲线

行检测与诊断。第一个层次是针对每一个传感器的,第二个层次是对所有传感器综合进行的。

4.2 数值模拟

假定某泵压式 LRE 系统只有一个正常模式,即额定工作状态 $\bar{p} = (0.99, 1.41, 1.59, 0.99, 1.38, 1.38)$, 本文考虑了 6 个故障模式,见表 1 和表 2。按照故障数据和正常数据的绝对误差进行了特征提取。把特征提取所得故障样本对送入神经网络进行训练,调整权系数,达到一定精度停止学习。

表 1 故障模式及数据

故障模式	故障数据 ($N, p_{o2}, p_{f2}, p_c, 10p_o, 10p_f$)					
主系统燃料管路阻塞	1.19	1.87	1.50	1.14	1.38	1.38
副系统管路阻塞	0.92	1.25	1.39	0.90	1.38	1.38
泵的效率降低	0.69	0.79	0.83	0.62	1.38	1.38
喷注器阻塞	1.28	2.65	2.30	0.95	1.38	1.38
氧化剂贮箱压力降低	0.98	1.35	1.56	0.96	0.69	1.38
燃料贮箱压力降低	1.00	1.43	1.56	1.00	1.38	0.69

表 2 故障样本对

输入	输出
(1,1,0,1,0,0)	(1,0,0,0,0,0)
(0,-1,-1,-1,0,0)	(0,1,0,0,0,0)
(-1,-1,-1,-1,0,0)	(0,0,1,0,0,0)
(1,1,1,0,0,0)	(0,0,0,1,0,0)
(0,0,0,0,-1,0)	(0,0,0,0,1,0)
(0,0,0,0,0,-1)	(0,0,0,0,0,1)

表 3 神经网络 BP 算法数值模拟结果

输入	输出(采用了避免误差陷入局部极小的技术)	输出(未采用其它技术)
(1)(1,1,0,1,0,0)	0.999,0.000,0.000,0.000,0.001,0.000	0.999,0.000,0.000,0.500,0.002,0.00
(2)(0,-1,-1,-1,0,0)	0.006,1.000,0.007,0.000,0.001,0.000	0.000,1.000,0.000,0.011,0.000,0.00
(3)(-1,-1,-1,-1,0,0)	0.002,0.004,1.000,0.004,0.003,0.000	0.000,0.001,1.000,0.002,0.015,0.00
(4)(1,1,1,0,0,0)	0.000,0.000,0.000,1.000,0.005,0.004	0.018,0.000,0.000,0.499,0.000,0.00
(5)(0,0,0,0,-1,0)	0.000,0.003,0.000,0.000,1.000,0.000	0.000,0.000,0.015,0.014,1.000,0.00
(6)(0,0,0,0,0,-1)	0.004,0.000,0.000,0.001,0.000,1.000	0.000,0.000,0.000,0.015,0.001,1.00
(7)(1,0,0,1,0,0)	0.829,0.001,0.000,0.000,0.003,0.001	
(8)(0,9,1,1,0.95,0,1,0,0)	0.000,0.000,0.000,1.001,0.005,0.003	

从数值模拟结果可以看到,对于改进的 BP 算法,当以样本向量作为输入时,表 3 中输入 (1) ~ (6),得到的输出向量偏差都小于 0.01,效果还是比较好的。当以新的故障信息输入时,如表 3 中输入 (7),我们发现当输入向量接近样本 (1) 的输入时,输出结果与 (4) 的样本输出结果相匹配,实现了联想功能;输入 (8) 考虑了输入 (4) 有噪声影响的情况,它的输出结果与 (4) 的样本输出结果相匹配,表明神经网络具有剔除噪声的能力。从表 3 还知,对于同样的故障模式,未改进的 BP 算法不能诊断表示喷注器阻塞的故障,并有可能误报主系统燃料管路阻塞故障。这是由于系统在学习过程中,系统误差陷入了局部极小,而不是全局最小。

(下转 33 页)

面压强系数 C_p 减小。在算例一中, 由于曲率较小, 曲率的影响不十分明显。两个二阶修正项造成速度 U 的最大相对变化量为 5%, 而 δ^* 增加极小, 并仍保持与实验结果相吻合。

在算例二中, 修正后的结构使 δ^* 提高约 20%, 但与实验结果仍相差较多。但壁面压强系数 C_p 更接近于实验, 而曲线分布形状与实验近似。于 $x=120\text{mm}$ 附近曲率 K^* 达到最大值, 这一阶段恰为附面层分离阶段, 这与物理含义相吻合。因此, 本文所提出的二阶项——曲率及雷诺正应力的修正方法是基本可行的。

参 考 文 献

- [1] Thompson B E, Whitelaw J H. Characteristics of a Trailing-Edge Flow with Turbulent-Layer Separation. *J Fluid Mech*, 1985, 157: 305~326
- [2] Simpson R L, Chew Y T, Shivaprasad B G. The Structure of a Separating Turbulent Boundary Layer. *J Fluid Mech*, 1981, 113: 23~74
- [3] Hastings R C, Moreton K G. An Investigation of a Separated Equilibrium Turbulent Boundary Layer. *Proc. Int. Symp. on Application of Laser Doppler Anemometry to Fluid Mechanics*, Lisbon, Portugal, 1982, Paper 11
- [4] Lock R C, Firman M C P. Survey of Techniques for Estimation Viscous Effects in External Aerodynamics. *Proc. of IMA Conf. on Numerical Methods in Aeronautical Fluid Dynamics*, edited by P. Roc, 1981 Paper 13, Academic Press
- [5] Strawn R C, Ferziger J H, Kline S J, A New Technique for Computing Viscous-Inviscid Interactions in Internal Flows. *ASME J of Fluids Engineering*, 1984, 16 (1): 73~80
- [6] 尹军飞. 二维不可压内流湍流附面层分离流动预测. *南京航空学院学报*, 1992, 24 (5): 513~520
- [7] 尹军飞. 实验研究湍流附面层分离. *实验力学*, 1992, (4): 24~30
- [8] 尹军飞. 应用 LDV 研究二元管道内湍流分离流动. *推进技术*, 1993 (2)

(上接第6页)

5 结 论

(1) 神经网络 BP 算法学习速度很慢, 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 算法学习速度加快; 在神经网络中引入噪声能使系统误差跳出局部极小。

(2) 训练好的神经网络能在短时间内仿真发动机的故障状态, 为发动机的故障监控提供了有效途径。

(3) 神经网络能在短时间内成功地诊断出 LRE 故障, 具有很强的容错能力和处理强噪声干扰实时数据的能力, 可望用于 LRE 地面试车或上天在线实时检测。

参 考 文 献

- [1] Whitehead B, Ferber H, Ali M. Neural Network Approach to Space Shuttle Main Engine Health Monitoring. *AIAA 90-2259*, 1990
- [2] 黄敏超, 冯心, 张育林. 应用神经网络识别泵压式液体火箭发动机故障模式. *湖南省宇航学会应用力学、推进技术年会*, 1992. 12
- [3] 胡泽新等. 神经网络自适应控制系统研究. *控制与决策*, 1992. 9