

# 压电陶瓷微动机器人控制系统的研究

## 1.1 引言

为了精确、灵活地进行微细操作，需要高性能的微动机器人控制系统协调、控制各关节的运动。本章详细介绍了压电陶瓷微动机器人控制系统的硬件结构和软件设计。针对压电陶瓷存在迟滞、蠕变和位移非线性等不足，提出了两种压电陶瓷微位移系统位置闭环控制方法：一种是带有 BP 神经网络前馈环的 PID 控制方法，另一种是 Fuzzy—PI 多模态分段控制方法，并且对两种控制方法的控制性能进行了测试。

## 1.2 控制系统的总体结构

压电陶瓷微动机器人的控制系统分为两级，即协调级和伺服级。协调级负责微动机器人的运动学计算和人机交互，伺服级负责各个关节的伺服控制。该控制系统采用了具有开放性的总线结构，由 CPU 模块、传感器模块、压电陶瓷驱动模块和通讯接口组成。这种开放式的系统结构有利于系统的扩展，如增减微动机器人的自由度，或在微动机器人系统中增加各种操作工具或传感器等。

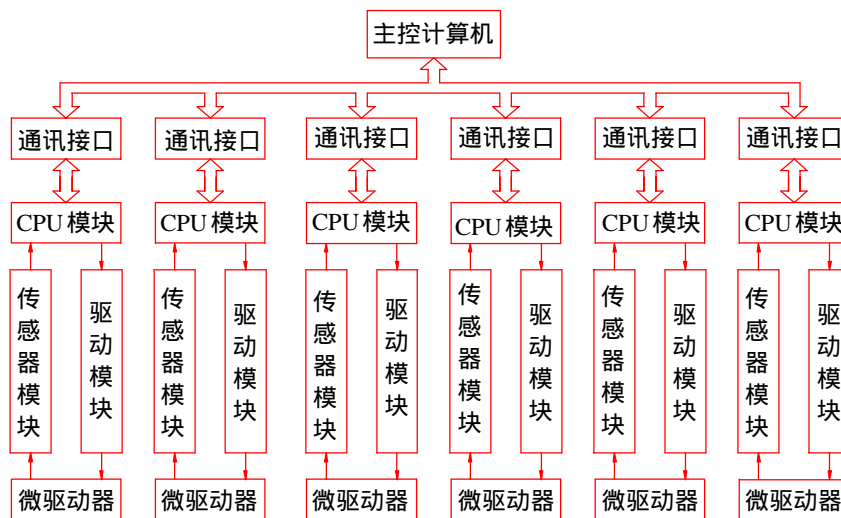


图 1-1 压电陶瓷微动机器人控制系统结构图

Fig.1-1 Control system structure of micro robot driven by piezoceramic actuators

图 1-1 为压电陶瓷微动机器人控制系统结构图。上层协调级采用 IBM/PC486

作为主控计算机,实现人机交互功能和运动轨迹的规划;下层伺服级采用 MCS-51 或 8098 单片机,组成微位移驱动器的闭环位置控制系统。

## 1.3 控制系统硬件设计

### 1.3.1 主从计算机之间的通讯接口

通讯接口是主从计算机之间的信息通道。实现信息传送功能的接口电路原理如图 1-2 所示。

图 1-2 主从计算机通讯接口原理图

Fig.1-2 Surface circuit for the communication between master and slave computers

主控计算机 AST486 与伺服级 CPU 模块之间,通过两级并行接口芯片 8255 实现并行通讯。第一级 8255 芯片通过扩展槽与主机相连,端口 A 置为双向传送方式,端口 B 置为基本输入方式。第二级 8255 芯片的 A 口工作在双向输入输出方式。

### 1.3.2 微位移驱动器位置闭环控制的实现电路

微动机器人系统各关节位置闭环控制框图如图 1-3 所示。硬件电路包括单片机模块、压电陶瓷驱动电源、微位移传感器信号处理电路。其中压电陶瓷驱动电源如第二章所述,微位移传感器信号处理电路如第三章所述。




图 1-3 微位移驱动器位置闭环控制系统框图

Fig.1-3 Position close-loop control system of micro displacement model

单片机 CPU 模块的电路如图 1-4 所示。扩展 8255 的 PA 口和 PC 口的低 4 位用于 12 位 D/A 的数据输出，PB 口和 PC 口的高 4 位用于 12 位 A/D 数字信号的采集，A/D 转换器与单片机通过中断方式联系。

图 1-4 CPU 模块电路原理图

Fig.1-4 Block diagram of CPU model circuit

## 1.4 压电陶瓷微位移系统 BP 神经网络建模

### 1.1.1 非线性系统的神经网络辨识

非线性系统本身所包含的现象非常丰富，长期以来非线性系统辨识理论的发展非常缓慢。传统的基于泛函级数的非线性系统描述方法，虽然能够充分表示一大类非线性系统，但是该方法需要估计的参数太多，计算量太大。即使对简单的非线性系统特征化，也往往需要辨识几百个参数。后来，Lentaritis 和

Bilings 提出了外援非线性自回归滑动平均模型(NARMAX),大多数实际非线性系统都可以用它描述,但是该模型的非线性函数形式是未知的,通常采用多项式函数进行逼近。这样,可以利用已有的线性估计方法来估计参数,但是该方法存在维数爆炸问题,即随着输入维数的增加,多项式的项急剧增多,处理起来比较困难。

80年代中期以来,人工神经网络以其独特的优点引起了人们的极大关注。它能够充分逼近任意复杂的非线性系统,即使仅有单隐层,也能以任意精度逼近连续函数;能够学习与适应不确定系统的动态特性;所有定量或定性的信息都储存于各神经元之中,所以有很强的鲁棒性和容错性;采用并行处理方法,能够快速进行大量运算。这些特点显示出神经网络在非线性和不确定系统的辨识与控制方面具有巨大的潜力。

神经网络进行非线性动态系统辨识的原理如图 1-5 所示。神经网络模型与系统模型并行放置,将系统输出和网络输出的误差(预测误差)作为网络的训练信号。该学习结构是所谓的监督学习问题,教师(系统)直接在学习者(网络模型)的输出端提供目标值。为了对动态系统进行辨识,要求网络模型具有动态特性。一种方法是在网络本身中引入动态,另一种方法是将网络的输入扩展,使其包括系统过去的输入和输出。由于动态网络的训练比较困难,经常出现局部收敛和发散,所以通常采用扩展网络输入的方法辨识动态系统。

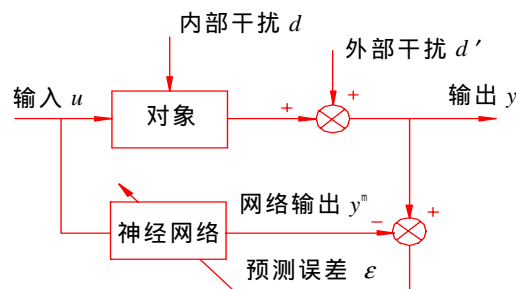


图 1-5 非线性系统神经网络辨识原理

Fig.1-5 Identification method of nonlinear system by neural network

假设系统可以用下列非线性离散差分方程描述:

$$y(k) = f[y(k-1)\Delta, y(k-n), u(k-1)\Delta, u(k-m)]$$

系统 k 时刻的输出  $y(k)$ , 可以表示成系统 n 个过去的输出和 m 个过去的输入的非线性函数。系统建模方法有两种:一种是选择神经网络的输入/输出结构与系统的输入/输出表示完全一样。网络的输出用  $y^n$  表示, 则

$$y^n(k) = f'[y(k-1)\Delta, y(k-n), u(k-1)\Delta, u(k-m)]$$

式中,  $f'$  表示网络的非线性输入/输出函数。系统的实际输出  $y(k)$  相当于静态神经网络的期望输出, 这种结构称为串—并模型。另一种模型称为并联模型,

把网络的输出(或它的延迟)反馈回来,作为网络输入的一部分。该网络模型描述为

$$y^n(k) = f' [y^n(k-1)\Delta, y^n(k-n), u(k-1)\Delta, u(k-m)]$$

它的优点是网络一旦学习收敛,得到的网络内部模型将完全与系统等价,可以用来取代系统离散训练控制器。但是并联模型不能保证参数收敛,也不能保证其输出误差会趋近于零,因此实际应用中通常采用串—并模型。

### 1.1.2 误差反向传播(BP)神经网络

按照神经元之间互联方式的不同,目前出现了 40 余种不同类型的神经网络模型,主要有 BP 网络、Hopfield 网络、自适应共振理论(ART)网络和小脑关节模型控制器(CMAC)等,其中误差反向传播神经网络(BP 网络)是当前应用最广泛的神经网络。

BP 神经网络是一种具有隐含层的多层前馈网络,多层神经网络结构如图 1-6 所示。在输入层和输出层之间有若干层(一层或多层)神经元,称为隐含层。下层的每一个神经元与上层的每一个神经元都通过权连接起来,每层各神经元之间无连接。连接权值决定了各神经元之间的联接强度,连接权值的改变能够改变网络输入和输出之间的关系。

BP 神经网络可以完成从一个空间到另一个空间的高度复杂的非线性映射。Robert 从 Kolmogorov 定理出发,证明了对于任何一个平方可积的函数  $f[0,1]^M \rightarrow R^L$ ,都存在一个三层 BP 网络,能在均方差意义下逼近该函数<sup>[103]</sup>。Funahashi 证明了任意连续映射均可被含有一个隐节点且隐节点的活化函数为有界连续递增函数的三层前馈网络逼近<sup>[104]</sup>。上述两人的工作揭示了 BP 网络实现函数映射的潜力,为 BP 网络在系统辨识与控制方面的应用奠定了理论基础。




图 1-6 BP 神经网络模型原理图

Fig.1-6 Simple figure of back-propagation neural network

BP 学习算法是一种建立在梯度下降基础上的有导师学习算法。输入信息从

输入层，经隐含层传向输出层。如果输出层不能得到期望的输出，则转入反向传播，将误差信号沿着原来的连接通道返回。通过修改各层神经元的权值，使误差信号最小。

设有  $m$  层神经网络，在输入层加上输入模式  $P$ ，第  $K$  层第  $i$  单元的输入总和为  $net_i^{[k]}$ ，输出为  $o_i^{[k]}$ ，由  $k-1$  层的第  $j$  神经元到  $k$  层的第  $i$  单元的连接权值为  $W_{ij}^{[k]}$ 。各神经元的输入和输出关系函数是  $f$ ，则各变量之间的关系为

$$o_i^{[k]} = f(net_i^{[k]}) \quad (1-1)$$

$$net_i^{[k]} = \sum_j W_{ij}^{[k]} o_j^{[k-1]}$$

神经网络二次型误差函数  $E$  为期望输出与实际输出之差的平方和。

$$E = \frac{1}{2} \sum_l (o_l^{[m]} - y_l)^2 \quad (1-2)$$

式中， $y_l$  - 输出单元的期望输出，这里作为教师信号。

$o_l^{[m]}$  - 输出单元的实际输出，它是输入模式  $P$  和权值  $W$  的函数。

BP 算法实际上是求误差函数的极小值。通常利用非线性函数规划中的最快速下降法，使权值沿着误差函数的负梯度方向改变，权值的更新量  $\Delta W_{ij}^{[k]}$  可用下式表示

$$\Delta W_{ij}^{[k]} = -\varepsilon \frac{\partial E}{\partial W_{ij}^{[k]}}$$

由于 
$$\frac{\partial net_i^{[k]}}{\partial W_{ij}^{[k]}} = \frac{\partial}{\partial W_{ij}^{[k]}} \left( \sum_j W_{ij}^{[k]} o_j^{[k-1]} \right) = o_j^{[k-1]}$$

则 
$$\frac{\partial E}{\partial W_{ij}^{[k]}} = \frac{\partial E}{\partial net_i^{[k]}} \cdot \frac{\partial net_i^{[k]}}{\partial W_{ij}^{[k]}} = \frac{\partial E}{\partial net_i^{[k]}} \cdot o_j^{[k-1]}$$

得 
$$\Delta W_{ij}^{[k]} = -\varepsilon \frac{\partial E}{\partial net_i^{[k]}} \cdot o_j^{[k-1]}$$

设 
$$d_i^{[k]} = \frac{\partial E}{\partial net_i^{[k]}}$$

则此时的学习公式：
$$\Delta W_{ij}^{[k]} = -\varepsilon \cdot d_i^{[k]} \cdot o_j^{[k-1]}$$

式中， $\varepsilon$  - 权值学习步长，取正参数。

对于算式 
$$d_i^{[k]} = \frac{\partial E}{\partial net_i^{[k]}} = \frac{\partial E}{\partial o_i^{[k]}} \cdot \frac{\partial o_i^{[k]}}{\partial net_i^{[k]}} \quad (1-3)$$

由(1-1)式可得，上式右边第二项为：

$$\frac{\partial o_i^{[k]}}{\partial net_i^{[k]}} = f'(net_i^{[k]})$$

为了便于求导，这里取  $f(x)$  为非线性 S 形函数。

$$f(net_i^{[k]}) = \frac{1}{1 + \exp(-net_i^{[k]})}$$

$$f'(net_i^{[k]}) = o_i^{[k]}(1 - o_i^{[k]})$$

(1-3) 式中等号右边第一项可分为两种情况：

1. 如果  $i$  是输出层(第  $m$  层)的神经元， $k=m$ ，则  $y_i$  是整个网络的期望输出，是定值。由式(1-2)得

$$\frac{\partial E}{\partial o_i^{[k]}} = (o_i^{[m]} - y_i)$$

则

$$d_i^{[m]} = o_i^{[m]}(1 - o_i^{[m]})(o_i^{[m]} - y_i)$$

2. 如果  $j$  不是输出层，而是中间的隐含层  $k$ ，有

$$\frac{\partial E}{\partial o_i^{[k]}} = \sum_l \frac{\partial E}{\partial net_l^{[k+1]}} \cdot \frac{\partial net_l^{[k+1]}}{\partial o_i^{[k]}} = \sum_l W_{li}^{[k+1]} \cdot d_l^{[k+1]}$$

则

$$d_i^{[k]} = o_i^{[k]}(1 - o_i^{[k]}) \cdot \sum_l W_{li}^{[k+1]} \cdot d_l^{[k+1]}$$

可以看出， $k$  层的误差信号  $d_i^{[k]}$  正比于上一层的误差信号  $d_l^{[k+1]}$ 。

综上所述，多层神经网络的 BP 算法是将某一样本加到输入层，按前述法则，它将逐个影响下一层的状态，最终得出一个输出  $o_i^{[m]}$ 。如果这个输出与期望值不符，就产生误差信号，然后通过如下公式改变权值：

$$\Delta W_{ij}^{[k]} = -\varepsilon \cdot d_i^{[k]} \cdot o_j^{[k-1]} \quad (1-4)$$

其中

$$d_i^{[m]} = o_i^{[m]}(1 - o_i^{[m]})(o_i^{[m]} - y_i) \quad (1-5)$$

$$d_i^{[k]} = o_i^{[k]}(1 - o_i^{[k]}) \cdot \sum_l W_{li}^{[k+1]} \cdot d_l^{[k+1]} \quad (1-6)$$

以上公式表明，求解本层  $d_i^{[k]}$  必须用到上一层的  $d_l^{[k+1]}$ ，因此误差函数的求解是一个始于输出层的反向传播递归过程。通过多个样本的反复训练，朝着减少偏差的方向修改权值，最后达到满意的结果，故称为反向传播学习算法。

为了改善收敛特性，采用权值更新量  $\Delta W_{ij}^{[k]}$  的修正公式：

$$\Delta W_{ij}^{[k]}(t+1) = -\varepsilon \cdot d_i^{[k]} o_j^{[k-1]} + \alpha \Delta W_{ij}^{[k]}(t) \quad (1-7)$$

式中， $\alpha$ —惯性系数。即确定后一次权值更新值的时候，适当地考虑上一次的权值更新值。

### 1.1.3 微位移系统 BP 神经网络逆模型

建立系统逆模型是神经网络辨识的核心，因为在控制系统中逆模型起着非常重要的作用。线性单变量系统的可逆性是一目了然的，线性多变量系统可逆性可以转换成系统的能观性问题，而非线性系统的可逆性问题则复杂得多。

离散单输入 - 单输出非线性系统

$$y(k+1) = f[y(k), \Lambda, y(k-n), u(k-1), \Lambda, u(k-m)] \quad (m \leq n) \quad (1-8)$$

如果存在  $R^{m+n+1}$  的子集  $A$ ，对于  $[y(k), \Lambda, y(k-n), u(k-1), \Lambda, u(k-m)]^T \in A$ ，当任意的  $u(k) \neq u'(k)$  时，必有

$$\begin{aligned} & f[y(k), \Lambda, y(k-n), u(k), u(k-1), \Lambda, u(k-m)] \\ & \neq f[y(k), \Lambda, y(k-n), u'(k), u'(k-1), \Lambda, u'(k-m)] \end{aligned}$$

则称系统方程(1-8)在点  $[y(k), \Lambda, y(k-n), u(k-1), \Lambda, u(k-m)]^T$  处是可逆的。反过来，对于任何  $[y(k), \Lambda, y(k-n), u(k-1), \Lambda, u(k-m)]^T \in A$  及任何两个不同的  $u(k)$ 、 $u'(k)$ ，导致所产生的输出是相等的，则称该系统是奇异的。

【定理】如果  $f[y(k), \Lambda, y(k-n), u(k), u(k-1), \Lambda, u(k-m)]$  对于  $u(k)$  是严格单调的，那么系统在点  $[y(k), \Lambda, y(k-n), u(k-1), \Lambda, u(k-m)]^T$  处是可逆的。如果上述结论对于任意时刻  $k$  都成立，则该系统是可逆系统。

显然，压电陶瓷微位移系统符合该定理的条件，系统是可逆的。神经网络直接逆系统建模的原理如图 1-7 所示。 $u$  是未知系统的输入信号， $y$  为系统的输出， $u^m$  是网络的输出。利用  $u^m - u$  训练神经网络，使网络以未知系统的输出  $y$  作为网络的输入时，网络的输出  $u^m$  正好等于未知系统的输入  $u$ 。

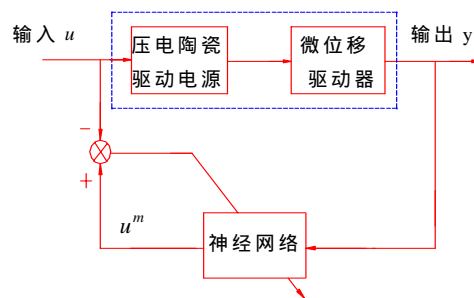


图 1-7 微位移系统神经网络逆模型辨识原理  
Fig.1-7 Identification of inverse model of micro displacement system by neural network

压电陶瓷微位移系统的逆模型可以用差分方程表示为

$$u(k) = f[y(k+1), y(k), \Lambda, y(k-n), u(k-1), \Lambda, u(k-m)] + v(k)$$

式中， $\{y(k)\}$ — 阶次为  $n$  的输入序列；

$\{u(k-1)\}$ — 阶次为  $m$  的输入序列；



$v(k)$ —  $k$  时刻系统的不可测干扰或噪声；




图 1-8 微位移系统 BP 神经网络逆模型结构图  
Fig.1-8 Structure of BP neural network inverse model

系统逆模型 BP 神经网络结构如图 1-8 所示。活化函数采用 Sigmoid 函数

$$f(\text{net}_j^{[i]}) = \frac{1}{1 + e^{-(\text{net}_j^{[i]} + \theta_j^{[i]})/\theta_0}}, \text{ 误差函数为 } E = \frac{1}{2}[u(k) - u^m(k)]^2。$$

网络输入层

$$o_j^{[1]}(k) = \begin{cases} y(k-j) & (-1 \leq j \leq n) \\ u(k-j+n+2) & (n+1 \leq j \leq m_1) \end{cases}$$

式中， $m_1$  — 输出输入序列个数， $m_1 = m + n + 2$ 。

隐含层

$$\text{net}_i^{[2]}(k) = \sum_{j=1}^{m_1} W_{ij}^{[2]} \cdot o_j^{[1]}(k) + \theta_i^{[2]} \quad (i = 1, 2, \dots, m_2)$$

$$o_i^{[2]}(k) = f[\text{net}_i^{[2]}(k)] \quad (i = 1, 2, \dots, m_2)$$

输出层

$$\text{net}_l^{[3]}(k) = \sum_{i=1}^{m_2} W_{li}^{[3]} \cdot o_i^{[2]}(k) + \theta_l^{[3]} \quad (l = 1)$$

$$u^m(k) = f[\text{net}_l^{[3]}(k)] \quad (l = 1)$$

式中， $\text{net}_j^{[2]}(k)$ —  $k$  时刻第 2 层第  $j$  个神经元的输入。

$o_j^{[2]}(k)$ —  $k$  时刻第 2 层第  $j$  个神经元的输出。

$W_{ij}^{[2]}$ — 第 1 层第  $j$  个神经元与第 2 层第  $i$  个神经元之间的连接权。

$m_2$ — 隐含层的节点数。

$\theta_i^{[2]}$ — 第 2 层第  $i$  个神经元的阈值。

由式(1-4)、(1-5)、(1-6)、(1-7)，得到系统 BP 神经网络逆模型的学习算法如下：

$$\Delta W_{li}^{[3]}(k) = -\varepsilon \cdot d_l^{[3]} o_i^{[2]} + \alpha \cdot \Delta W_{li}^{[3]}(k-1) \quad (1-9)$$

$$\Delta\theta_1^{[3]}(k) = -\beta \cdot d_1^{[3]} \quad (1-10)$$

$$\Delta W_{ij}^{[2]}(k) = -\varepsilon \cdot d_i^{[2]} o_j^{[1]} + \alpha \cdot \Delta W_{ij}^{[2]}(k-1) \quad (1-11)$$

$$\Delta\theta_i^{[2]}(k) = -\beta \cdot d_i^{[2]} \quad (1-12)$$

$$d_1^{[3]} = \frac{1}{\theta_0} u^m(k) (1 - u^m(k)) (u^m(k) - u(k)) \quad (1-13)$$

$$d_i^{[2]} = \frac{1}{\theta_0} o_i^{[2]} (1 - o_i^{[2]}) \cdot W_{li}^{[3]} d_1^{[3]} \quad (1-14)$$

式中,  $\varepsilon$  — 权值学习速率。

$\beta$  — 阈值学习速率。

$\alpha$  — 惯性系数。

### 1.1.4 微位移系统 BP 神经网络逆模型辨识实验

如图 1-9 所示, 由 AST486 计算机、PD-II 型压电陶瓷驱动电源和压电陶瓷旋转驱动器组成压电陶瓷微位移系统。压电陶瓷旋转驱动器的驱动元件是 AE0505D08 型压电陶瓷微位移器件, 旋转驱动器内部装有电阻应变式微角位移传感器。采用 12 位 D/A 转换器, 驱动电压范围 0-150V。

已知微位移系统当前时刻的输出  $y(k)$ , 过去的输出序列  $\{y(k-1), y(k-2), \dots, y(k-n)\}$ , 过去的输入序列  $\{u(k-1), u(k-2), \dots, u(k-m)\}$  和下一时刻期望的输出  $y(k+1)$ , 通过 BP 神经网络辨识系统当前时刻的输入  $u(k)$ 。

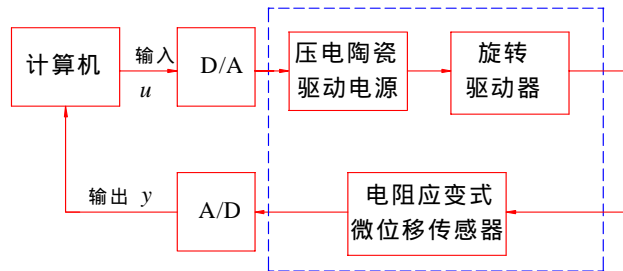


图 1-9 神经网络逆模型辨识实验系统组成

Fig.1-9 Experiment system for identifying neural network

由于微位移系统的响应速度快、滞后小, 选取公式(1-8)中  $n=2, m=3$ 。系统逆模型用差分方程表示为

$$u(k) = f[y(k+1), y(k), y(k-1), y(k-2), u(k-1), u(k-2), u(k-3)] + v(k)$$

构造一个 7 输入 1 输出的三层 BP 神经网络。神经网络辨识微位移系统逆模型的步骤如下:

### 1. 训练样本的选取

计算机控制压电陶瓷驱动电源，按照  $0\text{v} \rightarrow 150\text{v} \rightarrow 0\text{v} \rightarrow 120\text{v} \rightarrow 135\text{v} \rightarrow 15\text{v} \rightarrow 30\text{v} \rightarrow 105\text{v} \rightarrow 45\text{v} \rightarrow 90\text{v} \rightarrow 60\text{v} \rightarrow 75\text{v}$  和  $0\text{v} \rightarrow 90\text{v} \rightarrow 0\text{v} \rightarrow 75\text{v} \rightarrow 15\text{v} \rightarrow 60\text{v} \rightarrow 30\text{v} \rightarrow 45\text{v}$  的顺序，每隔一个采样周期  $T = 10\text{ms}$ ，电压升高或降低  $5\text{v}$  或  $10\text{v}$ ，同时计算机采集电阻应变式微位移传感器的输出数字量。微位移系统每相邻 4 个时刻的输入量和输出量： $y(k+1)$ 、 $y(k)$ 、 $y(k-1)$ 、 $y(k-2)$ 、 $u(k-1)$ 、 $u(k-2)$ 、 $u(k-3)$  和  $u(k)$  组成一个样本。选择随机干扰成分小，能够表现系统输入输出特征的 100 个数据对作为训练样本。微位移系统输入 - 输出关系如图 1-10 所示。




图 1-10 微位移系统电压 - 位移关系

Fig.1-10 Displacement with applied voltage of micro displacement system

### 2. 训练样本的标准化

样本的数据属于不同的值域，在网络训练之前要对数据进行预处理。系统的输入电压除以 150，输出角位移数字量除以系统输出量的最大值。

$$u'(k) = \frac{u(k)}{150} \quad y'(k) = \frac{y(k)}{y_{\max}}$$

标准化处理之后，样本的取值都处于  $(0 \sim 1)$  之间。

### 3. 网络训练

BP 神经网络逆模型的学习算法如公式(1-9)~(1-14)。为了提高收敛速度，采取“交叉排列、分批训练”的方法训练神经网络。具体的方法是：将微位移驱动器同一升程或回程电压段上的样本分在一个样本组中，训练时在各个组中轮流取数据进行训练。每次训练后，分别计算各组的均方差误差，然后用误差大的一组对神经网络补充进行一次训练。活化函数采用 Sigmoid 函数

$f(x) = \frac{1}{1 + e^{-x/\theta_0}}$ ， $f(x)$  的取值范围为  $(0 \sim 1)$ 。因为活化函数在 0 和 1 附近函数的变化率很小，输入层的误差变化进入平坦区，学习速度变慢，所以在训练中  $f(x)$  的取值范围为  $(0.01 \sim 0.99)$ 。误差函数定义为  $E = \sum |u'_d(k) - u'(k)|$ 。初始的权值采用随机数发生器予以赋值，初始权值的范围为  $-1 \sim +1$ 。隐含层神经元的

数目要根据实际的计算时间和网络的收敛情况来确定。

训练结果如图 1-11 所示，曲线 1 隐含层数目  $HN=10$ ，权值学习速率  $\varepsilon=0.08$ ，阈值学习速率  $\beta=0.08$ ，惯性系数  $\alpha=0.9$ ；曲线 2 隐含层数目  $HN=4$ ，权值学习速率  $\varepsilon=0.07$ ，阈值学习速率  $\beta=0.08$ ，惯性系数  $\alpha=0.9$ ；曲线 3 隐含层数目  $HN=6$ ，权值学习速率  $\varepsilon=0.07$ ，阈值学习速率  $\beta=0.08$ ，惯性系数  $\alpha=0.9$ 。100 个样本训练后，全部收敛。将训练样本以外的样本，输入训练好的神经网络，神经网络辨识误差小于  $1v$ 。

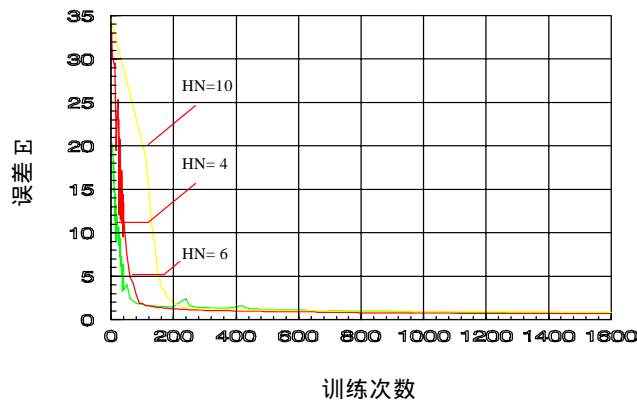


图 1-11 BP 神经网络逆模型训练过程

Fig.1-11 Training procedure of BP neural network inverse model

## 1.5 微位移系统带 BP 神经网络前馈环的 PID 控制

压电陶瓷微位移系统带 BP 神经网络前馈环的 PID 控制方法如图 1-12 所示。将压电陶瓷驱动电源和压电陶瓷微位移驱动器作为被控对象，建立被控对象的 BP 神经网络逆模型。利用该模型，可以根据被控对象的输出序列  $\{y(k), y(k-1), y(k-2), \dots, y(k-n)\}$ ，输入序列  $\{u(k-1), u(k-2), \dots, u(k-m)\}$  和下一时刻的期望输出(参考输入)  $y(k+1)$ ，预测出当前时刻应该作用在被控对象上的输入  $u(k)$ 。当系统的参考输入发生变化时，前馈控制起作用，可以提高系统的快速跟踪能力。BP 神经网络的训练是离线进行的。训练结束后，将神经网络模型和训练后的权值存入计算机中，作为系统的前馈参考模型。

微位移系统还会受到许多不可测扰动的影响，采用前馈控制对所有扰动进行补偿是不可能的。如果将前馈控制和反馈控制(如 PID 控制)结合起来，构造前馈—反馈复合控制系统，既可以发挥前馈控制作用及时的优点，又可以保持反馈控制能克服多个扰动、最终消除偏差的长处。通常，一个前馈—反馈复合控制系统，只需要前馈模型精确到  $\pm 10\%$ ，就可以使控制性能改善 10 倍左右<sup>[105]</sup>。

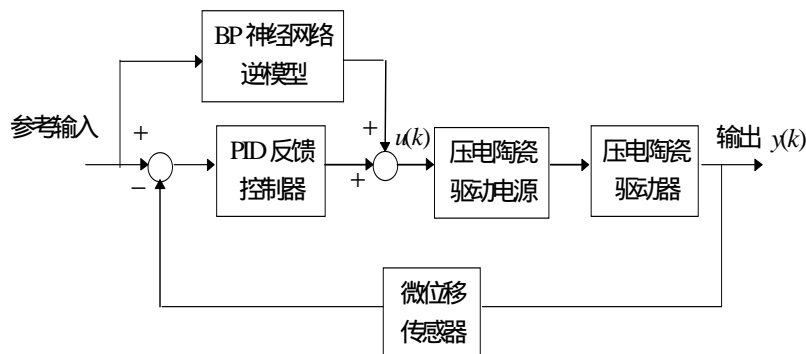


图 1-12 带 BP 神经网络前馈环的 PID 反馈控制器结构框图

Fig.1-12 The structure of PID feedback controller with BP neural network modeling in feedforward loop

前馈模型不精确或其它干扰因素引起的偏差，靠 PID 闭环控制来校正。利用 PID 中的积分环节，可以最终消除系统的稳态误差，保证微位移系统的定位精度。PID 算法离散化形式为：

$$u(k) = k_p e(k) + k_i \sum_{j=0}^k e(j) + k_d [e(k) - e(k-1)] \quad (1-15)$$

式中， $u(k)$ —第  $k$  次采样时刻控制器的输出。

$e(k)$ —第  $k$  次采样时刻系统的偏差。

$k_p, k_i, k_d$ —比例系数，积分系数，微分系数。

为了节省内存和减小误差积累，采用增量型 PID 算法。

$$\begin{aligned} \Delta u(k) &= u(k) - u(k-1) \\ &= k_p [e(k) - e(k-1)] + k_i e(k) + k_d [e(k) - 2e(k-1) - e(k-2)] \end{aligned}$$

PID 的控制参数  $k_p, k_i, k_d$  相互独立，采用实验的方法进行参数整定比较方便。

计算机控制压电陶瓷驱动电源，每隔 10ms，对压电陶瓷旋转驱动器施加  $0\text{v} \rightarrow 50\text{v} \rightarrow 100\text{v} \rightarrow 150\text{v} \rightarrow 100\text{v} \rightarrow 50\text{v} \rightarrow 0\text{v}$  的驱动电压。采用 3562A 动态分析仪，记录电阻应变式微角位移传感器的输出。压电陶瓷旋转驱动器的开环阶跃响应曲线如图 1-13 所示。

每隔 10ms，系统的参考输入按  $0'' \rightarrow 25'' \rightarrow 50'' \rightarrow 75'' \rightarrow 50'' \rightarrow 25'' \rightarrow 0''$  的顺序变化。采用带 BP 神经网络前馈环的 PID 控制器，控制压电陶瓷旋转驱动器，采样时间 1ms。利用 3562A 动态分析仪，记录电阻应变式微角位移传感器的输出。

## 1.6 微位移系统 Fuzzy—PI 控制

压电陶瓷微位移系统是一个非线性的多因素时变系统，通过理论分析的方法为其建立精确的数学模型是比较困难的，这阻碍了压电陶瓷微位移系统控制性能的进一步提高。解决这一问题的途径主要有两个：一种是采用神经网络等非传统的系统辨识方法，建立压电陶瓷微位移系统的神经网络模型，然后基于该模型对微位移系统进行控制，如带 BP 神经网络前馈环的 PID 控制；另一种方法是采用不需要系统精确数学模型的智能控制方法，如 Fuzzy—PI 多模态分段控制方法，对压电陶瓷微位移系统进行高精度的位置控制。

Fuzzy 控制器是模仿人的模糊逻辑思维方式进行工作的，它不需要被控对象精确的数学模型。与常规控制方法相比，Fuzzy 控制器具有响应速度快、超调小等优点。但是 Fuzzy 控制器中没有积分环节，对输入量的处理是离散和有限的，输出是抖动的，所以被控量在平衡点附近存在稳态误差，甚至出现小振幅的振荡现象。在平衡点附近的小范围内，PI 控制器的调节效果是理想的。它的积分作用可以最终消除残差。由此，我们提出压电陶瓷微位移系统的 Fuzzy—PI 多模态分段控制方法。当系统位置偏差较大时，采用 Fuzzy 控制；在系统位置偏差较小时，采用 PI 控制。Fuzzy—PI 多模态分段控制综合了模糊控制和比例积分控制的长处。它可以使系统既具有响应速度快和超调小的优点，又可以达到较高的稳态定位精度。压电陶瓷微位移系统 Fuzzy—PI 多模态分段控制原理如图 1-15 所示。

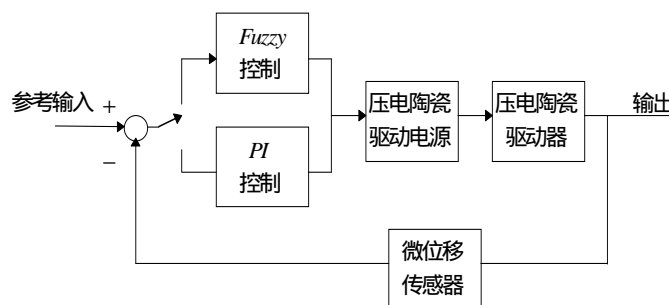


图 1-15 Fuzzy—PI 多模态分段控制结构框图

Fig.1-15 Figure of Fuzzy-PI sectionalized multimodal control structure

微位移系统的位置偏差  $e$  和偏差的变化率  $de$  作为 Fuzzy 控制器的输入。当  $|e| > e_m$  时，采用 Fuzzy 控制；当  $|e| \leq e_m$  时，切换到 PI 控制。 $e_m$  是 Fuzzy 控制和 PI 控制之间切换的误差阈值。




图 1-16 位移偏差  $e$  的隶属函数定义  
Fig.1-16 Membership function of the  $e$




图 1-17 偏差变化率  $de$  的隶属函数定义  
Fig.1-17 Membership function of the  $de$

经过输入量模糊化、模糊规则推理和输出量反模糊化三个过程，综合出控制量的增量  $\Delta u(k)$ 。控制量  $u(k) = u(k-1) + \Delta u(k)$ 。 $e$  和  $de$  经归一化处理，定义在  $[-1, 1]$  区间。图 1-16 和图 1-17 是  $e$  和  $de$  的隶属函数和语言值的定义。为了提高平衡点附近的渐近稳定性，采用非均匀分级法。经过理论分析和实验研究，归纳出模糊控制的 25 条控制规则，如表 1-1 所示。

表 1-1 模糊控制规则表  
Table.1-1 The fuzzy rules

$e \setminus de$	NB	NS	ZE	PS	PB
NB	NB	NB	NB	NS	ZE
NS	NB	NB	NS	ZE	PS
ZE	NS	NS	ZE	PS	PB
PS	NS	ZE	PS	PB	PB
PB	ZE	PS	PS	PB	PB

控制器输出的隶属函数和语言值的定义如图 1-18 所示。




图 1-18 控制器输出的隶属度函数定义  
Fig.1-18 The define of membership function of controller output

采用 MAX—MIN—INFERENCE 方法进行模糊推理。在前提条件中选取各条件中隶属度最小的值，作为该规则前提条件的满足程度。规则结论部分的模糊子集与该满足程度相截，其结果作为该规则的结论(MIN)。然后，将所应用的若干条规则的结论合并起来，作为总的推理结果(MAX)。

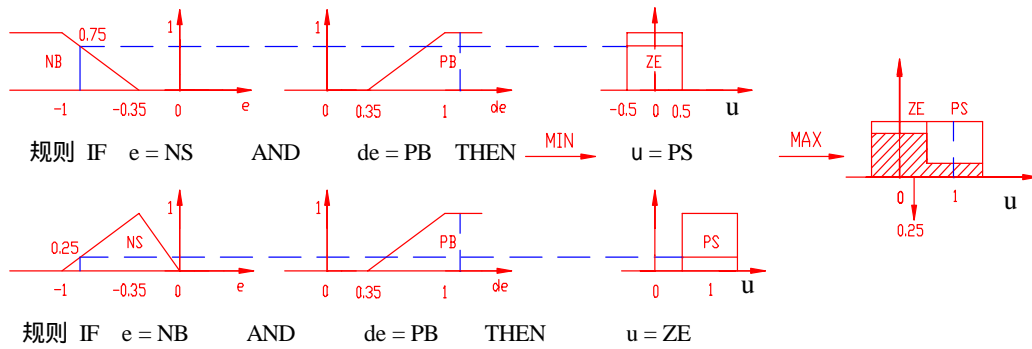


图 1-19 模糊推理和反模糊化过程

Fig.1-19 The procedure of rule evaluation and defuzzification

模糊推理和反模糊化过程 ( $e = -0.837, de = 1.1$ ) 如图 1-19 所示。反模糊化过程采用面积重心反模糊化法。面积重心法的计算公式如下：

$$u = \frac{\sum_n \mu(n) \times U(n)}{\sum_n \mu(n)}$$

式中， $U(n)$  — 第  $n$  条规则结论隶属度函数的中心值。

$\mu(n)$  — 第  $n$  条规则的隶属度。

$u$  — 模糊控制器的输出。

当  $|e| \leq e_m$  时，Fuzzy 模态切换到 PI 模态。将误差阈值  $e_m$  选在误差语言变量“零(ZE)”附近。 $e_m$  的取值要通过实验来确定。 $e_m$  选得比较大时，有利于减小超调，但是过早地进入 PI 模态会影响系统响应速度。 $e_m$  选得比较小时，离期望值太近，有可能出现大的超调。

PI 控制算法：

$$u(k) = u(k-1) + k_p \cdot [e(k) - e(k-1)] + k_i \cdot e(k)$$

式中， $k_p$  — 比例系数。

$k_i$  — 积分系数。当  $e \cdot de \leq 0$  时， $k_i = 0$ 。

$u(k)$  — PI 控制器的控制量输出。

PI 控制器根据误差  $e$  以及误差的变化率  $de$  来改变积分作用。当误差  $e$  朝着误差增大的方向变化时，积分控制起作用，以抑制误差继续增大；当误差  $e$  朝着误差减小的方向变化时，保持积分控制输出为常量，这时 PI 控制器积分器仅相当于一个比例控制器；当  $e = 0$  或积分饱和时，将积分器关闭清零。

采用 Fuzzy—PI 多模态分段控制方法，对压电陶瓷直线驱动器进行闭环位置控制实验。压电陶瓷驱动电源为哈工大 PD—II 型压电陶瓷驱动电源，它的输



出电压 0 ~ 300 v。

第一个实验是微位移系统定位精度测试实验。实验过程是：在直线驱动器的行程上以  $1\ \mu\text{m}$  为间距,确定 6 个测试点。采用量程为  $\pm 30\ \mu\text{m}$ ,位移分辨率  $0.02\ \mu\text{m}$  的 DWS 型电容测微仪,测量测试点处直线驱动器的输出位移。每一个测试点定位 10 次,共得到 60 个数据。测试结果表明：每点上的测试值与指令值之差不超过  $0.05\ \mu\text{m}$ 。

第二个实验是微位移系统位置闭环阶跃响应实验。采用 Fuzzy—PI 多模态分段控制方法,对压电陶瓷直线驱动器进行位置闭环控制。给系统的参考输入端加入一个幅值为  $2\ \mu\text{m}$  的阶跃位移信号,用 3562 信号分析仪记录 DWS 型电容测微仪测量直线驱动器的输出位移压电陶瓷直线驱动器 PI 控制的阶跃响应曲线,采样周期  $0.9\ \text{ms}$ 。压电陶瓷微位移驱动器 Fuzzy—PI 控制的阶跃响应曲线,采样周期  $0.9\ \text{ms}$ 。阶跃响应调整时间为  $10\ \text{ms}$ 。