

具有时滞的不确定性系统神经网络模糊自学习控制*

陈善本 吴 林 , 张 铨 张福恩

(哈尔滨工业大学材料学院·哈尔滨, 150001) (哈尔滨工业大学航天学院·哈尔滨, 150001)

摘 要: 本文对具有时滞的不确定性控制对象提出了一种神经网络时滞补偿模糊自学习控制方法. 模糊控制器采用误差、误差变化及误差加速度的加权和解析描述形式, 利用人工神经网络直接对过程建模, 实现时滞补偿预报以及对模糊加权因子的自学习优化调整. 将上述方法用于焊接熔池动态过程控制试验, 结果表明本文提出的自学习神经网络时滞补偿模糊控制方案有效.

关键词: 不确定对象; 时滞补偿; 神经网络; 模糊控制

1 引 言

对于具有不确定性因素对象的控制问题一直是控制理论和控制工程实践中的难题, 而对于具有时滞特性的不确定性对象则使控制问题更加复杂化. 然而许多实际对象通常具有这种复杂性, 这使得对此问题的研究具有重要的理论意义及实际意义. 周知, 用于解决不确定性对象控制问题的经典理论主要有自适应控制和鲁棒控制方法, 它们通常要求将对象描述为某些标准的数学模型类, 如常微分方程或差分方程描述的线性系统或特定的非线性系统. 对于含时滞过程的控制常用的一些预估补偿方法也须基于一定的数学模型. 而且对系统的扰动性质通常也有一定要求. 因此, 其处理的不确定范围和应用的有效性受限制较大. 因为许多工业过程和实际控制对象具有非常复杂的不确定性以致无法采用精确的数学建模方法给出有效的可控模型, 使得基于精确数学模型的经典和现代控制理论方法都难以奏效. 近年来兴起的模拟人类智能的控制方法如模糊控制和神经网络控制方法则是解决具复杂不确定对象控制问题的新途径^[1,2]. 许多应用实践表明模糊控制方法对处理复杂不确定对象控制问题有独到的功效. 有待改进的是模糊推理规则的实时学习和修正. 另外受模糊规则数量及模糊论域划分的限制, 使得常规模糊控制精度和适应能力仍受限较大, 这也是人们致力探索的研究方向. 目前人工神经网络的出现似乎为不确定对象的智能控制带来了新的生机. 神经网络对于控制工程师的吸引力在于: 能够充分逼近任意复杂的非线性映射; 能够学习与适应严重不确定性对象的动态特性; 由于其存储信息的特点使之具有很强的鲁棒性和容错性以及并行处理方法的快速性. 这些特点显示了神经网络在解决高度非线性和严重不确定性系统控制方面的巨大潜力.

本文研究将人工神经网络与模糊控制结合对具有时滞的不确定对象实现自学习或自优化的控制方法. 其基本思想是: 利用人工神经网络的映射功能对复杂对象过程实时建模从而得到时滞补偿的预报; 利用解析形式具有可调因子的三维模糊控制器取代常规的模糊规则控制表; 然后根据不确定对象的随机变化实时修正人工神经网络模型参数和模糊控制器

* 国家自然科学基金资助项目.
本文于1995年1月21日收到, 1995年10月16日收到修改稿.

的调整因子从而实现对具有时滞的复杂不确定对象的自优化控制,其实质目标是对人的智能调节活动进行模拟。

2 神经网络自学习模糊控制方案

对一般具有时滞的不确定性控制对象,我们提出如下神经网络自学习模糊控制方案:




图 1 神经网络时滞补偿模糊自学习控制框图

图中 FC 为模糊控制器, $f(\cdot)e^{-\tau}$ 为含时滞的不确定性控制对象, PMN 为控制对象和信号检测处理环节 MS 的人工神经网络模型, EPMN 为去时滞的过程预估人工神经网络模型, D 为期望值, $e(t)$ 为控制误差, $u(t)$ 为控制输入, $y(t)$ 为实际对象输出, 在不计 MS 变换系数意义下将对象输出与检测输出均用同一变量 $y(t)$ 表示, $y_m(t)$ 与 $y_r(t)$ 分别为神经网络 PMN 和 EPMN 模型的输出量, $\varepsilon(t)$ 为模型与检测量的误差, $\bar{e}$ 为时滞预报补偿量, 各功能框图说明如下:

1) FC 为模型控制器, 其解析式描述为^[3,4]

$$U(t) = \sigma[a(t)b(t)E(t) + (1-a(t))b(t)EE(t) + (1-b(t))ER(t)]. \quad (2.1)$$

式中 $a(t)$, $b(t)$ 为加权因子(对角元素矩阵), 待学习优化调整, $E(t)$, $EE(t)$ 和 $ER(t)$ 是与误差 $e(t)$, 误差变化 $ee(t) = e(t) - e(t-1)$ 和误差加速度 $er(t) = ee(t) - ee(t-1)$ 对应的模糊量, 式(2.1)与[4]的不同之处是不做取整运算, $U(t)$ 与实际用于控制的清晰量 $u(t)$ 之间仅差与论域有关的一个常数因子。模糊量 E, EE, ER, U 的论域是相同的连续区间, 相当于模糊量的分档无限细, 而其量化比例因子则与各自的清晰量定义域有关。 $\sigma = \pm 1$ 与控制过程性质即模糊逻辑有关, 如 $u \propto e, ee$ 则 $\sigma = 1$; $u \propto -e, -ee$ 则 $\sigma = -1$ 。

2) 不确定性对象和测量环节 MS 的神经网络模型 PMN

模型由四层 BP 网实现, 节点数 N_1, N_2, N_3, N_4 , 实现的映射关系为

$$y_m(t+1) = f_m(u(t-\tau), u(t-\tau-1), \dots, u(t-\tau-m);$$

$$y_m(t), \dots, y_m(t-n)). \quad (2.2)$$

定义 $x^T[x_1, \dots, x_{N_1}]^T = [u(t-\tau), \dots, u(t-\tau-m); y_m(t), \dots, y_m(t-n)]^T$, τ 为对象的时滞常数, n, m 为对象模型的近似阶次, PMN 的网络结构示意图如图 2 网络函数为:




图 2 不确定对象神经网络模型

$$f_{1j} = 1 / \{1 + \exp[-(\sum_{i=1}^{N_1} w_{1ij} x_i + q_{2j})]\}, \quad j = 1, \dots, N_2, \quad (2.3)$$

$$f_{2k} = 1 / \{1 + \exp[-(\sum_{j=1}^{N_2} w_{2jk} f_{1j} + q_{3k})]\}, \quad k = 1, \dots, N_3, \quad (2.4)$$

$$y_m(t+1) = 1 / \{1 + \exp[-(\sum_{k=1}^{N_3} w_{3ko} f_{2k} + q_{3o})]\} = f_m(f_{2k}(f_{1j}(x))), \quad j = 1, \dots, N_2. \quad (2.5)$$

3) 时滞补偿原理.

基本原理采用 Smith 时滞补偿的思想. 对于确定性系统, 基本的 Smith 预估系统如图 3 所示. 记含时滞时的系统输出




图 3 常用 Smith 时滞补偿控制系统

$$\begin{aligned} y(t+1) &= L^{-1}\{G(s)e^{-\tau s}\} \\ &= f(u(t-\tau), u(t-\tau-1), \dots, \\ &\quad u(t-\tau-m), y(t), \dots, y(t-n)), \end{aligned} \quad (2.6)$$

则无时滞时的系统预测输出

$$\begin{aligned} y_r(t+1) &= L^{-1}G(s) \\ &= f_r(u(t), u(t-1), \dots, u(t-m); y_r(t), \dots, y_r(t-n)), \end{aligned} \quad (2.7)$$

误差补偿量 $\bar{e} = f_r(\cdot) - f(\cdot)$.

式中 $L^{-1}\{\cdot\}$ 表示拉普拉斯反变换, $G_c(s)$ 为控制器, 对于不确定系统, 图 1 中利用模糊控制器 FC 代替图 3 中的 $G_c(s)$ 利用神经网络模型 EPMN 给出无时滞输出量的预测值实现补偿控制. 只须将含时滞过程的输入样本序列作时间位移 τ 即可. 再由与 (2.2) 映射相同的网络结构学习训练得到无时滞时的预测输出

$$y_r(t+1) = f_{mr}(u(t), u(t-1), \dots, u(t-m); y_r(t), \dots, y_r(t-n)), \quad (2.8)$$

然后与测量输出相减得到补偿误差 $\bar{e}$.

3 神经网络模糊控制器的自学习算法

1) 控制误差指标

$$J_d = \sum_{t=1}^N [D - y(t+1)]^2 / 2.$$

将检测输出与过程输出在不计系数变换意义下用同一变量 $y(t+1)$ 表示, 下同.

2) 调节控制器误差指标

$$\begin{aligned} J_e &= \sum_{t=1}^N e^2(t+1) / 2 = \sum_{t=1}^N [D - y(t+1) + \bar{e}]^2 / 2 \\ &= \sum_{t=1}^N [D + y_r(t+1) - 2y(t+1)]^2 / 2. \end{aligned} \quad (3.1)$$

可以证明 J_d 与 J_e 具有等价性.

3) 过程模型 PMN 输出与测量量的误差指标

$$J_e = \sum_{t=1}^N \epsilon^2(t+1)/2 = \sum_{t=1}^N [y(t+1) - y_m(t+1)]^T [y(t+1) - y_m(t+1)]/2. \quad (3.2)$$

4) 过程模型 PMN 网络参数的学习.

PMN 的网络参数学习可采用离线和在线学习方法, 离线学习是根据 $u(t) \sim y(t+1)$ 的批量测量数据样本学习得到权重, 可采用一般 BP 网络的参数学习算法. 离线学习的结果即作为实际过程的参考模型. 在线学习则是根据 PMN 与 MS 的误差指标随网络参数变化梯度下降的原则实时修正网络的权重, 即

$$\begin{aligned} \Delta w(t) &\propto -\partial J_e / \partial w(t), \\ w(t+1) &= w(t) + \Delta w(t). \end{aligned} \quad (3.3)$$

依(3.1)~(3.3)将学习算法简要说明如下: 作

$$\begin{aligned} v_3(t) &= (y(t) - y_m(t))(1 - y_m(t))y_m(t), \\ v_{2k}(t) &= f_{2k}(t)(1 - f_{2k}(t))w_{3ko}(t)v_3(t), \quad k = 1, \dots, N_3, \\ v_{1j}(t) &= f_{1j}(t)(1 - f_{1j}(t)) \sum_{k=1}^{N_3} w_{3jk}(t)v_{2k}(t), \quad j = 1, \dots, N_2. \end{aligned}$$

权重修正

$$\begin{aligned} \Delta w_{3ko}(t) &= h_3 v_3(t) f_{2k}(t) + a_3 \Delta w_{3ko}(t-1), \\ w_{3ko}(t+1) &= w_{3ko}(t) + \Delta w_{3ko}(t), \end{aligned} \quad (3.4)$$

$$q_{3o}(t+1) = q_{3o}(t) + h_3 v_3(t), \quad (3.5)$$

$$\begin{aligned} \Delta w_{2jk}(t) &= h_2 v_{2k}(t) f_{1j}(t) + a_2 \Delta w_{2jk}(t-1), \\ w_{2jk}(t+1) &= w_{2jk}(t) + \Delta w_{2jk}(t), \end{aligned} \quad (3.6)$$

$$q_{2k}(t+1) = q_{2k}(t) + h_2 v_{2k}(t), \quad (3.7)$$

$$\begin{aligned} \Delta w_{1ij}(t) &= h_1 v_{1j}(t) x_1(t) + a_1 \Delta w_{1ij}(t-1), \\ w_{1ij}(t+1) &= w_{1ij}(t) + \Delta w_{1ij}(t), \end{aligned} \quad (3.8)$$

$$q_{1j}(t+1) = q_{1j}(t) + h_1 v_{1j}(t). \quad (3.9)$$

式中 $h_1, a_1 \in (0, 1)$ 为学习因子和动量因子, 式(3.4)~(3.9)即控制周期内的网络一步反向学习算法.

5) 模糊控制器 FC 的加权因子 $a(t), b(t)$ 的学习.

以离线或前次学习的 PMN 网络参数为已知量, 调整 a, b 的算法如下:

$$a(t+1) = a(t) + \Delta a(t), \quad (3.10)$$

$$b(t+1) = b(t) + \Delta b(t), \quad (3.10)$$

$$\Delta a(t) = -h_a (\partial J_e / \partial a(t)), \quad (3.12)$$

$$\Delta b(t) = -h_b (\partial J_e / \partial b(t)). \quad (3.13)$$

式中学习因子 $h_a, h_b \in (0, 1)$,

$$\frac{\partial J_e}{\partial a(t)} \approx [D + y_r(t+1) - 2(y_m(t+1) + \epsilon)],$$

$$\left[\frac{\partial y_r(t+1)}{\partial a(t)} - \frac{2 \partial y_m(t+1)}{\partial a(t)} \right]$$

$$= [D + y_r(t+1) - 2y(t+1)] \left[\frac{\partial y_r(t+1)}{\partial a(t)} - \frac{2\partial y_m(t+1)}{\partial a(t)} \right], \quad (\text{忽略 } \frac{\partial \varepsilon}{\partial a}) \quad (3.14)$$

$$\frac{\partial y_r(t+1)}{\partial a(t)} = \left[\frac{\partial f_m \tau}{\partial u(t)} \right] \left[\frac{\partial u(t)}{\partial a(t)} \right], \quad (3.15)$$

$$\frac{\partial y_m(t+1)}{\partial a(t)} = \left[\frac{\partial f_m(t)}{\partial u(t)} \right] \left[\frac{\partial u(t)}{\partial a(t)} \right], \quad (3.16)$$

$$\left[\frac{\partial u(t)}{\partial a(t)} \right] = \sigma b(t) [E(t) - EE(t)], \quad (3.17)$$

同理

$$\begin{aligned} \frac{\partial J_\varepsilon}{\partial b(t)} &\approx [D + y_r(t+1) - 2(y_m(t+1) + \varepsilon)] \left[\frac{\partial y_r(t+1)}{\partial b(t)} - \frac{2\partial y_m(t+1)}{\partial b(t)} \right] \\ &= [D + y_r(t+1) - 2y(t+1)] \left[\frac{\partial y_r(t+1)}{\partial b(t)} - \frac{2\partial y_m(t+1)}{\partial b(t)} \right], \quad (\text{忽略 } \frac{\partial \varepsilon}{\partial a}) \end{aligned} \quad (3.18)$$

$$\frac{\partial y_r(t+1)}{\partial b(t)} = \left[\frac{\partial f_m \tau}{\partial u(t)} \right] \left[\frac{\partial u(t)}{\partial b(t)} \right], \quad (3.19)$$

$$\frac{\partial y_m(t+1)}{\partial b(t)} = \left[\frac{\partial f_m(t)}{\partial u(t)} \right] \left[\frac{\partial u(t)}{\partial b(t)} \right], \quad (3.20)$$

$$\frac{\partial u(t)}{\partial b(t)} = \sigma [a(t)E(t) + (1 - a(t))EE(t) - ER(t)]. \quad (3.21)$$

而

$$\begin{aligned} \frac{\partial f_{m\tau}}{\partial u(t)} &= \frac{\partial f_{m\tau}}{\partial x_1} = \sum_{K=1}^{N_3} \left[\frac{\partial f_{m\tau}}{\partial f_{2k}} \right] \sum_{j=1}^{N_2} \left[\frac{\partial f_{2k}}{\partial f_{1j}} \right] \left[\frac{\partial f_{1j}}{\partial x_1} \right] \\ &= - \left\{ f_{m\tau}(1 - f_{m\tau}) \sum_{K=1}^{N_3} [w_{3ko} f_{2k}(1 - f_{2k})] \sum_{K=1}^{N_3} [w_{2jk} f_{1j}(1 - f_{1j}) w_{11j}] \right\}. \end{aligned} \quad (3.22)$$

式中 f, w 对应 EPMN 网络状态及参数

$$\begin{aligned} \frac{\partial f_m}{\partial u(t)} &= \frac{\partial f_m}{\partial x_1} = \sum_{K=1}^{N_3} \left[\frac{\partial f_m}{\partial f_{2k}} \right] \sum_{j=1}^{N_2} \left[\frac{\partial f_{2k}}{\partial f_{1j}} \right] \left[\frac{\partial f_{1j}}{\partial x_1} \right] \\ &= - \left\{ f_m(1 - f_m) \sum_{K=1}^{N_3} [w_{3ko} f_{2k}(1 - f_{2k})] \sum_{K=1}^{N_3} [w_{2jk} f_{1j}(1 - f_{1j}) w_{11j}] \right\}. \end{aligned} \quad (3.23)$$

式中 f, w 对应 PMN 网络状态及参数。

式(3.10)~(3.23)即控制周期内的模糊控制器加权因子 a, b 的一步学习算法,其本质是对模糊控制规则的实时调整^[3,4]。

4 控制方案的实验结果

为了考察上述设计对于不确定对象控制的有效性,我们选取一个复杂的工业控制对象——脉冲 TIG 焊接熔池的动态过程控制。周知,由于焊接熔池动态变化过程是一个高度非线性,多变量耦合作用,时滞特性明显,同时具有大量随机不确定因素的复杂过程,经典的数学建模方法不可能得到有效的可控制模型,决定了对焊接熔池的动态变化亦即对焊接熔宽、熔透和焊缝成形等质量控制是非常困难的。因此我们采用上述控制方案对脉冲 TIG 焊接熔

池的动态过程作试验验证。

通过对脉冲 TIG 焊的实验测试分析知:在确定的母材及工艺参数规范下,主要影响 TIG 焊熔宽变化的因素是焊接速度和焊接电流。一般情况下 TIG 焊工艺操作是将焊速固定而调节焊接电流,因为调节电流相对容易实现的缘故。然而,本质上这是一种滞后调节而非实时控制,从直接焊工经验可知:实时调节焊速对焊缝成形是最为有效的。因此在本文的研究方案中,我们只选控制焊接焊速——正面熔宽的单入单出系统作为研究对象。将焊速调节的惯性用时滞特性模拟。过程模型采用的输入输出测量数据如图 4 所示,可见具有明显的时滞 $\tau \approx 1$ 。




图 4 对象测试曲线

对上述过程建立如图 2 所示神经网络模型实现的映射关系为:

$$y_m(t+1) = f_m(u(t-\tau), u(t-\tau-1), u(t-\tau-2), y_m(t), y_m(t-1))$$

系统时滞测试约为 1, 阶次取 $m=2, n=1$, 网络节点数取为 5-15-15-1。离线学习满足精度要求后作为实际过程辨识模型 PMN 与前节设计的神经网络模糊控制器按图 1 系统连接, 控制器中模糊逻辑参数 $\sigma=1$ 。预估模型 EPMN 采用上述测量数据作时序位移后训练图 2 网络获得。实际试验用的脉冲 TIG 焊正面熔宽动态过程自学习模糊神经网络控制系统硬件框图如下(图 5):




图 5 实验系统硬件框图

图中视觉传感采用的是日本 National 公司生产的硅靶面工业摄像机, 焊接电源采用日本大

阪变压器公司的 COMPAQ—500 型交直流钨极氩弧焊电源,焊接工作台采用 8031 单片机系统控制. 自学习模糊神经网络控制算法由 PC 机实现.

正面熔宽信息的检测利用视觉传感及图象处理实现^[5].

在如下实验条件下,我们在上述系统做了堆焊试验. 控制曲线如图 6 所示.

材料:A3 钢;

板厚:2mm;

哑铃形试件,两端铃部:80mm×100mm;

中间细部:90mm×30mm;

电极:钍钨极,直径 3.0mm;

氩气流量:8L/min;

电弧电压 12~15V;

焊接电流:180A.

选取哑铃型试件的目的是为了验证变散热条件下调节焊速以保持恒定熔宽采用本文控制方案的有效性.





图 6 恒定规范焊接

试验结果分析:

1) 对变散热条件试件的实焊控制效果表明本文提出的自学习模糊神经网络控制方法对脉冲 TIG 焊熔宽过程速度控制有效. 期望熔宽为 6.25mm, 恒定焊速的熔宽变化误差范围为 16%, 且哑铃中部变化剧烈几乎焊漏, 而采用焊速调节的图 7(a) 的熔宽基本维持在期望值附近, 误差范围为 5% 左右, 满足一般焊接工艺要求. 明显, 图 6 和图 7 的控制结果比较说明控制调节过程与人的经验一致, 散热条件差时应略微提高焊速以保持焊缝均匀一致. 时滞补偿方案则较好地改善了控制效果.

2) 控制算法和图象处理的周期偏长影响控制效果. 这有赖于神经网络的并行处理实现提高运算速度. 由于目前的控制算法全部是软件实现, 这使控制周期缩短受到限制, 如能以硬件实现神经网络算法, 将会更进一步提高系统性能.






图 7 控制实验结果

5 结 束 语

本文对具有时滞常数的不确定性控制对象提出了一种人工神经网络补偿及自学习模糊控制方法. 这种神经网络自学习模糊控制器实质上实现了对不确定性对象模糊控制经验规则的智能调整, 从而回避了经典方法对过程建模及常规模糊控制规则在线自调整的困难. 利用神经网络模型实现对不确定对象时滞补偿量的预报, 此方法对具有时滞的一般复杂不确定性控制对象具有适用性. 应用此方法对脉冲 TIG 焊熔池正面熔宽动态过程的速度控制的试验结果表明控制方案可行.

参 考 文 献

- [1] Procyk, T. J., Mamdani, E. H.. A Linguistic Self-Organizing Process Controller. *Automatica*, 1979, 15:15-30
- [2] Wilis N. J. et al.. Artificial Neural Networks in Process Estimation and Control. *Automatica*, 1992, 28:1181-1187
- [3] 龙升照, 汪培庄. Fuzzy 控制规则的自调整问题. *模糊数学*, 1982, 3:105-111
- [4] 李士勇等. 模糊控制和智能控制理论与应用. 哈尔滨: 哈尔滨工业大学出版社, 1990
- [5] 刘玉池. 计算机视觉脉冲 TIG 焊正面实时检测与熔宽控制的研究. 哈尔滨工业大学研究生学位论文, 1994

A Self-Learning Neural Networks Fuzzy Control of Uncertain Systems with Time Lag

CHEN Shanben and WU Lin

(School of Material Science and Engineering, Harbin Institute of Technology • Harbin, 150001, PRC)

ZHANG Quan and ZHANG Fuen

(Aerospace School, Harbin Institute of Technology • Harbin, 150001, PRC)

Abstract: A self-learning neural network time lag compensation and fuzzy control approach to the controlled uncertain objects with time lag is presented in this paper. Using artificial neural networks for modelling the objects, the fuzzy controller described in the analysis formula with control error, error change and error acceleration is real-timely regulated by self-learning weight factors and the time lag compensation and prediction of the systems is realized. The results of experiment on the dynamic process of weld pool in the pulse TIG welding show that the self-learning neural network time lag compensation and

fuzzy control scheme presented in this paper is effective .

Key words: Uncertain objects; time lag compensation; neural networks; self-learning fuzzy control

本文作者简介

陈善本 1956 年生, 1982 年毕业于大连铁道学院自动化专业, 学士, 1987 和 1991 年获哈尔滨工业大学控制理论及应用专业硕士和博士学位. 曾任教于上海铁道学院, 海军航空工程学院, 哈工大材料科学与工程站博士后. 现任哈尔滨工业大学教授, 研究领域为鲁棒控制, 最优控制, 自适应控制和机器人焊接及智能控制相关的理论及其应用方向.

吴林 1935 年生, 哈尔滨工业大学教授, 博士生导师. 1959 年毕业于哈尔滨工业大学焊接专业, 现任中国焊接学会副理事长. 研究领域为机器人焊接及焊接自动化的相关领域.

张铃 1935 年生, 哈尔滨工业大学教授. 1959 年毕业于哈尔滨工业大学自动控制专业. 研究领域为计算机控制, 机器人及智能控制等相关领域.

张福恩 1936 年生, 哈尔滨工业大学教授, 博士生导师. 1961 年毕业于哈尔滨工业大学自动控制专业. 研究领域为控制系统设计, 最优控制, 鲁棒控制和计算机控制等相关领域.

百人计划招聘指南

学科领域: 系统科学

对人选的具体要求: 从事系统科学研究, 在控制理论、运筹学和统计学等方面有深厚的功底, 掌握系统科学发展动态, 已在系统科学的某些领域做出了具有国际影响的研究成果, 并具有综合解决复杂问题的能力和良好的学科组织能力.

引进单位及简介: 系统科学研究所(北京)

该所是以系统科学及有关的交叉学科为主的科研机构, 以系统运筹与管理、系统控制、统计与计算、机器证明及若干的数学近代分支为主要研究领域, 兼顾横向研究任务, 科研环境良好, 学术气氛浓厚.

说 明:

1. 申报者需具有博士学位, 年龄一般在 40 周岁以下(对急需和特别优秀者年龄可适当放宽.)

2. 申报者可直接向招聘单位报名.

单 位: 中国科学院系统科学研究所人事处 100080

地 址: 北京中关村南四街甲一号

联系电话: 010-62553063 **FAX:** 010-2568364

联 系 人: 田秋实 张月田

3. 报名截止时间: 1996 年 7 月 30 日.