

45-53      ⑧

# 驱动行波谐振电机的模糊神经网络控制系统

项湜伍

(上海师范大学 理工信息学院, 上海 200234)

183  
TP ~~389.1~~  
TM 359.9

**摘 要:** 用模糊神经网络(NN)系统来控制 USM 特殊电机,可很好地控制 USM 电机的转子位置,模拟神经网络系统可以在线学习变化速率,也能有效地减少参数变化的影响及外部干扰.此系统可获得精确的轨迹响应.

**关键词:** 模糊控制器; 神经网络; 行波型谐振电机

**中图分类号:** TP389.1    **文献标识码:** A    **文章编号:** 1000-5137(2000)04-0045-09

## 0 引 言

行波谐振电机(USM)有很多十分优秀的性能<sup>[1]</sup>,如高保持转矩,低速的高转矩,体积小巧,运行时无噪声,无电磁干扰.

USM 电机的驱动系统是利用压电元件的超声振动力,所以它的机械模式很难确定,USM 的集总电机模式也不易建立.

USM 系统动态性能十分复杂而且是非线性的,系统的参数随时间变化.我们采用自适应的模糊神经网络控制系统,它具有分辨不确定信息的能力及学习能力,可以很好地控制 USM 电机系统.

使用 Pentium 微机来构成接口并组成模糊控制器,使用数字信号处理器(DSP)来实现神经网络的学习训练、自适应及刻度因素的调谐.

模糊控制器实现 USM 转子位置的控制.为了增加 USM 驱动系统的跟踪性能,使用具有不同学习速率的在线训练神经网络系统来调谐模糊控制器的输出刻度因数.为了确保跟踪差的收敛性,使用离散型 Lyapunov 函数的分析方法来确定需要变化的学习速率.用带有 DSP 的计算机来实现控制器的功能,它能测试 USM 系统的控制特性<sup>[2~6]</sup>.

## 1 模糊神经网络控制器

为了加强模糊控制系统的控制性能,采用自适应机制通过输入信号来控制 USM 系统,

**收稿日期:** 1999-12-24

**作者简介:** 项湜伍(1944-),男,上海师范大学理工信息学院副教授.

偏差信号是标准输入和输出信号的反馈信号之差. 为了提高系统对不同输入信号的跟踪性能, 使用有各种学习速率的在线训练神经网络来完成模糊控制器的输出比例因数调谐. 图1是控制系统的模糊神经网络控制器的结构图.

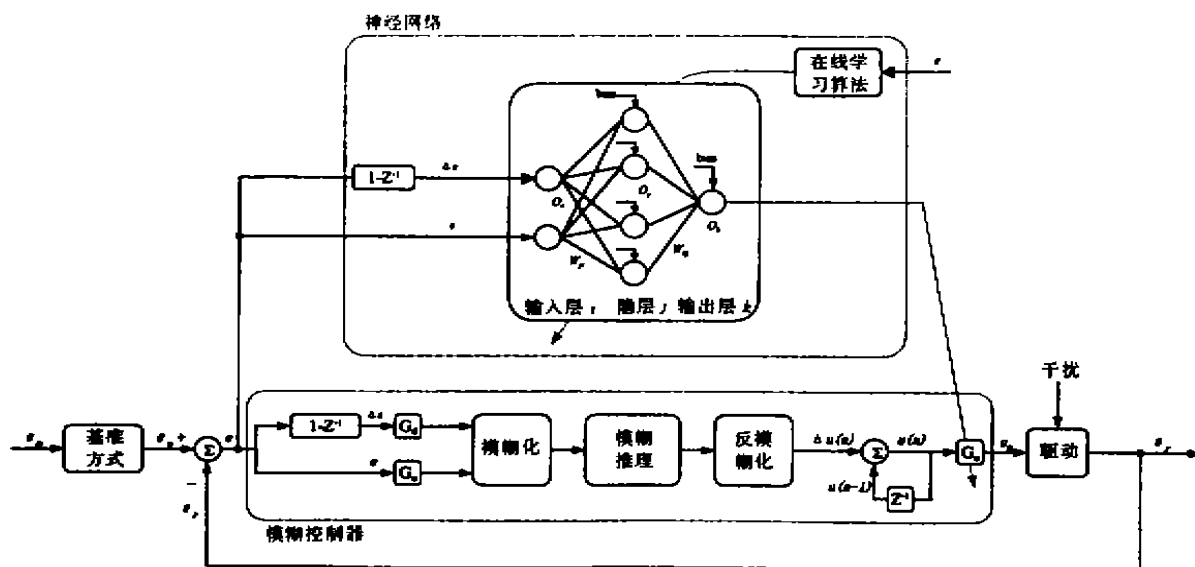


图1 模糊神经网络控制系统

模糊控制器的输入/出的参数为: 偏差信号  $e(n)$ , 偏差信号变化率  $\Delta e(n)$ , 以及控制量变化率  $\Delta u(n)$ . 他们的定义分别为:

$$e(n) = \theta_r(n) - \theta_r(n), \tag{1}$$

$$\Delta e(n) = e(n) - e(n-1), \tag{2}$$

$$u(n) = \Delta u(n-1) + \Delta u(n), \tag{3}$$

- 这里:  $n(n)$  第  $n$  次取样周期的输入信号;
- $r(n)$  第  $n$  次取样周期的反馈信号(输出信号);
- $e(n)$  第  $n$  次取样周期的偏差信号;
- $\Delta e(n)$  第  $n$  次取样周期的偏差信号变化率;
- $u(n)$  第  $n$  次取样周期的控制信号;
- $\Delta u(n)$  第  $n$  次取样周期的控制信号变化率;
- $W_{ij}$  神经网络权值从  $i$  到  $j$  节点.

选取的模糊数如下:

正大 $P_B$	正中 $P_M$	正小 $P_S$	零 $P_Z$
负小 $N_S$	负中 $N_M$	负大 $N_B$	

采用梯形隶属函数, 它能产生最好的, 且是最简单的控制性能. 使用六点法来表示输入隶属函数.

该法取  $P_1, P_2, P_3, P_4$  和上升边的斜率  $S_1$  和下降边的斜率  $S_2$  来表示图2所示的函数.




图 2 梯形输入隶属函数的表示方法

设  $x$  为  $[a, b]$  闭区间上的输入多量, 即  $x$  的最大值为  $b$ , 最小值为  $a$ . 为了用一个字节表示  $x$ , 可以把它映射为  $[0, \text{OFFH}]$  上的量, 即  $x = a$  时, 输入  $IN$  为 0;  $x = b$  时, 输入值 =  $\text{OFFH}$ ; 对其他值, 有  $IN = \frac{x - a}{b - a} \cdot \text{OFFH}$ .

如果  $p_i'$  为  $[a, b]$  区间上的值, 我们可以定义:

$$p_i = \frac{p_i' - a}{b - a} \cdot \text{OFFH}, \quad S_1 = \frac{\text{OFFH}}{P_2 - P_1}, \quad S_2 = \frac{\text{OFFH}}{P_4 - P_3}$$

对于模糊控制器, 选用误差信号和误差变化率为模糊控制器的输入信号. 输入变量的量化值如表 1 所示. 为了增加控制系统的灵敏度,  $e(n)$  和  $\Delta e(n)$  信号分别乘以  $G_e$  和  $G_d$  因子.

表 1 误差和误差变化率的量化表(模糊化)

误差 $e$ (mV)	误差变化 $\Delta e$ (mV)	量化(模糊化)
$e \leq -800$	$\Delta e \leq -800$	-6
$-800 < e \leq -400$	$-800 < \Delta e \leq -400$	-5
$-400 < e \leq -200$	$-400 < \Delta e \leq -200$	-4
$-200 < e \leq -100$	$-200 < \Delta e \leq -100$	-3
$-100 < e \leq -50$	$-100 < \Delta e \leq -50$	-2
$-50 < e \leq -25$	$-50 < \Delta e \leq -25$	-1
$-25 < e \leq 25$	$-25 < \Delta e \leq 25$	0
$25 < e \leq 50$	$25 < \Delta e \leq 50$	1
$50 < e \leq 100$	$50 < \Delta e \leq 100$	2
$100 < e \leq 200$	$100 < \Delta e \leq 200$	3
$200 < e \leq 400$	$200 < \Delta e \leq 400$	4
$400 < e \leq 800$	$400 < \Delta e \leq 800$	5
$800 < e$	$800 < \Delta e$	6

按照动态信号分析所得到的控制规则表为表 2, 使用面积中心的方法, 得到表 3, 即解模糊化表.

表2 模糊规则表

$\Delta e$	NB	NM	NS	ZE	PS	PM	PB
NB	NB	NB	NM	NM	NS	ZE	ZE
NM	NB	NM	NM	NM	NS	ZE	ZE
NS	NM	NM	NM	NS	ZE	ZE	PS
ZE	NM	NS	NS	ZE	PS	PS	PM
PS	NS	ZE	ZE	PS	PS	PM	PM
PM	NE	ZE	PS	PS	PM	PM	PB
PB	NE	ZE	PX	PM	PM	PB	PB

表3 解模糊化表

$\Delta e$	-6	-5	-4	-3	-2	-1	0	1	2	3	4	5	6
-6	-6	-6	-6	-5	-4	-4	-4	-3	-2	-1	0	0	0
-5	-6	-6	-5	-4	-4	-4	-3	-2	-2	-1	0	0	0
-4	-6	-5	-4	-4	-4	-3	-2	-2	-2	-1	0	0	0
-3	-5	-4	-4	-4	-3	-2	-2	-2	-1	0	0	0	1
-2	-4	-4	-4	-3	-2	-2	-2	-1	0	0	0	1	2
-1	-4	-4	-3	-2	-2	-2	-1	0	1	1	1	2	3
+0	-4	-3	-2	-2	-2	-1	0	1	2	2	2	3	4
+1	-3	-2	-1	-1	-1	0	1	2	2	2	3	4	4
+2	-2	-1	0	0	0	1	2	2	2	3	4	4	4
+3	-1	0	0	0	1	2	2	2	3	4	4	4	5
+4	0	0	0	1	2	2	2	3	4	4	4	5	6
+5	0	0	0	1	2	2	3	4	4	4	5	6	6
+6	0	0	0	1	2	3	4	4	4	5	6	6	6

通过查表(即经过模糊决策),可以进行解模糊化,从而得到实际的控制输出。为了增强自适应能力,通过在线训练神经网络,调节比例因数  $G_0$  (图1)。

## 2 在线训练神经网络

(1) 在线训练神经网络控制器采用3层神经网络。神经网络的输入信号是  $e(n)$  和  $e(n)$ , 而输出信号是  $G_0$ 。每层神经网络的信号传播和激活作用如下:

输入层:

$$rmnet_i = x_i, O_i = f_i(net_i) = net_i, \quad (4)$$

$x_i$  表示输入层的第  $i$  个输入节点。

隐层:

$$net_j = \sum_i (W_{ij} O_i) + \theta_j,$$

$$O_j = f_j(\text{net}_j) = \frac{1}{1 + e^{-\text{net}_j}} \quad (5)$$

这里  $W_{jk}$  是输入和隐层之间的权值,  $\theta_j$  是隐值的阈值,  $f_j$  是激活函数, 又称为 Sigmoidal 函数。  
输出层:

$$\begin{aligned} \text{net}_k &= \sum_j (W_{kj} O_j) + \theta_k, \\ O_k &= f_k(\text{net}_k) = \frac{1}{1 + e^{-\text{net}_k}} = G_o \end{aligned} \quad (6)$$

### (2) 在线学习算法

现在研究此系统在线训练神经网络的在线学习算法, 首先能量函数  $E$  定义为:

$$E = 0.5e^2. \quad (7)$$

学习算法如下.

输出层: 传播的误差项

$$\delta_k = - \frac{\partial E}{\partial \text{net}_k} = - \frac{\partial E}{\partial e} \cdot \frac{\partial e}{\partial \theta_k} \cdot \frac{\partial \theta_k}{\partial u_p} \cdot \frac{\partial u_p}{\partial O_j} \cdot \frac{\partial O_j}{\partial \text{net}_k}, \quad (8)$$

输出层权修改量

$$\Delta W_{kj} = - \eta_k \frac{\partial E}{\partial W_{kj}} = - \eta_k \frac{\partial E}{\partial \text{net}_k} \cdot \frac{\partial \text{net}_k}{\partial W_{kj}} = \eta_k \delta_k O_j. \quad (9)$$

$\eta_k$  系数是输出和隐层之间权的学习速率参数, 按下列公式来修改输出层.

$$W_{kj}(n+1) = W_{kj}(n) + \Delta W_{kj}(n) \quad (10)$$

隐层: 传播误差项

$$\delta_j = - \frac{\partial E}{\partial \text{net}_j} = - \frac{\partial E}{\partial \text{net}_k} \cdot \frac{\partial \text{net}_k}{\partial O_j} \cdot \frac{\partial O_j}{\partial \text{net}_j} = \sum_k \theta_k W_{kj} f_j'(\text{net}_j). \quad (11)$$

隐层权的修改量

$$\Delta W_{jk} = - \eta_j \frac{\partial E}{\partial W_{jk}} = - \eta_j \frac{\partial E}{\partial \text{net}_j} \cdot \frac{\partial \text{net}_j}{\partial W_{jk}} = \eta_j \delta_j O_k. \quad (12)$$

这里比例系数  $\eta_j$  是连接隐层和输入层之间的权的学习参数, 按下列公式修改隐层的权.

$$W_{jk}(n+1) = W_{jk}(n) + \Delta W_{jk}(n). \quad (13)$$

通过反向传播算法可以获得公式(8), 由于驱动系统的动态设置为未知的, 能难计算 Jacobian 系统的  $\theta_j/u_p$  精确值<sup>[9]</sup>.

为了解决问题, 增加连接权的在线学习速率, 用 Sign 函数可以近似计算  $\theta_j/u_p$ . 公式(8)可以变换为<sup>[10]</sup>

$$\theta_j = \frac{\partial E}{\partial \theta_j} \cdot \frac{\partial \theta_j}{\partial u_p} \cdot \frac{\partial u_p}{\partial O_j} \cdot \frac{\partial O_j}{\partial \text{net}_k}. \quad (14)$$

这里  $\text{Sgn}(\cdot)$  是 Sign 函数. 公式(8)~(14)组成神经网络的在线学习算法. 在隐层和输出层的每个神经元用同样的学习算法进行在线训练, 学习速率的参数值对神经网络影响很大. 为了有效地训练神经网络, 需要改变学习速率的参数, 这样可以保证误差的收敛, 具体方法读者可以用离散的 Lyapunov 函数有关资料.

### 3 模糊神经网络系统的硬件结构和软件

图3是以DSP为基础的微机控制系统结构图。

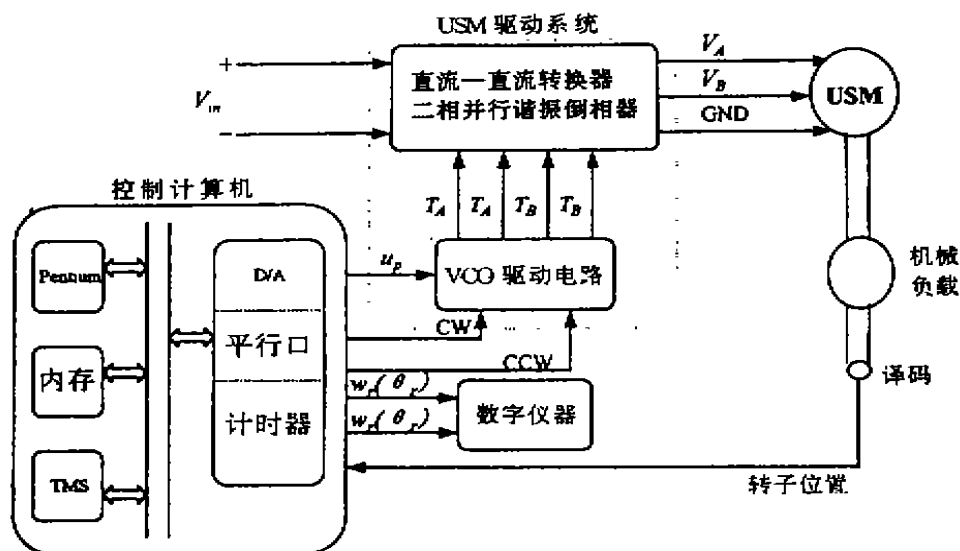


图3 DSP为基础的微机控制系统

$\omega$  为电机角速度  
 $V_A$  为电机一相 正弦电压  
 $V_B$  为电机另一相 正弦电压  
 GND 地线

CW, CCW 为电机旋转方向  
 $V_{in}$  为输入电压  
 $T_A, T_B$  VCO 驱动电路输出电压  
 $V_{in}$  输入电压

DSP 是得克萨斯仪器公司的 TMS3200C32 浮点运算芯片。一块控制卡包括多通道 D/A 转换器、可编程平行输入/出接口(8255)及一些编码接口电路。在接口电路中增加数字滤波器和倍频电路,它们可以增加反馈量的精度。

微机有两个子程序,一个是微机的中断子程序,一个是 DSP 的子程序。

中断服务子程序 ISR 的中断间隔时间为 2ms。ISR 首先从编码器读出电机转子的位置,使用基准模型产生监测信号,计算  $e$  和  $\Delta e$  的值,同步地执行 DSP。

然后从内存中得到输出比例因数  $G_o$ ,按模糊控制器规律产生输出值  $u_p$ 。

DSP 子程序首先从 DPRAM 得到偏差信号,接着计算学习速率,训练神经网络的权值及偏置值,最后调谐输出比例因数  $G_o$ 。

### 4 结 论

由于 USM 电机的动态特征十分复杂,而且是非线性的,为了增强系统的瞬变响应及电机驱动系统的鲁棒性,我们采用了模糊神经网络控制器。

在控制系统中,神经网络自动地调整输出比例因数  $G_o$ 。输入信号减去反馈信号得到偏

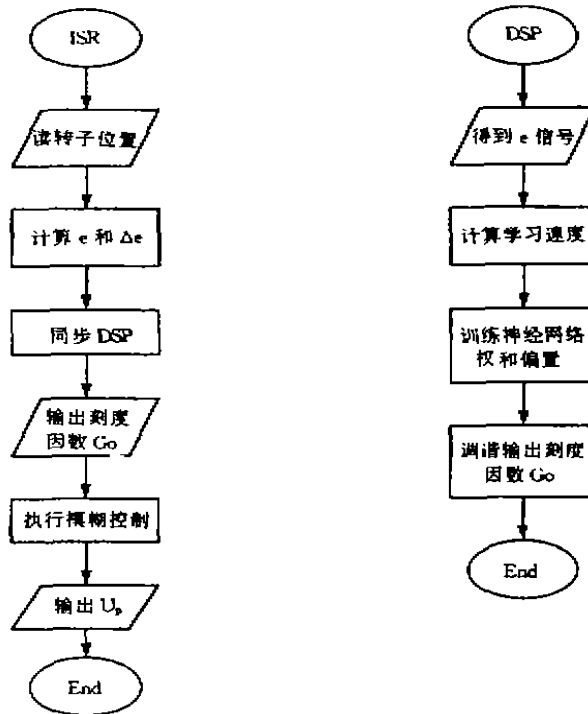


图 1 模糊神经网络控制系统的软件流程图

差信号  $e(n)$ 、神经网络在线改变学习速率、训练它们的权值及偏置。

从仿真结果来看,此控制系统的实际控制效果很好。

图 5 是一些仿真的实验曲线,供参考。

## 5 附加资料

为了有效地训练神经网络,需要改变学习速率的参数。在分析离散型 Lyapunov 函数时,为了保证跟踪的收敛性,我们使用下列两个定理

**定理 1**  $\eta_o$  是连接输出层和隐层之间的学习速率参数,  $P_{k, \max}$  定义为  $P_{k, \max} = \max \|P_{k, (n)}\|$ , 这里  $P_{k, (n)} = 2O_k / 2W_{kj}$ ; 用 sign 函数置换系统的 Jacobian 函数。如果选择  $\eta_o$  为  $\eta_o = 1 / (P_{k, \max} U)^2 = 16 / (R_{kj} U^2)$  则可以确保  $\eta_o$  的收敛性,  $R_{kj}$  是神经网络中输出和隐层之间的权值;  $u$  是模糊神经网络控制器的输出。

**定理 2**  $\eta_n$  为隐层和输入层之间的连接权的学习速率参数; 定义  $P_{j, \max} \equiv \max |P_{j, (n)}|$ , 这里  $P_{j, (n)} = 2O_k / 2W_{jn}$ ; 定义  $|W_{kj}|_{\max} \equiv \max_n |W_{kj}(n)|$ 。

用 sign 函数置换系统的雅各比函数,  $\eta_n$  定义为

$$\eta_n = 1 / (P_{j, \max} U)^2 = 256 O_{k, \max}^2 / (|W_{kj}|_{\max}^2 R_{kj} U^2),$$

则可以确保  $\eta_n$  收敛。




图5 带有负载的模糊神经网络控制系统的基准模式和转子位置的相应曲线  
 (a) 为脉冲曲线响应      Rotor position 转子位置变化曲线      rad 弧度  
 (b) 为正弦曲线响应      Sec 秒      Reference 基准模式变化曲线

## 参考文献:

- [1] SASGIDA T, KENJO T. An Introduction to Ultrasonic Motors[M]. Oxford U K Clarendon. 1993.
- [2] FURUYA S, MARUHASHI T, IZUNO Y, NAKAOKA M. Load-adaptive frequency tracking control implementation of two-phase resonant inverter for ultrasonic motor[J]. In proc IEEE PESC'90, 1990, 17-24.
- [3] IZUNO Y, TAKEDA R, NAKAOKA M. New fuzzy reasoning-based high-performance speed/position servo control schemes incorporating ultrasonic motor[J]. IEEE trans Power Electron, 1992, 12: 613-618.
- [4] SENJYU T, UEZATO K. Adjustable speed control of ultrasonic motor by adaptive control[J]. In Proc IEEE PESC'94, 1994, 1237-1242.
- [5] LIN F J. fuzzy adaptive model-following position control for ultrasonic motor[J]. IEEE Trans Power Electron, 1997, 12: 261-268.



- [6] LIN F J, KUO L C. Driving circuit for ultrasonic motor servo drive wit variable-structure adaptive model-following control[J]. Proc Inst Elect Eng, 1997, 144: 199-206.
- [7] LEE C C. Fuzzy logic in control systems: Fuzzy logic controller-Przrts I and II[J]. IEEE Trants Syst Man Cybern. 1990, 20: 404-436.
- [8] KU C C, LEE K Y. Diagonal recurrent networks for dynamic systems control[J]. IEEE Trans Neural Networks, 1995, 6: 144-156.
- [9] NARENDA K S, PARTHASARATHY K. Identification and control of dynamical systems using neural networks[J]. IEEE Trans Neural Networks, 1990, 1:4-27.
- [10] WATANABE K, TANG J, NAKAMURA M, KOGA S, FUKUDA T. A fuzzy gaussian neural network and its application to mobile robot control[J]. IEEE Trans Contr Syst Technol, 1996, 4: 193-199.

## The Fuzzy and Neural System of Driving Traveting-wave-type Motor

XIANG Shi-wu

(College of Sciences, Engineering and Informantion, Shanghai Teachers University, Shanghai 200234, China)

**Abstract:** The newly developed traveling-wave-type ultrasonic motor (USM) has many excellent feaures. However, the dynamic characteristics of the USM are difficult to obtain and the motor parameters are time varying. A fuzzy neural netwok (NN) controller is proposed to control the USM drive system.

**Key words:** fuzzy; neural network; traveling-wave-type ultrasonic motor