

利用神经网络诊断火箭发动机的故障

王 克 昌

(国防科学技术大学)

摘 要: 首先简要地介绍了人工神经网络(以下简称神经网络)的 BP 学习方法。然后将 BP 学习算法用于火箭发动机的故障诊断。仿真实验的结果表明,神经网络完全可以用于发动机的故障诊断。

主题词: 火箭发动机, 故障诊断, 网络分析, 算法

ROCKET ENGINE FAULT DIAGNOSIS USING NEURAL NETWORKS

Wang Kechang

(National University of Defense Technology)

Abstract: In this paper, the back-propagation (BP) learning algorithm is reviewed at first. The BP algorithm is applied to rocket engine fault diagnosis. The simulation experiments show that the neural networks can be used in engine fault diagnosis.

Keywords: Rocket engine, Fault diagnosis, network analysis, algorithm

1 前 言

对下一代可重复使用的液体火箭推进系统而言,人们期望能得到低费用和高可靠性的系统。这种期望已经使得研制和发展发动机的健康管理系统成为国内外广大研究工作者的热点。在着手研究的众多健康管理中,普遍注意确定发动机故障的诊断和决策系统。其中尤以故障诊断更为引人注目。近年来国外正致力于研制一个基于多种知识的实时故障诊断系统。该系统将神经网络方法用于实时故障诊断,取得了较好的结果。

近年来,神经网络的研究受到人们极大关注。它的发展无疑将为人工智能和模式识别等

研究开辟一条新的技术途径。神经网络具有下列特点：具有通用的匹配能力，能抵抗带有噪声的输入，具有并行处理的能力。另外它还具有自适应自学习能力，通过样本训练，根据周围环境不断改变自己的网络。这些特点就有利于缓和人工智能技术常遇到的知识获取和知识表示等方面涉及的问题。

本文主要针对神经网络的 BP 模型（亦称误差反向传播模型）作了一些初步的探讨。首先介绍 BP 算法，然后将 BP 算法用于火箭发动机系统的故障诊断。计算机仿真结果表明，用这种算法训练的神经网络对发动机系统的故障诊断有较高的识别率。

2 神经网络的基本原理及 BP 法

2.1 神经网络基本原理

神经网络是由大量的处理单元（神经元）广泛互连而成的网络。网络的信息处理由神经元之间的互相作用来实现。




图1 处理元

神经网络的基本元件是处理单元，如图1所示。通常，它是一个多输入/单输出的非线性元件。每一个输入有一与其相连的激励和加权值。处理元的目的是：(1) 把激励（称为激励函数）施加到输入激励加权值乘积之和上，(2) 输出结果。处理元的输出称为元的激励。

目前

广泛使用的网络拓扑由三层组成，其形

如图2所示。第一层是输入节点。它联接到称为隐藏层的第二层，隐藏层又连接到第三层——输出层。

网络运转时，来自发动机地面（或飞行）试

验的传感器数据作为外部激励激活输入节点。这个输入节点的激励和输入层与隐藏层之间联接加权值的乘积成为隐藏层的输入。然后，隐藏层的激励和隐藏层与输出层之间的联接加权值的乘积就成为输出层的输入。而输出层的激励表示为神经网络的输出。

在隐藏层，输出层均有一个激励函数。通常情况下，它的类型有三种非线性激励函数。其中，半线性激励函数是经常用的。其表示形式为：

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

2.2 BP 算法（反向传播算法）

Rumelhart、McClelland 等人在 1985 年发展了 BP 网络学习算法。从此，BP 算法得到了广泛运用。这个算法的学习过程是由正向传播和反向传播组成的。在正向传播过程中，输入信




图2 神经网络拓扑




图3 Sigmoid型激励函数

息从输入层经隐藏层逐层处理,并传向输出层,每一层神经元的状态只影响下一层神经元的状态。如果在输出层不能得到期望的输出,则转入反向传播,将误差信号沿原来的连接通路返回,通过不断修改各层神经元的权值 ($W_{i,j}$, $W_{j,L}$),使得误差信号最小。具体而言,这个误差信号指的是:

$$E_p = 0.5 \sum (t_{pk} - O_{pk})^2 \quad (2)$$

式中 $\{O_{pk}\}$ ——系统的输出值。

$\{t_{pk}\}$ ——期望输出值。

BP 算法的步骤可描述如下:

(1) 选定初始权值。这个权值是随机预置的。在计算中是调用一个产生随机数的子程序实现的。

(2) 输入训练样本的数据与期望输出。在 I 个输入结点上加载一个 I 维的输入向量。指定每一输出结点的期望值 t_i 。对于我们引入的网络,实际上是一个有 L 个模式的分类器,因此,期望输出是一个 L 维向量。在这个 L 维向量中,除了表征与输入相对应的模式类的输出结点的期望值为 1 外,其余输出结点的期望值均应指定为 0,例如: $\{1, 0, 0, 0, \dots\}$ 。

这里应当指出,有两种不同的训练方法,也就是一种为序贯过程,即每输入一次样本,即调整一次权值。另一种方法是 P 个样本一起输入,然后调整一次权值,这个方法又称批训练方法。我们在编程时采用后者。

(3) 计算实际输出 (output)。要依次,分别对隐藏层与输出层的每个节点进行如下计算。

$$\text{Net-input}_j = i_j = \sum_i W_{ji} O_i \quad (3)$$

$$\text{Output}_j = O_j = \frac{1}{1 + \exp(-i_j)} \quad (4)$$

(4) 修正权值。权值修正的过程是从输出结点开始,反向地向隐藏层传播由总误差诱发的权值修正。这也就是“反向传播”(Back-propagation)的由来。

$$W_{ij}(\text{new}) = W_{ij}(\text{old}) + \eta \delta_j O_i \quad (5)$$

式中 j ——对应于要进行计算的结点序号; η ——增益项;

i ——隐藏层或输入层结点的序号;

O_i ——节点 i 的输出(指隐藏层而言,而对输入层而言,则是外部输入);

δ_j ——误差项,求取 δ_j 时,要区分两种情况。

①若 j 为输出层节点,则:

$$\delta_{pj} = (t_{pj} - O_{pj}) O_{pj} (1 - O_{pj}) \quad (6)$$

②若 j 为隐藏层节点,则:

$$\delta_{pj} = O_{pj} (1 - O_{pj}) \sum_K (\delta_{pk} W_{kj}) \quad (7)$$

式中, K 为 j 结点所在层之上各层的全部节点。

为了使收敛加快,并使加权值的变化平滑则可以加上动量项 α 。这时 $W_{ij}(\text{new})$ 可以按下

式计算:

$$W_{ij}(\text{new}) = W_{ij}(\text{old}) + \eta \delta_i O_j + \alpha [\Delta W_{ij}(\text{old})] \quad (8)$$

(5) 在达到预定误差精度或循环次数后退出。否则转行 2 进行重复。

BP 算法是一个很有用的算法, 已经成为神经网络的重要模型之一。

3 BP 学习算法在火箭发动机系统故障诊断中的应用

在这里, 神经网络被用于映射过程。其方法的主要特点就是一方面将来自发动机试验时各种各样的传感器的原始数据(如压力, 温度……等)转换为能表征特征的定性的和时间上的相互关系, 另一方面将这些关系映射到相应的故障情况, 从而完成发动机系统的诊断过程。

我们从文献〔1〕中选择一美国航天飞机主发动机几次有关主燃烧室喷注器故障的情况。其中 4 次试车数据作为训练样本, 而一次试车数据用来进行故障诊断。

我们选取的试验分别为 901-173, 901-331, 750-148, 901-183 和 902-198。每个测量参数(我们取 14 个与其故障相关的测量数据)都可用如下图所示两个特征来表示。它们就是偏离正常值的时间与变化率, 其数据汇总如表 1 所示。

神经网络模型的训练:

针对上述选定的数据, 该神经网络可取如下数据:

(1) 输入层节点数 $I=28$; 隐藏层节点数 $J=10$, 输出层节点数 $L=4$ 。

(2) $\eta=0.15$; $\alpha=0.075$

然后将前四组数据(表 1)进行批训练, 具体是在 IBM-PC 微机上用 C 语言编程进行训练的。训练结果如下:

初始误差: 0.25

迭代次数: 10 次, 其最终的误差为 0.009288, 它小于规定的 0.01。




图 4 发动机参数变化特征量




图 5 主燃烧室喷注器故障的训练与诊断结果

其输出节点的输出分别为 0.903626; 0.096374; 0.096374; 0.096374; 这组输出反映的事实, 如图 5 所示。

利用神经网络的上述训练结果, 再用第 5 组数据实施故障诊断。计算机运行结果如下: 其输出节点的输出分别为 0.908767; 0.091233; 0.091233; 0.091233。其误差值为 0.008323。由此可见神经网络是可以用于训练与诊断的。

表 1 SSME 试验数据特征参数汇总

测 量 参 数		901-173	901-331	750-148	901-183	902-198
		偏离时间 (变化率)	偏离时间 (变化率)	偏离时间 (变化率)	偏离时间 (变化率)	偏离时间 (变化率)
1	次层面板压降 Δp	0.48 (-212.5)	0.12 (-625.0)	0.18 (-666.7)	4.80 (-5.7)	0.25 (-200.0)
2	主层面板压降 Δp	0.48 (-282.3)	0.15 (-146.7)	0.28 (-589.3)	3.50 (-8.4)	0.30 (-266.0)
3	热燃气喷注器压降 Δp	0.16 (93.8)	0.12 (375.0)	0.08 (562.5)	0.68 (-10.3)	1.45 (-44.1)
4	高压燃料泵出口压力减去主燃烧室压力	0.36 (-500.0)	0.1 (-500.0)	0.2 (-1500.0)	0.6 (-33.3)	0.20 (-300.0)
5	氧化剂预燃室室压减去主燃烧室热燃气入口压力	0.66 (-90.9)	0.1 (-1000.0)	0.15 (-533.3)	无明显变化	1.30 (92.0)
6	低压氧化剂泵出口压力	0.36 (-34.7)	0.1 (170.0)	0.18 (72.2)	无明显变化	0.25 (-66.8)
7	主燃烧室冷却剂出口温度	无传感器	0.56 (89.3)	0.52 (101.9)	3.20 (1.5)	2.34 (23.5)
8	燃料预燃室压力减去主燃烧室热燃气入口压力	0.37 (216.2)	0.1 (-600.0)	0.1 (-750.0)	无明显变化	0.5 (120.0)
9	主燃烧室氧化剂入口压力	0.1 (-350.0)	0.7 (200.0)	0.08 (-862.5)	2.2 (3.9)	没有传感器
10	高压燃料涡轮出口温度 (1)	0.36 (388.9)	0.3 (566.7)	0.5 (1000.0)	0.10 (260.0)	0.40 (3625.0)
11	高压燃料涡轮出口温度 (2)	0.36 (388.9)	0.3 (583.3)	传感器 工作不正常	0.15 (146.7)	0.40 (237.5)
12	主燃烧室压力	0.48 (-250.0)	0.11 (-1000.0)	0.48 (-425.0)	0.19 (-39.5)	0.22 (-213.6)
13	高压氧化剂涡轮出口温度 (1)	0.36 (111.1)	0.75 (706.7)	0.46 (1169.6)	0.25 (12.0)	0.25 (1560.0)
14	高压氧化剂涡轮出口温度 (2)	0.36 (236.1)	0.74 (743.2)	0.46 (978.0)	0.25 (24.0)	0.25 (1620.0)

4 结 论

(1) 已经证实神经网络的 BP 算法在发动机系统的故障诊断中已取得满意的结果。只要有

足够的训练样本,则诊断结果的可靠性和强壮性是可以保证的。因此只要认真收集,分析发动机系统的大量试验数据,采用合适的特征表示方式就可得到良好的诊断效果。从而确立了神经网络模型在故障诊断系统中的地位。

(2) 应当指出,现有的神经网络的 BP 算法也不是万能的。对于那些尚未训练过的故障情况,诊断结果可信度就难以保证。同时,对于那些有相似的训练样本输入而又表示不同的故障状态的情况,训练过程收敛很慢,且亦难以获得良好的结果。另外,对于有大量数据缺损的情况(发动机试车时,因传感器损坏等原因而导致缺损测量参数的情况是经常出现的)其训练结果亦会受到影响。这些问题的存在表明,一方面要继续深入研究可信度高的神经网络算法,另一方面则是在建立故障诊断系统时要同时发展基于发动机设计和功能知识的诊断子系统,两者互相证实,互相补充,才能确保故障诊断任务的完成。

参 考 文 献

- [1] Taniguchi M H. Failure Control Techniques for the SSME. NAS 8-36305, 1986