

用于非线性动力系统控制问题的 自组织神经网络自适应方法¹⁾

王正志

(国防科技大学自控系, 长沙 410073)

摘要

本文提出一种用自组织自学习自适应思想解决非线性动力系统控制问题的新方法。在每个小区域(感受野), 可以把非线性系统近似展开为线性, 由神经元执行控制。各神经元的凝视点、感受野和功能由自组织自学习自适应方法进行调节。大量仿真结果验证了本方法的正确性和实用性。

关键词: 非线性系统, 自组织神经网络, 自适应控制

一、自组织过程

在非线性动力控制系统

$$\mathbf{x}_{t+1} = f(\mathbf{x}_t, \dots, \mathbf{x}_{t-n}, \mathbf{u}_t, \dots, \mathbf{u}_{t-m}) \quad (1)$$

中, 矢量 \mathbf{x}_t 是状态, \mathbf{u}_t 是控制。为了决定控制量 \mathbf{u}_t , 需要求出(1)式的逆函数

$$\mathbf{u}_t = g(\mathbf{x}_{t+1}, \mathbf{x}_t, \dots, \mathbf{x}_{t-n}, \mathbf{u}_{t-1}, \dots, \mathbf{u}_{t-m}). \quad (2)$$

为了简化符号, 记 $\mathbf{u} = \mathbf{u}_t$,

$$\mathbf{w} = \{\mathbf{x}_{t+1}^T, \mathbf{x}_t^T, \dots, \mathbf{x}_{t-n}^T, \mathbf{u}_{t-1}^T, \dots, \mathbf{u}_{t-m}^T\}^T. \quad (3)$$

其中上标 T 表示转置。于是(2)式化简记为

$$\mathbf{u} = g(\mathbf{w}). \quad (4)$$

在(1)和(4)式中, f 和 g 是相当复杂的非线性函数, 在实际控制中经常是未知的, 要用实际系统的输入输出测量数据, 通过自组织学习找出 \mathbf{u} 和 \mathbf{w} 之间的非线性函数关系(4)式。

把式(4)在 \mathbf{w}_s 处展开为 Taylor 级数, 并只取前两项,

$$\mathbf{u} = \mathbf{u}_s + A_s(\mathbf{w} - \mathbf{w}_s). \quad (5)$$

其中 \mathbf{u}_s 和 A_s 分别为零阶和一阶系数, 分别为矢量和矩阵。很明显, 用线性函数(5)表示非线性函数(4), 对于整个 W 空间, 精度不会高。所以把整个 W 空间划分为许多小区域,

本文于 1991 年 7 月 3 日收到。

1) 国家自然科学基金资助课题。

在每个小区域 F_r 上, 取一个代表点 w_r , 把这个小区域上的非线性函数(4)展开为

$$u = u_r + A_r(w - w_r), \quad w \in F_r. \quad (6)$$

工作空间 W 的区域划分按相竞原则进行。用 r 表示整数矢量, 其维数由被控对象的物理本质而定, 用 r 表示每个神经元在神经网络阵列中所处的位置。第 r 个神经元所负责的区域是 F_r , 神经元的注视中心点是 w_r 。在工作空间 W 中引入范数 $\|\cdot\|_R$ 。各神经元的责任区域由相竞原则划分。第 s 神经元责任区域 F_s 为

$$F_s = \{w \in W \mid \|w - w_s\|_R \leq \|w - w_r\|_R, \forall r\}. \quad (7)$$

若工作状态 w 落入区域 F_s , s 神经元就开始工作, 它的功能是按(5)由输入 w 输出控制量 u , 用以控制整个非线性动力系统。由于采用分区包干的办法, 使得用一组线性函数(6)对于整体非线性函数(4)的逼近精度大为提高, 从而使得控制精度大为提高。神经元 r 的注视中心 w_r , 以及它的功能系数 u_r 和 A_r , 按自组织原则进行安排。基本思想是, 把注视中心相邻和功能相近的各神经元安排到相邻的位置上。所以引入 r 神经元和 s 神经元的距离 $\|r - s\|$, 用诱导神经网络的拓扑。

为了应用到工程实际中, 可不用非线性系统的数学显式(1)和(2), 而使用系统在运行时输入输出的实际测量数据, 对各神经元的注视中心和功能系数进行自组织学习和自适应调整,

$$w_r(t+1) = w_r(t) + \varepsilon(t)h_{rs}(t)(w^*(t) - w_r(t)), \quad (8)$$

$$A_r(t+1) = A_r(t) + \varepsilon'(t)h'_{rs}(t)(A_s^*(t) - A_r(t)), \quad (9)$$

$$u_r(t+1) = u_r(t) + \varepsilon'(t)h'_{rs}(t)(u_s^*(t) - u_r(t)). \quad (10)$$

这里 $w^*(t)$ 是新出现的状态, 也就是要使系统达到的目标状态。比较 $w^*(t)$ 与各神经元 r 的注视中心 $w_r(t)$, 找出 $w^*(t)$ 落在哪个区域内。为确切, 可认为 $w^*(t)$ 落入区域 F_s 内, 于是有(8)~(10)式。值得注意的是, 不仅对 s 神经元的参数进行扫新, 而且对所有神经元 r 的参数均进行扫新, 只是扫新程度受到 $h_{rs}(t)$ 和 $h'_{rs}(t)$ 的影响。

在扫新前, 要对处在 F_s 状态区域内的实际系统做两次测量。

第一次测量。设 $\bar{u}_s(t)$ 为 $u_s(t)$ 附近的一个矢量。用 $\bar{u}_s(t)$ 控制后, 实际系统(1)将运行到新的状态 w_i 。这个新状态用测量得到, 而不是用(1)式计算, 因为假定不知(1)式的显式。

然后进行第二次测量。用 $u_s(t) + A_s(t)(w^*(t) - w_s(t))$ 作控制, 实际系统(1)运行到新状态 w_f , w_f 将由实际测量得到, 而不必用(1)式计算。

由这两个测量可确定(9),(10)式中的 $A_s^*(t)$ 和 $u_s^*(t)$ 。

$$A_s^*(t) = A_s(t) + [A_s(t)(w^*(t) - w_s(t) - \Delta w) + u_s(t) - \bar{u}_s(t)]\Delta w^T \|\Delta w\|^{-2}, \quad (11)$$

$$u_s^*(t) = \bar{u}_s(t) + A_s^*(t)(w_f(t+1) - w_i), \quad (12)$$

$$\Delta w = w_f - w_i. \quad (13)$$

在(8)~(10)式中, $h_{rs}(t)$ 和 $h'_{rs}(t)$ 分别表示 r 神经元和 s 神经元的注视中心和性能系数在自组织过程中的相互影响, 可有多种取法, 可取为

$$h_{rs}(t) = \exp(-\|r - s\|^2/\sigma^2(t)), \quad (14)$$

$$h'_{rs}(t) = \exp(-\|r - s\|^2/\sigma'^2(t)), \quad (15)$$

$$\sigma(t) = \sigma_0 e^{-\alpha t}, \quad \sigma'(t) = \sigma'_0 e^{-\alpha' t}. \quad (16)$$

另外, $\varepsilon(t)$ 和 $\varepsilon'(t)$ 为新息在扫新过程中的作用大小, 可取为如下形式:

$$\varepsilon(t) = \varepsilon_0 e^{-\beta t}, \quad \varepsilon'(t) = \varepsilon'_0 e^{-\beta' t}. \quad (17)$$

二、动态过程的自适应控制

使用神经网络, 一般要经过两个阶段。第一阶段是学习阶段, 由于不是正式使用, 所以测试信号和状态可有较大的随意性。第二阶段才是用神经网络对实际系统进行实时控制, 但这时自组织和性能系数扫新已停止, 仅用(5)式计算控制量, 故计算量很小。

本节将给出一种自适应控制方法, 即把上述两个阶段合并起来, 实现实时边学习边控制。要做到这点, 困难在于, 上节曾要求在两个不同的控制下进行两个测量。而在实时控制中只能一个控制一个测量地交替进行。

为了克服这个困难, 在进行自适应控制之前, 先对各区域 F_s 用 $u_s(0)$ 分别进行控制, 测出各个对应的 w_i , 并贮存在数据库里, 作为各区域中第一个控制和测量的原始资

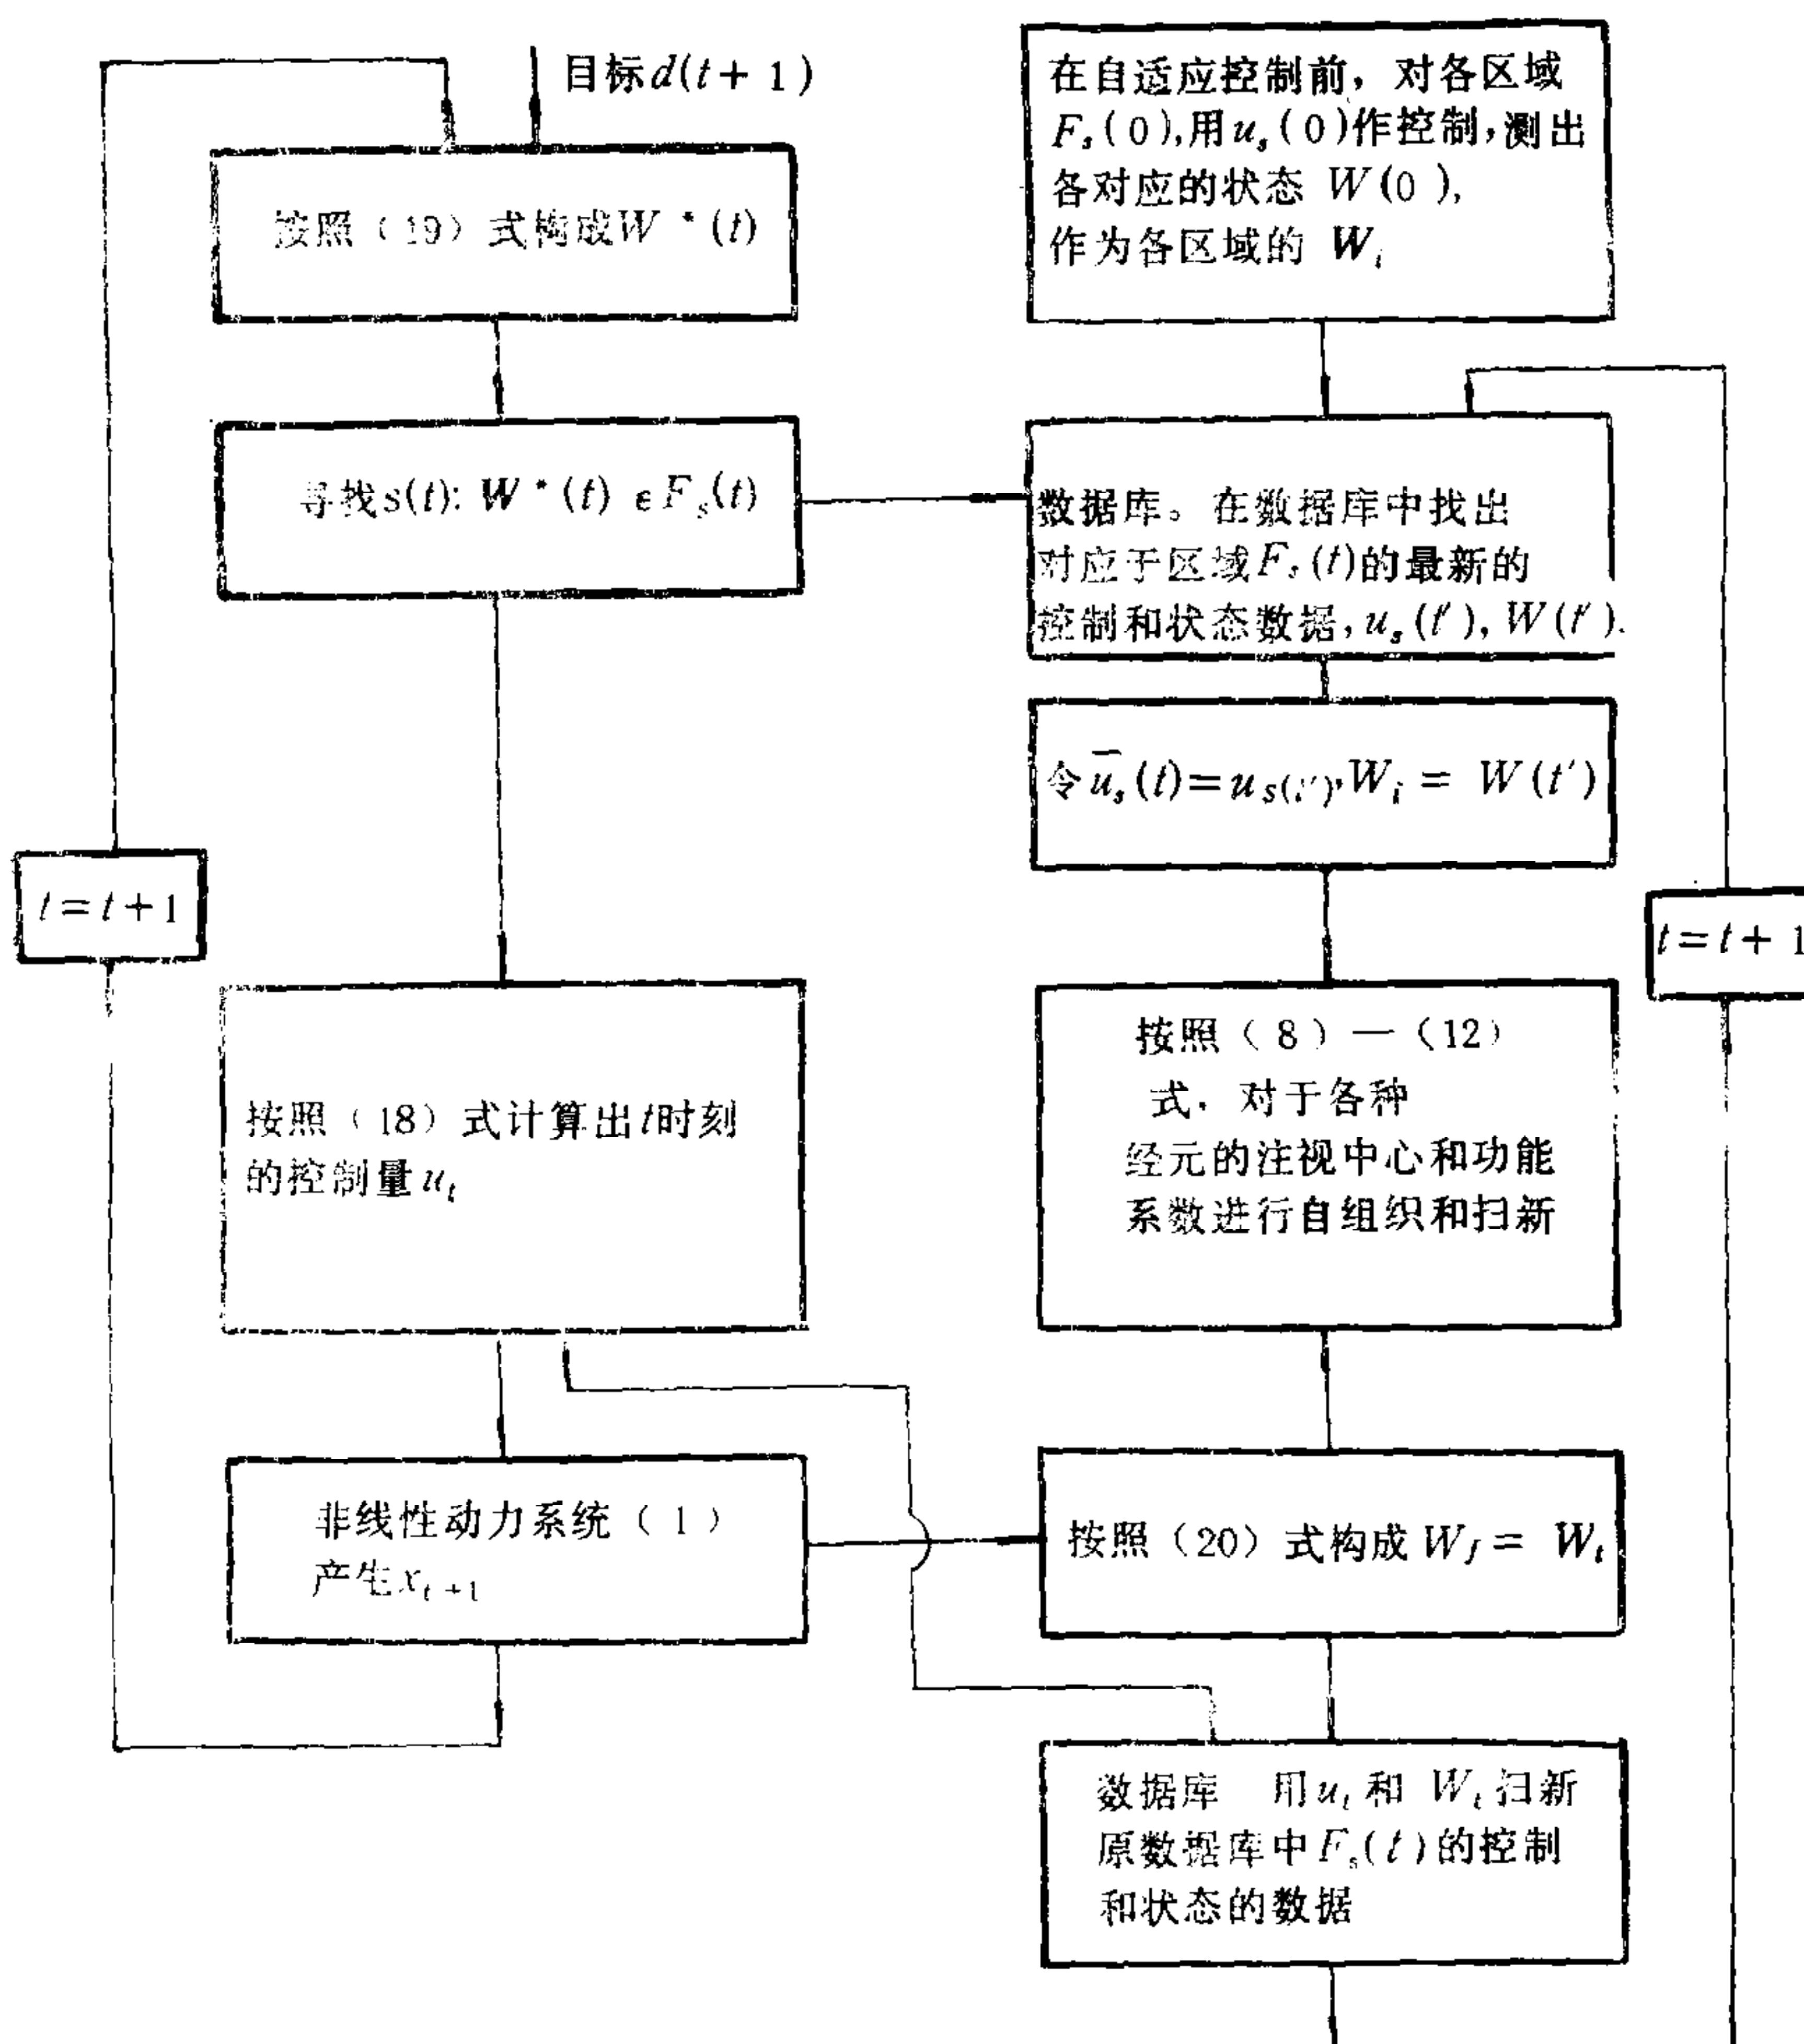


图1 非线性动力系统的神经网络自适应控制框图

料。在自适应控制实时进行时，仅用控制量

$$\bar{u}_t = u_t(t) + A_t(t)(w^*(t) - w_t(t)) \quad (18)$$

作为 t 时刻的实际控制。这里

$$w^*(t) = \{\mathbf{d}_{t+1}^T, \mathbf{x}_t^T, \dots, \mathbf{x}_{t-n}^T, \mathbf{u}_{t-1}^T, \dots, \mathbf{u}_{t-m}^T\}^T. \quad (19)$$

其中 \mathbf{d}_{t+1} 是欲使 \mathbf{x}_{t+1} 达到的目标。在 \bar{u}_t 控制下非线性系统(1)达到 \mathbf{x}_{t+1} 状态，测量出来后，取

$$w_t = \{\mathbf{x}_{t+1}^T, \mathbf{x}_t^T, \dots, \mathbf{x}_{t-n}^T, \mathbf{u}_{t-1}^T, \dots, \mathbf{u}_{t-m}^T\}^T. \quad (20)$$

由此看出，由于把预先存贮在数据库里的 $u_s(0)$ 作为第一次控制 $\bar{u}_s(t)$ ，其相应状态作为第一个测量 w_s ，从而在按(8)–(12)式进行自组织学习时，只要用(18)式的控制和相应的测量(20)式的 w_t 即可。而不必同时进行两个控制和两个测量。

为了防止在自组织过程中各区域变化导致数据库中的 $u_s(0)$ 和 w_s 失效，应该用最新落入 F_s 中的控制和状态不断地扫新数据库中的 $u_s(0)$ 和 w_s 。

这样，我们用自组织自学习自适应方法解决了非线性动力系统跟踪目标的实时控制问题。总框图如图 1 所示。

三、仿 真 结 果

例 1. 非线性系统

$$x_{t+1} = \text{th}(x_t) + (x_t + 1)u_t,$$

目标 d_{t+1} 为方波。采用由 8×8 个神经元组成的二维神经网络控制，其参数为

$$\sigma_0 = \sigma'_0 = 0.65, \alpha = \alpha' = 1.5 \times 10^{-5}, \varepsilon_0 = \varepsilon'_0 = 4 \times 10^{-3}, \beta = \beta' = 1 \times 10^{-3}.$$

仿真结果如图 2 所示。

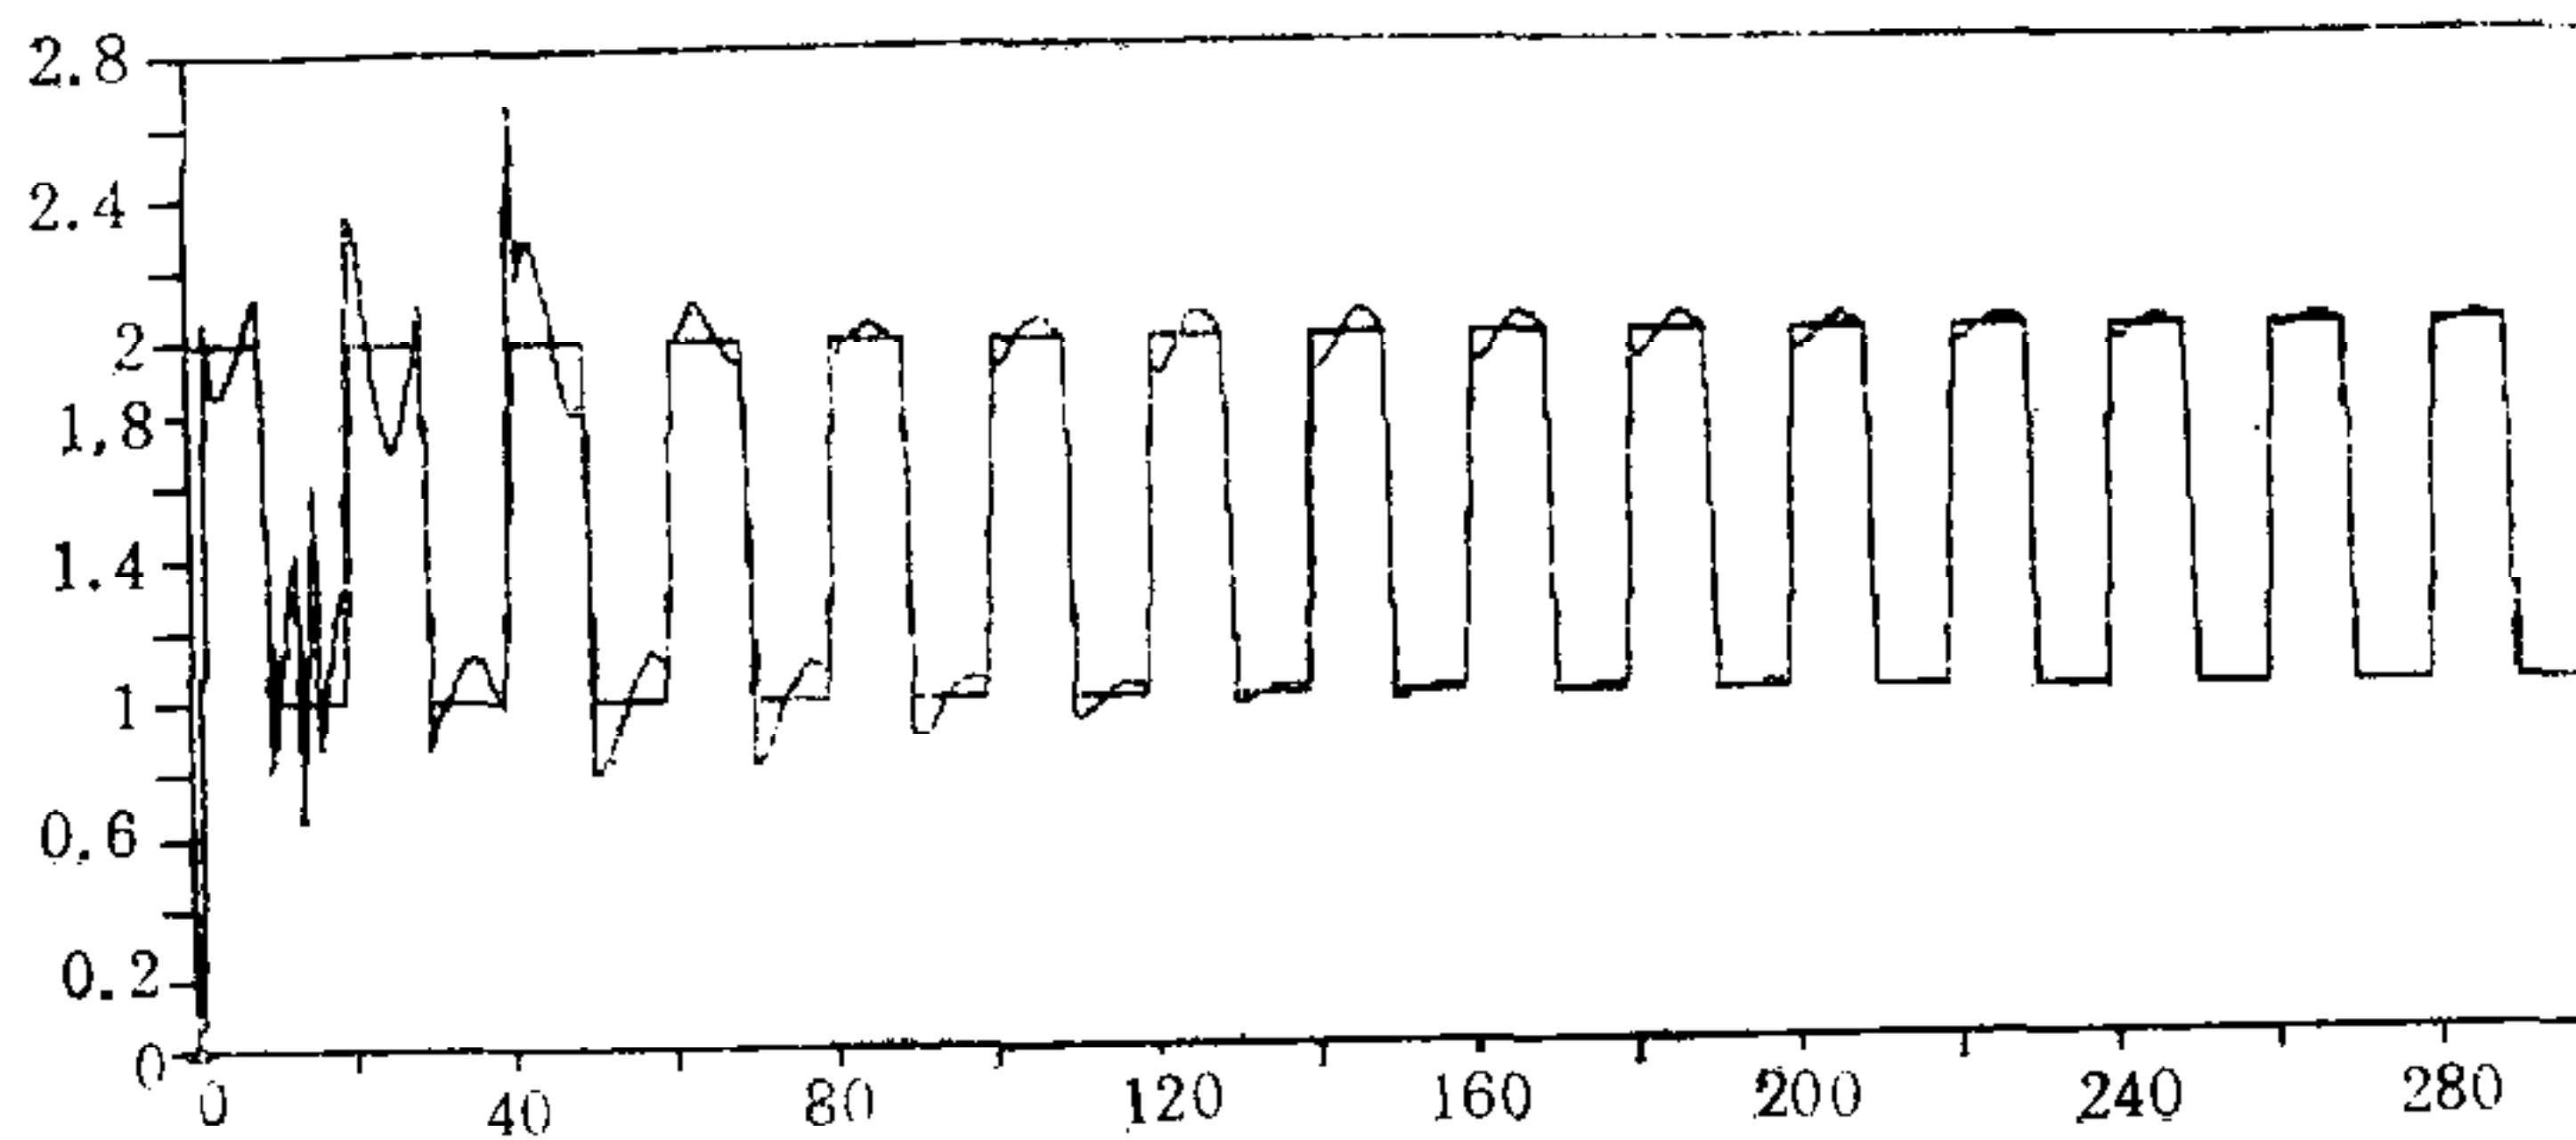


图 2 例 1 仿真结果

例 2. 温度为 $t_1 = 80^\circ\text{C}$ 的流体，其流量控制为 u_1 。另一温度为 $t_2 = 25^\circ\text{C}$ 的流体，其流量控制为 u_2 。这两个流体注入搅拌箱内得温度为 T 的液体，并通过管道流出。记搅拌箱内液面高度为 H ，可以得到 H 和 T 的非线性动力方程为

$$H_{k+1} = H_k - aH_k^{1/2} + b_1u_1 + b_2u_2,$$

$$T_{k+1} = T_k + c_1(t_1 - T_k)H_k^{-1}u_1 + c_2(t_2 - T_k)H_k^{-1}u_2.$$

设控制目标为 $H = 2\text{m}$, $T = 40^\circ\text{C}$ 。采用 8×8 个神经元组成的二维神经网络控制，其参数为

$$\sigma_0 = 0.4, \alpha = 4 \times 10^{-3}, \varepsilon_0 = 0.1, \beta = 3 \times 10^{-4},$$

$$\sigma'_0 = 0.03, \alpha' = 4 \times 10^{-4}, \varepsilon_0 = 0.1, \beta = 3 \times 10^{-4}.$$

仿真结果见图 3(a) 和图 3(b).

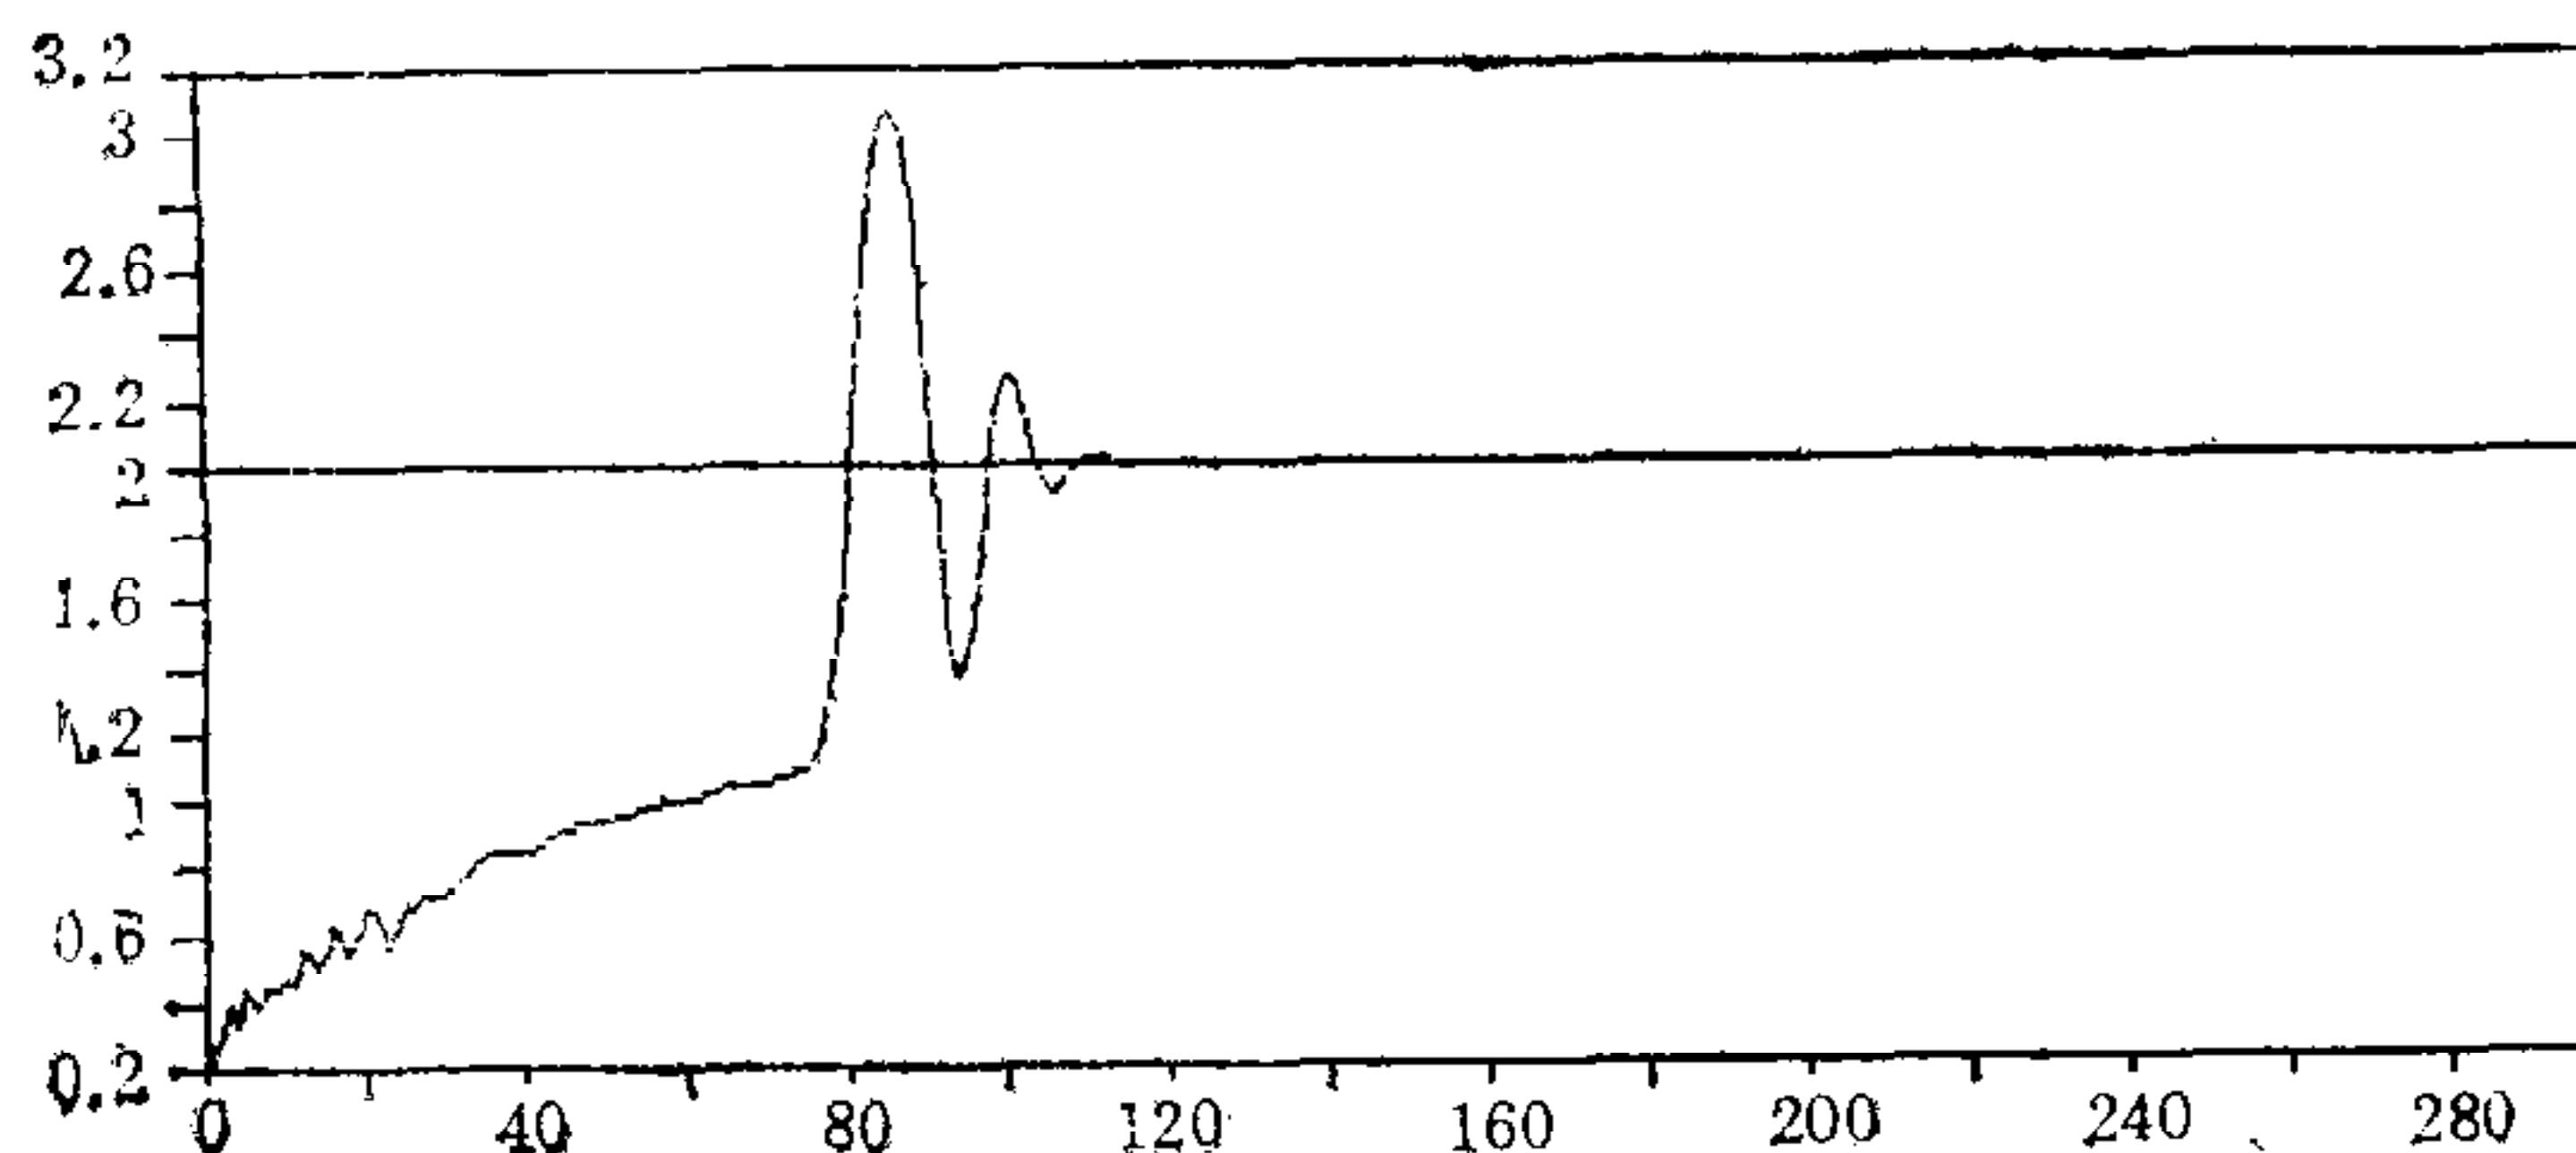


图 3(a) 液面高度 H

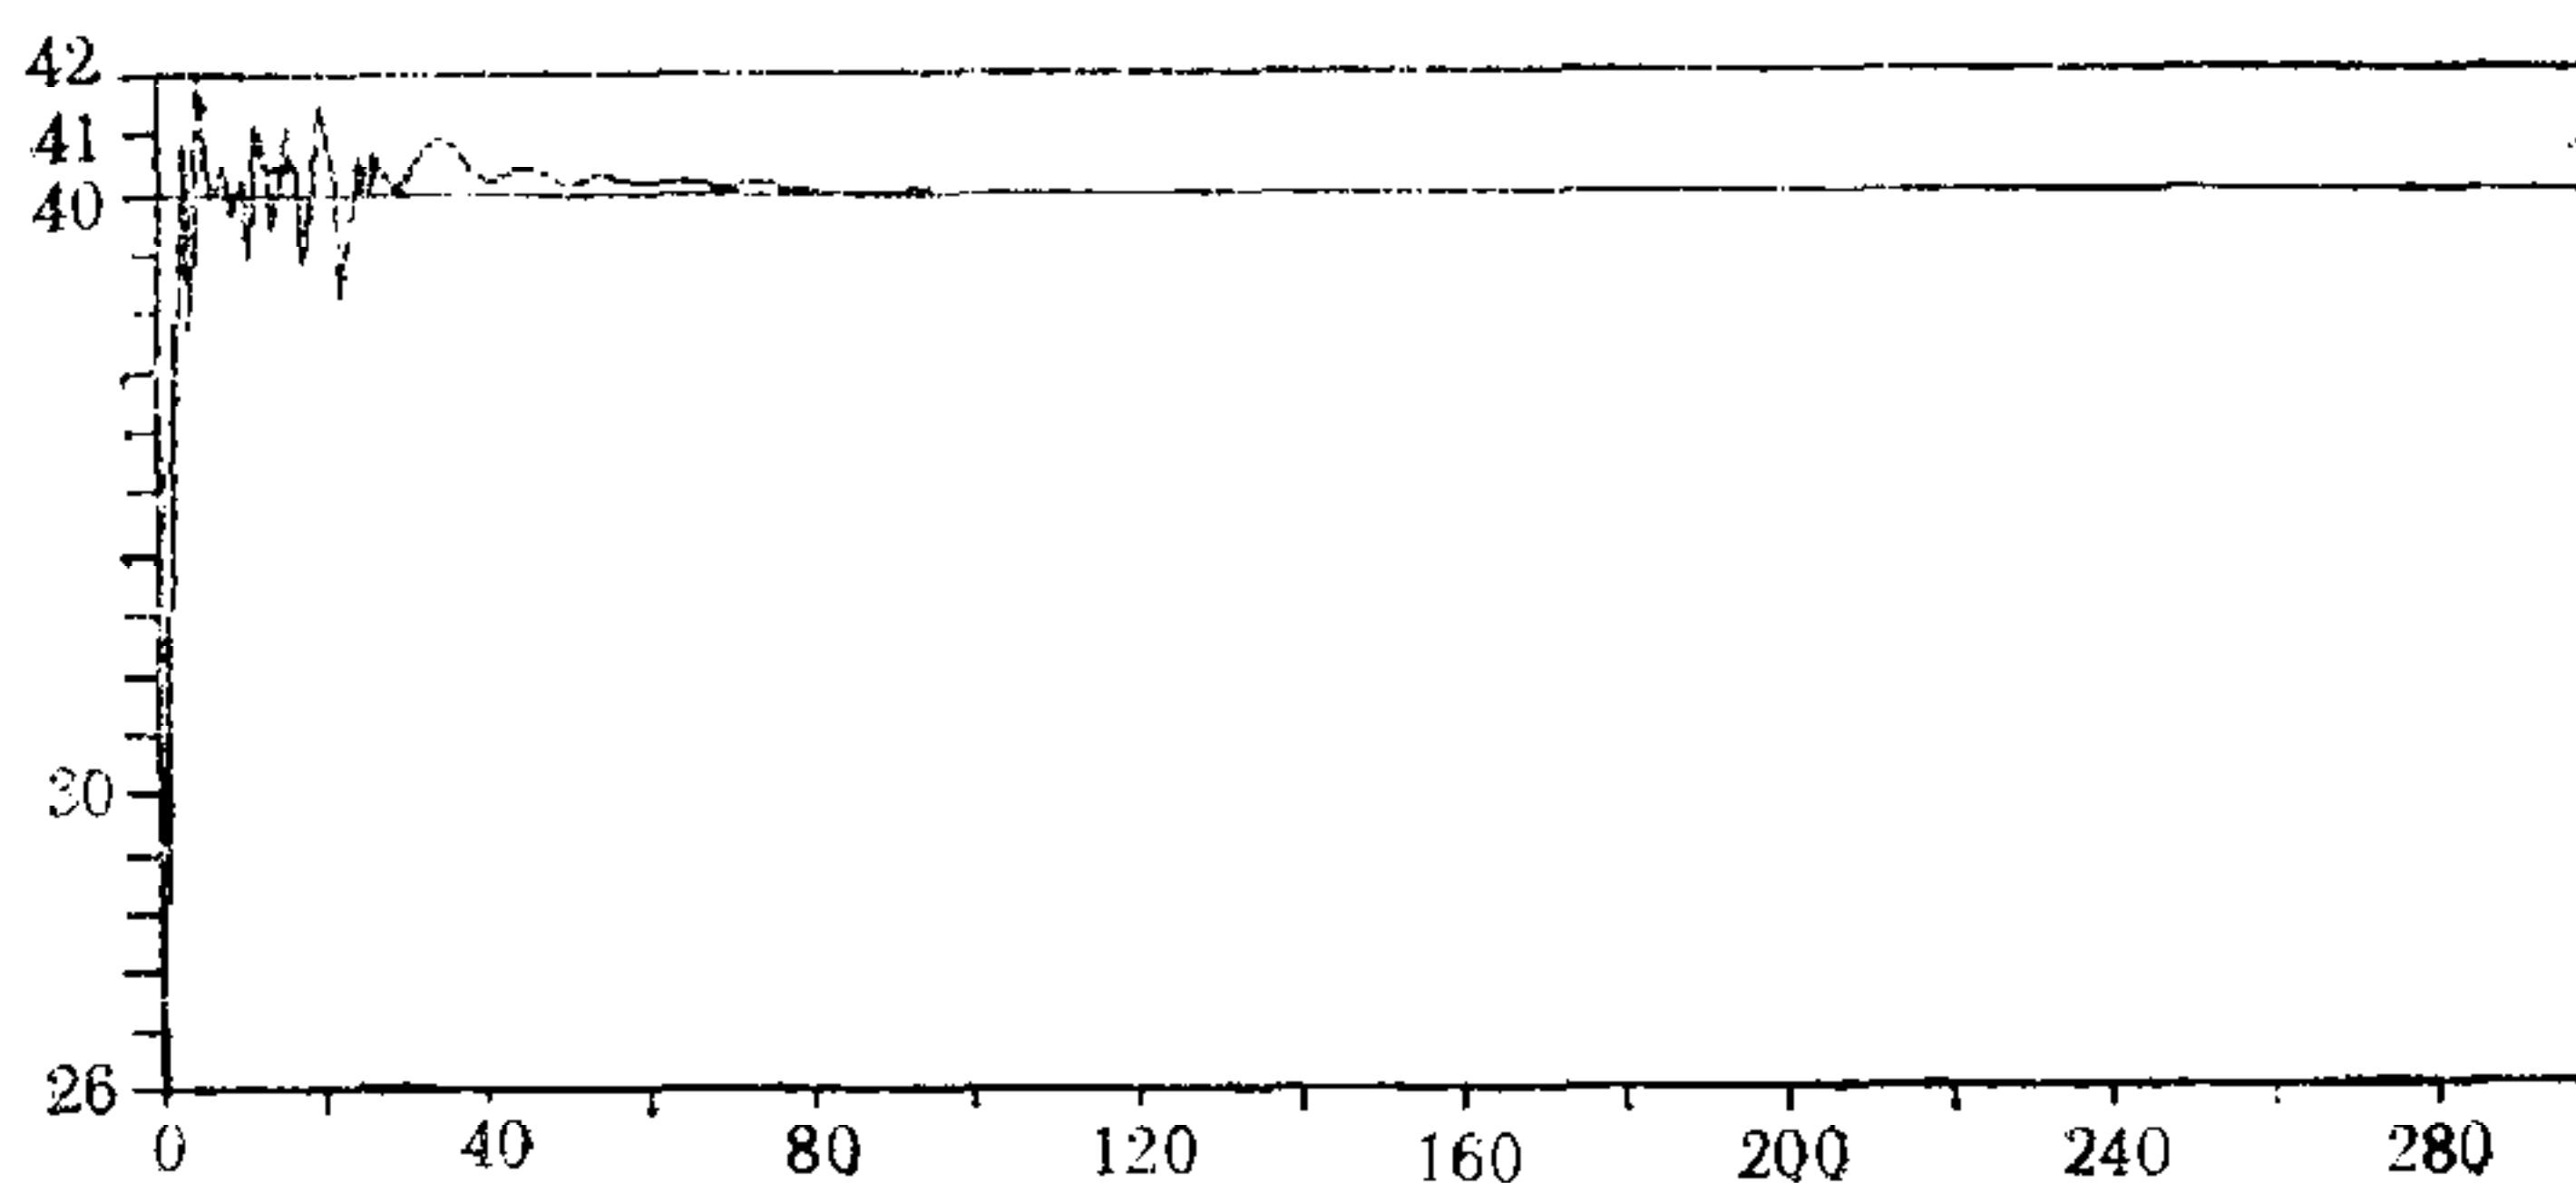


图 3(b) 混合液温度 T

四、讨 论

(1) 本文将分区划块和自组织方法应用到非线性动力系统控制问题上, 探索了非线性动力系统自适应控制的新途径。仿真实例验证了本文方法的正确性和实用性。

(2) 表面上看, 本文方法对于多维高阶的复杂动力系统将会遇到指数爆炸问题。由(3)式知工作空间 W 是 $(m+n+2)d$ 维空间, 这里假设 x_i 和 u_i 具有相同的维数 d 。如果把工作空间的每一维边界划分为 k 段, 则整个工作空间将会划分为 $k^{(m+n+2)d}$ 个区域。这样将需要具有 $k^{(m+n+2)d}$ 个神经元的巨大神经网络去控制, 这就导致了严重的指数爆炸问题。

但实际上将要乐观得多。本文在第一节已强调过神经网络阵列 \mathbf{r} 的维数 d , 决定于被控对象的物理本质, 在许多情形下 $d \ll (m+n+2)d$ 。值得注意的是, 如果直接限制神经网络中神经元的个数, 经过自组织, 各神经元的注视中心会移动到出现频率高的典型工作状态, 从而增加了神经元的工作效率。所以自组织可以大大减少所需要的神经元的数目。这就解释了为什么在例 2 中工作空间是四维, 而仅用二维神经网络就可以得到理想的控制。

参 考 文 献

- [1] Kohonen, T., The Self-organizing Map, Proceeding of IEEE, 78(1990), (9), 1464—1479.
- [2] Matinetz, T.M., Ritter, H.J., Schulten, K.J., 3D Neural Net for Learning Visuomotor Coordination of a Robot Arm, Proceedings of IJCNN, (1989) II351—356.

SELF-ORGANIZING NEURAL NETWORK ADAPTIVE METHOD FOR CONTROL PROBLEMS OF NONLINEAR DYNAMIC SYSTEMS

WANG ZHENGZHI

(Department of Automatic Control National University
of Defence Technology Changsha, Hunan 410073 China)

ABSTRACT

In this paper a new self-organizing, learning and adaptive method to solve the control problems of nonlinear dynamic systems is proposed. In each small regions (receptive fields), a nonlinear system can be expressed as a linear one and controlled by neurons. The gazing points, receptive fields and control functions of each neurons are regulated in self-organizing learning and adapting way. Several computer simulation examples verify the correctness and feasibility of this method.

Key words: nonlinear systems; self-organizing neural network; adaptive control.



王正志 1945 年生于上海。1967 年毕业于哈尔滨军事工程学院自动控制专业。1981 年至 1984 年在美国 Rice 大学电气工程系进修，并获得博士学位。现任国防科技大学自动控制系控制理论及应用教研室主任及教授。研究领域为 H_∞ 控制、自适应控制、经济控制、神经网络及智能机器人。