



# 基于 T-S 模型的稳定自适应 FNN 控制器的设计<sup>1)</sup>

马 勇 杨煜普 许晓鸣 张卫东

(上海交通大学智能控制研究室 上海 200030)

(E-mail: my@xinfel.com)

**摘要** 对一类不确定非线性系统,提出一种基于 T-S 模型的自适应 FNN 控制器。首先用权值固定的 FNN 作为非线性系统的近似模型,然后再应用自适应 FNN 逼近建模误差,并引入滑模项增加控制器的鲁棒性。通过稳定性理论设计自适应律,保证了系统的全局稳定,跟踪误差收敛到零。

**关键词** 非线性系统,模糊神经网络,自适应控制,稳定性。

## DESIGN OF STABLE ADAPTIVE FNN CONTROLLER USING T-S MODEL

MA Yong YANG Yu-Pu XU Xiao-Ming ZHANG Wei-Dong

(Intelligent Control Research Institute, Shanghai Jiaotong University, Shanghai 200030)

(E-mail: my@xinfel.com)

**Abstract** An adaptive FNN control scheme for a class of unknown nonlinear systems is presented. The control architecture first employs two fixed structural FNNs to approximate plant uncertainties, then uses additional parallel adaptive FNNs to compensate for the modeling errors. A sliding mode term is introduced to improve robustness. Based on the Lyapunov theory, the adaptation laws to tune on-line both the membership functions and weighting factors are derived. Therefore, the closed-loop system is stable with the tracking error converging to zero.

**Key words** Nonlinear systems, fuzzy-neural network, adaptive control, stability.

## 1 引言

Takagi 和 Sugeno 提出了一种用于多维模糊推理方法,本质非线性,易于表达复杂系

1) 国家自然科学基金资助项目。

统的动态特性的模型,称之为 T-S 模型<sup>[1]</sup>. 可以用很少的规则以很高的精度逼近一个高度非线性的系统. 模糊神经网络融合了模糊逻辑的推理能力与神经网络的学习能力,具有更好的全局逼近能力. 本文把二者结合起来,给出一种基于 T-S 模型的稳定的自适应 FNN 控制器(Adaptive Fuzzy Neural Network Controller, AFNNC),对权值固定的 FNN 估计不确定系统存在的建模误差,利用 AFNNC 作进一步地修正,并且通过引入滑模项增加系统的鲁棒性,使本文设计的控制器不仅具有较好的控制性能,而且保证了系统的闭环稳定性.

## 2 基于 T-S 模型的 AFNNC 设计

### 2.1 基于 T-S 模型的 FNN 设计

考虑非线性系统

$$x^{(n)} = f(x, \dot{x}, \dots, x^{(n-1)}) + g(x, \dot{x}, \dots, x^{(n-1)})u + d(x, \dot{x}, \dots, x^{(n-1)}, t), \quad (1)$$

其中  $f$  和  $g$  是光滑未知的非线性函数,  $u \in R$  为系统的输入,  $d$  是有界干扰.

设有界参考输入  $r = [x_m, \dot{x}_m(t), \dots, x_m^{(n-1)}(t)]$ , 定义跟踪误差  $e = (e_1, e_2, \dots, e_n)^T = r - x$ , 其中状态向量  $x = (x, \dot{x}, \dots, x^{(n-1)})^T$ . 控制目标是设计控制器使跟踪误差收敛到零的一个邻域内.

**假设1.** 存在非负函数  $\beta(x), D(x)$ , 在可控集  $\Omega_x \in R^n$  上满足

$$0 \leq \beta(x) \leq g(x), \quad |d(x, t)| \leq D(x).$$

首先用一种权值固定的基于 T-S 模型的 FNN 逼近不确定  $f, g$ , 相应的推理规则为  $R^j$ : If  $x_1$  is  $A_1^j$  and  $\dots$   $x_n$  is  $A_n^j$ , Then  $y = \theta_0^j + \theta_1^j h_1(x) + \dots + \theta_r^j h_r(x)$ ,  $j = 1, 2, \dots, M$ ,  
(2)

其中  $x = (x_1, x_2, \dots, x_n)^T = (x, \dot{x}, \dots, x^{(n-1)})^T$  是输入变量,  $A_i^j$  是相应模糊集,  $\theta_k^j$  ( $k = 1, 2, \dots, r$ ) 是可调参数,  $h_k(x)$  为任意给定的 Lipschitz 函数. FNN 结构如图1所示, 对规则乘积推理、重心非模糊化, 网络输出可以表示为

$$y = \sum_{j=1}^M v_j (\theta_0^j + \theta_1^j h_1(x) + \dots + \theta_r^j h_r(x)), \quad (3)$$

其中  $v_j = \frac{w_j}{\sum_{j=1}^M w_j}$ ,  $w_j = A_1^j(x) A_2^j(x) \dots A_n^j(x)$ . 记

$$H(x) = \begin{bmatrix} 1 \\ h_1(x) \\ \vdots \\ h_r(x) \end{bmatrix}, \quad A^T = \begin{bmatrix} \theta_0^1 & \theta_1^1 & \dots & \theta_r^1 \\ \theta_0^2 & \theta_1^2 & \dots & \theta_r^2 \\ \dots & \dots & \dots & \dots \\ \theta_0^M & \theta_1^M & \dots & \theta_r^M \end{bmatrix}, \quad V = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_M \end{bmatrix},$$

则有

$$y(x|A) = H(x)^T A V. \quad (4)$$

设逼近  $f$  和  $g$  的权值固定的 FNN 输出分别为  $y_f(x|\bar{A}_f)$  和  $y_g(x|\bar{A}_g)$ ,  $\bar{A}_f$  与  $\bar{A}_g$  分别是相应 FNN 由训练数据离线学习得到的权值, 具体的算法可参见文献[1].

### 2.2 基于 T-S 模型的 AFNNC 设计

用上节权值固定的 FNN 逼近  $f$  和  $g$ , 由于模型不完全匹配存在着建模误差. 设建模

误差分别为

$$\varepsilon_f(\mathbf{x}) = f(\mathbf{x}) - y_f(\mathbf{x} | \bar{A}_f), \varepsilon_g(\mathbf{x}) = g(\mathbf{x}) - y_g(\mathbf{x} | \bar{A}_g). \quad (5)$$

为了补偿建模误差,增强控制器处理系统变化的能力,用结构相似的 AFNN 通过在线学习来补偿建模误差。考虑到推理规则中隶属函数的选取对控制性能的好坏起着举足轻重的影响,设计自适应律在线调整权值的同时,隶属函数的参数也随着控制目标自动调整。

设自适应 FNN 对  $\varepsilon_f(\mathbf{x}), \varepsilon_g(\mathbf{x})$  的逼近输出分别为

$$y_f(A_f, V_f) = H(\mathbf{x})^T A_f V_f, \quad y_g(A_g, V_g) = H(\mathbf{x})^T A_g V_g, \quad (6)$$

其中  $A_f, A_g$  是网络调节权值,  $V_f, V_g$  分别表示在线调节规则强度。

**约定1.** 为了得到调节参数的自适应律,将式(2)表示的规则库记为

If  $x_1$  is  $A_1(\mathbf{m}_1, \sigma_1)$ ,  $x_2$  is  $A_2(\mathbf{m}_2, \sigma_2)$ , ...,  $x_n$  is  $A_n(\mathbf{m}_n, \sigma_n)$ , then  $y$  is  $(\theta_0, \theta_1, \dots, \theta_r)$ , 其中  $\mathbf{m}_i = (m_{i1}, \dots, m_{ij}, \dots, m_{iM})^T$ ,  $\sigma_j = (\sigma_{i1}, \dots, \sigma_{ij}, \dots, \sigma_{iM})^T$  ( $i=1, 2, \dots, n$ ) 为采用高斯函数的模糊子集  $A_i = [A_i^1, A_i^2, \dots, A_i^M]^T$  的均值和方差,  $\theta_k = [\theta_k^1, \theta_k^2, \dots, \theta_k^M]^T$ ,  $k=0, 1, \dots, r$ .

令调节参数向量

$$\varphi = [\varphi_0, \varphi_1, \dots, \varphi_r], \quad (7)$$

其中  $\varphi_k = [\theta_k^1, \theta_k^2, \dots, \theta_k^M, m_{11}^k, \sigma_{11}^k, \dots, m_{1M}^k, \sigma_{1M}^k, \dots, m_{n1}^k, \sigma_{n1}^k, \dots, m_{nM}^k, \sigma_{nM}^k]^T$ ,  $k=0, 1, \dots, r$ .

**假设2.** 设  $\mathbf{x}, \varphi_f, \varphi_g$  分别满足,

$$\{\mathbf{x}: |\mathbf{x}| \leq M\}, \quad \Omega_f = \{\varphi_f | \text{tr}(\varphi_f^T \varphi_f) \leq M_f\}, \quad \Omega_g = \{\varphi_g | \text{tr}(\varphi_g^T \varphi_g) \leq M_g\},$$

其中  $M, M_f, M_g$  为设计参数. 则在可行域上分别存在的最优参数  $\varphi_f^*, \varphi_g^*$  满足

$$\sup_{|\mathbf{x}| \leq M} |\varepsilon_f(\mathbf{x} | \varphi_f^*) - \varepsilon_f(\mathbf{x})| = \delta_f, \quad \sup_{|\mathbf{x}| \leq M} |\varepsilon_g(\mathbf{x} | \varphi_g^*) - \varepsilon_g(\mathbf{x})| = \delta_g, \quad (8)$$

其中  $\delta_f$  和  $\delta_g$  是参数最优值的逼近误差的界, 这里仅要求逼近误差是有界的, 不要求其为任意小。

由式(6)和(8), 对  $\varepsilon_f(\mathbf{x}), \varepsilon_g(\mathbf{x})$  的最优逼近分别为

$$\varepsilon_f(\mathbf{x}) = \varepsilon_f(\mathbf{x} | \varphi_f^*) + E_f, \quad \varepsilon_g(\mathbf{x}) = \varepsilon_g(\mathbf{x} | \varphi_g^*) + E_g, \quad (9)$$

其中  $E_f, E_g$  是不确定的, 用来补偿逼近误差, 分别满足  $|E_f| \leq \delta_f$ ,  $|E_g| \leq \delta_g$ .

设自适应 FNN 的实际输出分别为  $\varepsilon_f(\mathbf{x} | \varphi_f)$  和  $\varepsilon_g(\mathbf{x} | \varphi_g)$ , 将式(9)展开为泰勒展式, 忽略高阶项, 可得自适应 FNN 对  $\varepsilon_f(\mathbf{x}), \varepsilon_g(\mathbf{x})$  的逼近误差. 简记  $\varepsilon_f(\mathbf{x}), \varepsilon_g(\mathbf{x})$  为  $\varepsilon$ ;  $(\frac{\partial \theta_{fk}}{\partial \varphi_{fk}})^T \varphi_{fk}$

和  $(\frac{\partial \theta_{gk}}{\partial \varphi_{gk}})^T \varphi_{gk}$  为  $(\frac{\partial \theta_k}{\partial \varphi_k})^T \varphi_k$ ;  $E_f, E_g$  为  $E$ . 则对于  $f, g$  都有

$$\tilde{\varepsilon}(\mathbf{x}) = \varepsilon(\mathbf{x}) - \varepsilon(\mathbf{x} | \varphi) = H(\mathbf{x})^T \begin{bmatrix} (\frac{\partial \theta_0}{\partial \varphi_0})^T (\varphi_0^* - \varphi_0) \\ (\frac{\partial \theta_1}{\partial \varphi_1})^T (\varphi_1^* - \varphi_1) \\ \vdots \\ (\frac{\partial \theta_r}{\partial \varphi_r})^T (\varphi_r^* - \varphi_r) \end{bmatrix} + E, \quad (10)$$

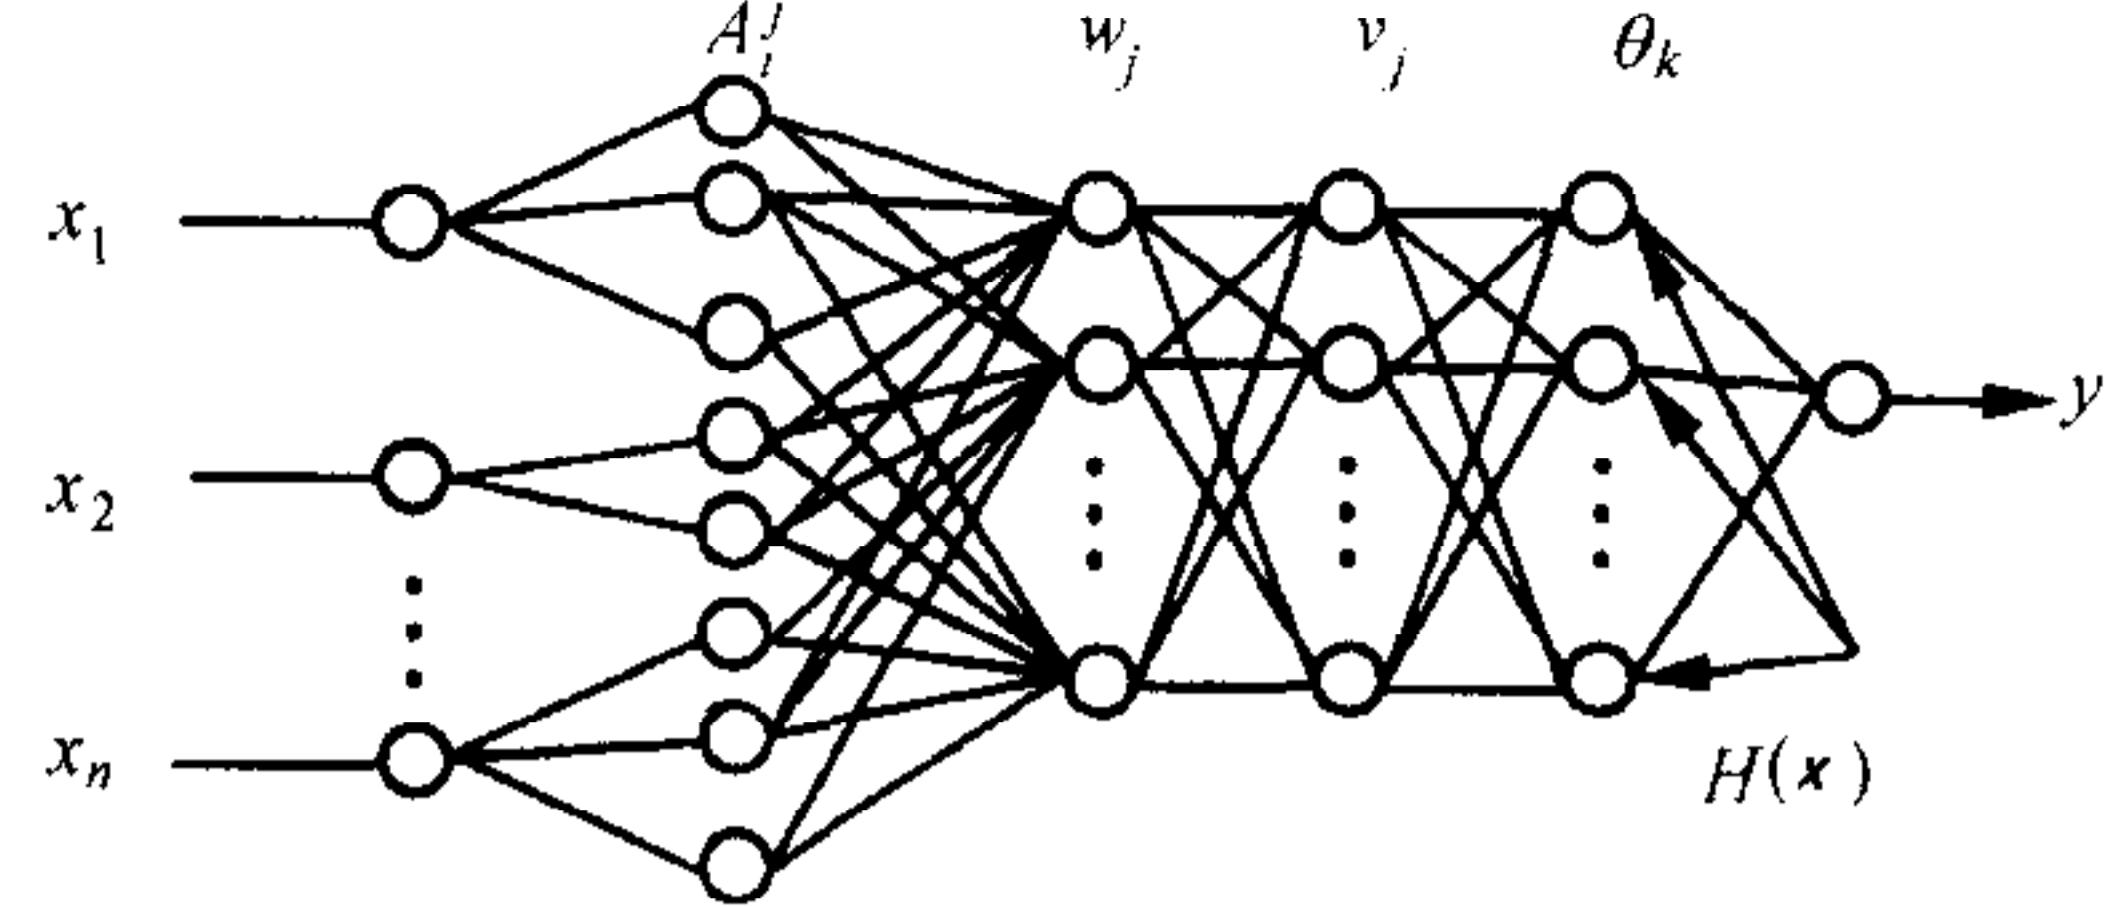


图1 基于 T-S 模型的 FNN 网络结构

$$\begin{aligned} \left(\frac{\partial \theta_k}{\partial \varphi_k}\right)^T \varphi_k = & \left[ \frac{\partial \theta_k}{\partial \theta_k^1}, \dots, \frac{\partial \theta_k}{\partial \theta_k^M}, \frac{\partial \theta_k}{\partial m_{11}^k}, \dots, \frac{\partial \theta_k}{\partial m_{1M}^k}, \frac{\partial \theta_k}{\partial \sigma_{11}^k}, \dots, \frac{\partial \theta_k}{\partial m_{n1}^k}, \frac{\partial \theta_k}{\partial \sigma_{n1}^k}, \right. \\ & \left. \dots, \frac{\partial \theta_k}{\partial m_{nM}^k}, \frac{\partial \theta_k}{\partial \sigma_{nM}^k} \right] \varphi_k, \end{aligned} \quad (11)$$

这里

$$\frac{\partial \theta_k}{\partial \theta_k^j} = \frac{\prod_{i=1}^n \mu_{A_i^j}(x)}{\sum_{j=1}^M \prod_{i=1}^n \mu_{A_i^j}(x)}, \quad \frac{\partial \theta_k}{\partial m_{ij}^k} = \frac{2(x_i - m_{ij}^k)(\theta_k^j - \theta_k)}{(\sigma_{ij}^k)^2 \sum_{j=1}^M \prod_{i=1}^n \mu_{A_i^j}(x_i)}, \quad (12)$$

$$\frac{\partial \theta_k}{\partial \sigma_{ij}^k} = \frac{2(x_i - m_{ij}^k)^2 (\theta_k^j - \theta_k) \prod_{i=1}^n \mu_{A_i^j}(x_i)}{(\sigma_{ij}^k)^3 \sum_{j=1}^M \prod_{i=1}^n \mu_{A_i^j}(x_i)}. \quad (13)$$

利用前向网络的误差反传算法,由式(12)和(13)有

$$\frac{\partial y}{\partial \theta_k^j} = h_k(x) \frac{\partial \theta_k}{\partial \theta_k^j}, \quad \frac{\partial y}{\partial m_{ij}^k} = \sum_{k=0}^r h_k(x) \frac{\partial \theta_k}{\partial m_{ij}^k}, \quad \frac{\partial y}{\partial \sigma_{ij}^k} = \sum_{k=0}^r h_k(x) \frac{\partial \theta_k}{\partial \sigma_{ij}^k}. \quad (14)$$

选择适当的  $\kappa = (\kappa_n, \kappa_{n-1}, \dots, \kappa_1)^T \in R^n$ , 使得  $h(s) = s^n + \kappa_1 s^{n-1} + \dots + \kappa_n$  的特征根在左半平面. 考虑到逼近误差和干扰的影响, 取控制律

$$u = u_c + u_s, \quad (15)$$

其中  $u_c = (y_g(x | \bar{A}_g) + \varepsilon_g(x | \varphi_g))^{-1} [y_m^{(n)} - y_f(x | \bar{A}_f) - \varepsilon_f(x | \varphi_f) + \kappa^T e]$  是自适应控制律, 控制  $u_s$  是用来补偿逼近误差和干扰的滑模控制项.

把式(15)代入到系统(1)中, 令  $\psi_k = \varphi_k^* - \varphi_k, k = 0, 1, \dots, r$ . 经过简单的运算可得误差

$$\dot{e} = \Lambda e - BH(x)^T \begin{bmatrix} \left(\frac{\partial \theta_{f0}}{\partial \varphi_{f0}}\right)^T \psi_{f0} \\ \left(\frac{\partial \theta_{f1}}{\partial \varphi_{f1}}\right)^T \psi_{f1} \\ \vdots \\ \left(\frac{\partial \theta_{fr}}{\partial \varphi_{fr}}\right)^T \psi_{fr} \end{bmatrix} - BH(x)^T \begin{bmatrix} \left(\frac{\partial \theta_{g0}}{\partial \varphi_{g0}}\right)^T \psi_{g0} \\ \left(\frac{\partial \theta_{g1}}{\partial \varphi_{g1}}\right)^T \psi_{g1} \\ \vdots \\ \left(\frac{\partial \theta_{gr}}{\partial \varphi_{gr}}\right)^T \psi_{gr} \end{bmatrix} u_c - B(g(x)) u_s + E_f + E_g u_c + d(x, t), \quad (16)$$

$$\text{其中 } \Lambda = \begin{bmatrix} 0 & 1 & 0 & \cdots & 0 \\ 0 & 0 & 1 & \cdots & 0 \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ -k_n & -k_{n-1} & -k_{n-2} & \cdots & -k_1 \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ 1 \end{bmatrix}.$$

滑模补偿控制项  $u_s$  取为

$$u_s = K \operatorname{sgn}(e^T P B), \quad (17)$$

这里  $K$  是滑模控制增益, 用来估计逼近误差和干扰的界, 有

$$K = \beta^{-1}(x) (|\hat{E}_f| + |\hat{E}_g| |u_c| + D(x)), \quad (18)$$

而  $P$  为满足 Lyapunov 方程的正定解

$$P \Lambda + \Lambda^T P = -Q, \quad (19)$$

$Q$  是任意正定矩阵,  $\hat{E}_f$  和  $\hat{E}_g$  分别是对  $E_f$  和  $E_g$  的估计界。通过自适应律在线估计  $\hat{E}_f$  和  $\hat{E}_g$  选择时变的增益  $K$ , 使它随时用略大于逼近误差和干扰的值保证系统的闭环稳定, 不仅保持了系统的鲁棒性, 而且使系统的颤动可以减到很弱。

为了满足设计参数  $M_f$  和  $M_g$ , 确保  $\varphi_{fk}$  和  $\varphi_{gk}$  在受限集内, 采用投影算法确定自适应律

$$\dot{\varphi}_{fk} = \begin{cases} -\gamma_{fk} \frac{\partial \theta_{fk}}{\partial \varphi_{fk}} H(\mathbf{x}) B^T P e, & \text{tr}(\varphi_f^\top \varphi_f) < M_f \text{ or } \text{tr}(\varphi_f^\top \varphi_f) = M_f, \frac{\partial \theta_{fk}}{\partial \varphi_{fk}} H(\mathbf{x}) B^T P e \geq 0, \\ P[-\gamma_{fk} \frac{\partial \theta_{fk}}{\partial \varphi_{fk}} H(\mathbf{x}) B^T P e], & \text{tr}(\varphi_f^\top \varphi_f) = M_f, \frac{\partial \theta_{fk}}{\partial \varphi_{fk}} H(\mathbf{x}) B^T P e < 0, \end{cases} \quad (20)$$

$$\dot{\varphi}_{gk} = \begin{cases} -\gamma_{gk} \frac{\partial \theta_{gk}}{\partial \varphi_{gk}} H(\mathbf{x}) B^T P e u_c, & \text{tr}(\varphi_g^\top \varphi_g) < M_g \text{ or } \text{tr}(\varphi_g^\top \varphi_g) = M_g, \frac{\partial \theta_{gk}}{\partial \varphi_{gk}} H(\mathbf{x}) B^T P e u_c \geq 0, \\ P[-\gamma_{gk} \frac{\partial \theta_{gk}}{\partial \varphi_{gk}} H(\mathbf{x}) B^T P e u_c], & \text{tr}(\varphi_g^\top \varphi_g) = M_g, \frac{\partial \theta_{gk}}{\partial \varphi_{gk}} H(\mathbf{x}) B^T P e u_c < 0, \end{cases} \quad (21)$$

这里  $\gamma_{fk} > 0, \gamma_{gk} > 0$  为学习率, 投影算子  $P[\cdot]$  定义见文献[2]。

逼近误差估计  $\hat{E}_f$  和  $\hat{E}_g$  的自适应律为

$$|\dot{\hat{E}}_f| = \eta_f |\mathbf{e}^\top P B|, |\dot{\hat{E}}_g| = \eta_g |\mathbf{e}^\top P B| |u_c|, \quad (22)$$

其中自适应率  $\eta_f > 0$  和  $\eta_g > 0$ 。

**定理1.** 考虑非线性系统(1), 其控制律由式(15)确定, 采用式(20)~(22)给出的自适应律, 则有 1)  $\text{tr}(\varphi_f^\top \varphi_f) \leq M_f, \text{tr}(\varphi_g^\top \varphi_g) \leq M_g, u \in L_\infty$ , 2)  $\lim_{t \rightarrow \infty} \mathbf{e}(t) = 0$ 。

证明. 1) 的证明与文献[3]类似, 下面证明2). 取 Lyapunov 函数

$$V = \frac{1}{2} \mathbf{e}^\top P \mathbf{e} + \frac{1}{2} \sum_{k=0}^r \frac{1}{\gamma_{fk}} \psi_{fk}^\top \psi_{fk} + \frac{1}{2} \sum_{k=0}^r \frac{1}{\gamma_{gk}} \psi_{gk}^\top \psi_{gk} + \frac{1}{2\eta_f} \tilde{E}_f^2 + \frac{1}{2\eta_g} \tilde{E}_g^2, \quad (23)$$

其中  $\tilde{E}_f = |E_f| - |\hat{E}_f|$  和  $\tilde{E}_g = |E_g| - |\hat{E}_g|$ . 对式(23)沿时间微分得

$$\begin{aligned} \dot{V} = & -\frac{1}{2} \mathbf{e}^\top Q \mathbf{e} - \mathbf{e}^\top P B \left[ \left( \frac{\partial \theta_{f0}}{\partial \varphi_{f0}} \right)^\top \psi_{f0}, \left( \frac{\partial \theta_{f1}}{\partial \varphi_{f1}} \right)^\top \psi_{f1}, \dots, \left( \frac{\partial \theta_{fr}}{\partial \varphi_{fr}} \right)^\top \psi_{fr} \right] H(\mathbf{x}) + \sum_{k=0}^r \frac{1}{\gamma_{fk}} \dot{\varphi}_{fk} \psi_{fk}^\top - \\ & \mathbf{e}^\top P B \left[ \left( \frac{\partial \theta_{g0}}{\partial \varphi_{g0}} \right)^\top \psi_{g0}, \left( \frac{\partial \theta_{g1}}{\partial \varphi_{g1}} \right)^\top \psi_{g1}, \dots, \left( \frac{\partial \theta_{gr}}{\partial \varphi_{gr}} \right)^\top \psi_{gr} \right] H(\mathbf{x}) u_c + \sum_{k=0}^r \frac{1}{\gamma_{gk}} \dot{\varphi}_{gk} \psi_{gk}^\top - \\ & \mathbf{e}^\top P B (E_f + E_g u_c + g(\mathbf{x}) u_s + d(\mathbf{x}, t)) - \frac{1}{\eta_f} \tilde{E}_f |\dot{\hat{E}}_f| - \frac{1}{\eta_g} \tilde{E}_g |\dot{\hat{E}}_g|. \end{aligned} \quad (24)$$

将式(17),(20),(21)代入式(24)中并进行一些简单的矩阵转置运算, 有

$$\begin{aligned} \dot{V} \leq & \frac{1}{2} \mathbf{e}^\top Q \mathbf{e} - \mathbf{e}^\top P B (E_f + E_g u_c + d(\mathbf{x}, t)) - |\mathbf{e}^\top P B| (|\dot{\hat{E}}_f| + |\dot{\hat{E}}_g| |u_c| + D(\mathbf{x})) - \\ & \frac{1}{\eta_f} \tilde{E}_f |\dot{\hat{E}}_f| - \frac{1}{\eta_g} \tilde{E}_g |\dot{\hat{E}}_g| \leq -\frac{1}{2} \mathbf{e}^\top Q \mathbf{e} + \frac{1}{\eta_f} \tilde{E}_f (\eta_f |\mathbf{e}^\top P B| - |\dot{\hat{E}}_f|) + \\ & \frac{1}{\eta_g} \tilde{E}_g (\eta_g |\mathbf{e}^\top P B| |u_c| - |\dot{\hat{E}}_g|). \end{aligned} \quad (25)$$

由式(22)容易得到

$$\dot{V} \leq -\frac{1}{2} \mathbf{e}^\top Q \mathbf{e} \leq 0. \quad (26)$$

以下关于 $\lim_{t \rightarrow \infty} e(t) = 0$ 的详细证明可见文献[4].

### 3 仿真研究

考虑文献[2]所示的倒立摆系统.  $|x| \leq \frac{\pi}{6}$ ,  $M_f = 18$ ,  $M_g = 1.8$ ,  $\beta(x) = 1.12$ ,  $D(x) = 0.1$ ,  $H(x) = [1, x_1, x_2]$ ,  $m_1$ 和 $m_2$ 初值分别取 $(-\frac{\pi}{6}, -\frac{\pi}{12}, -\frac{\pi}{24}, 0, \frac{\pi}{24}, \frac{\pi}{12}, \frac{\pi}{6})$ , 方差初值都取0.1,  $Q = \text{diag}[10, 10]$ ,  $k_2 = 2$ ,  $k_1 = 1$ ,  $\gamma_{fk} = 25$ ,  $\gamma_{gk} = 0.5$ ,  $k = 0, 1, 2$ ,  $\eta_f = \eta_g = 0.001$ ,  $\hat{E}_f(0) = \hat{E}_g(0) = 0.005$ . 对权值固定的网络的训练数据在 $[-\pi/6, \pi/6]$ 内均匀取值.  $x_m = \frac{\pi}{40} \sin t$ ,  $x(0) = (-\frac{\pi}{50}, 0)^T$ . 仿真结果如图2和3所示.

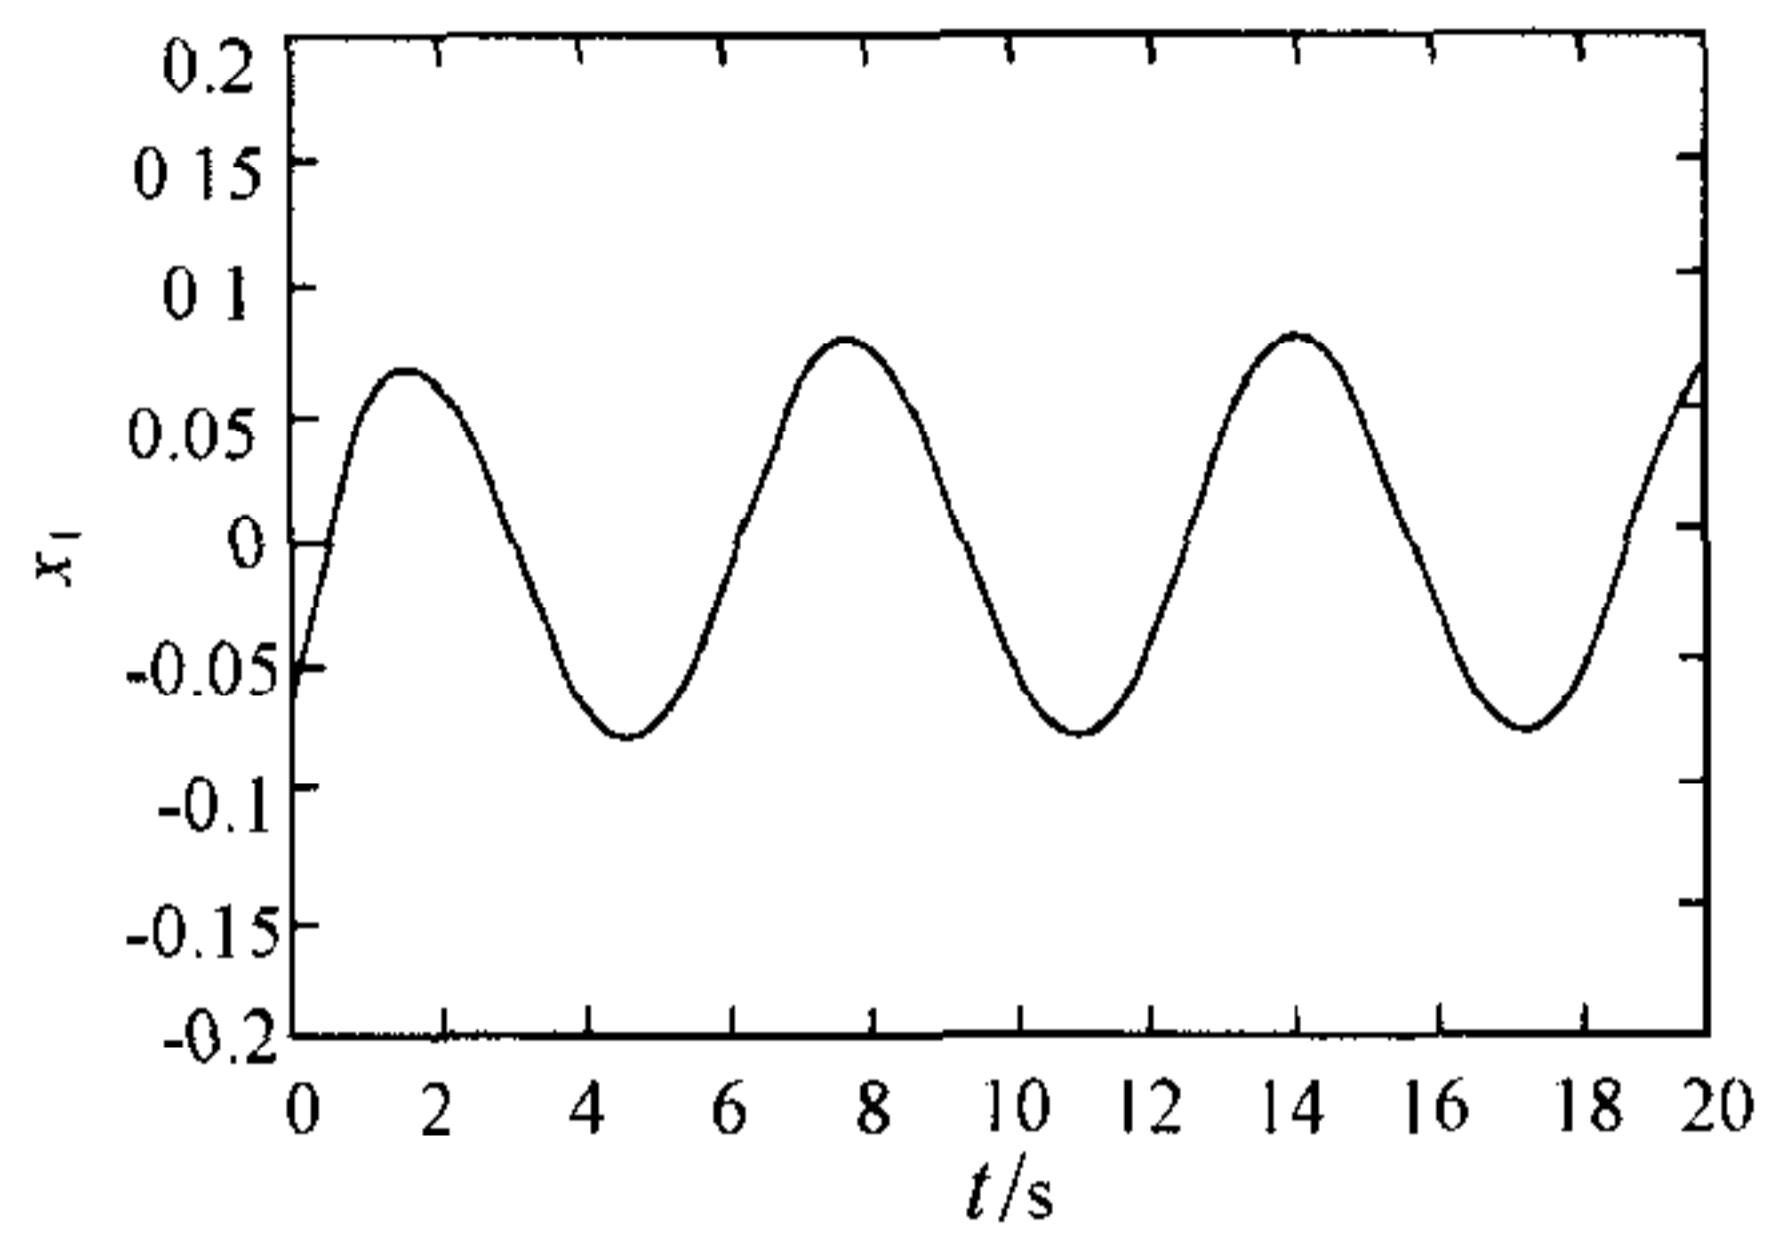


图2 AFNNC作用下倒立摆 $x_1$ 的输出  
(实线为 $x_1$ 输出,虚线为 $x_m$ 输出)

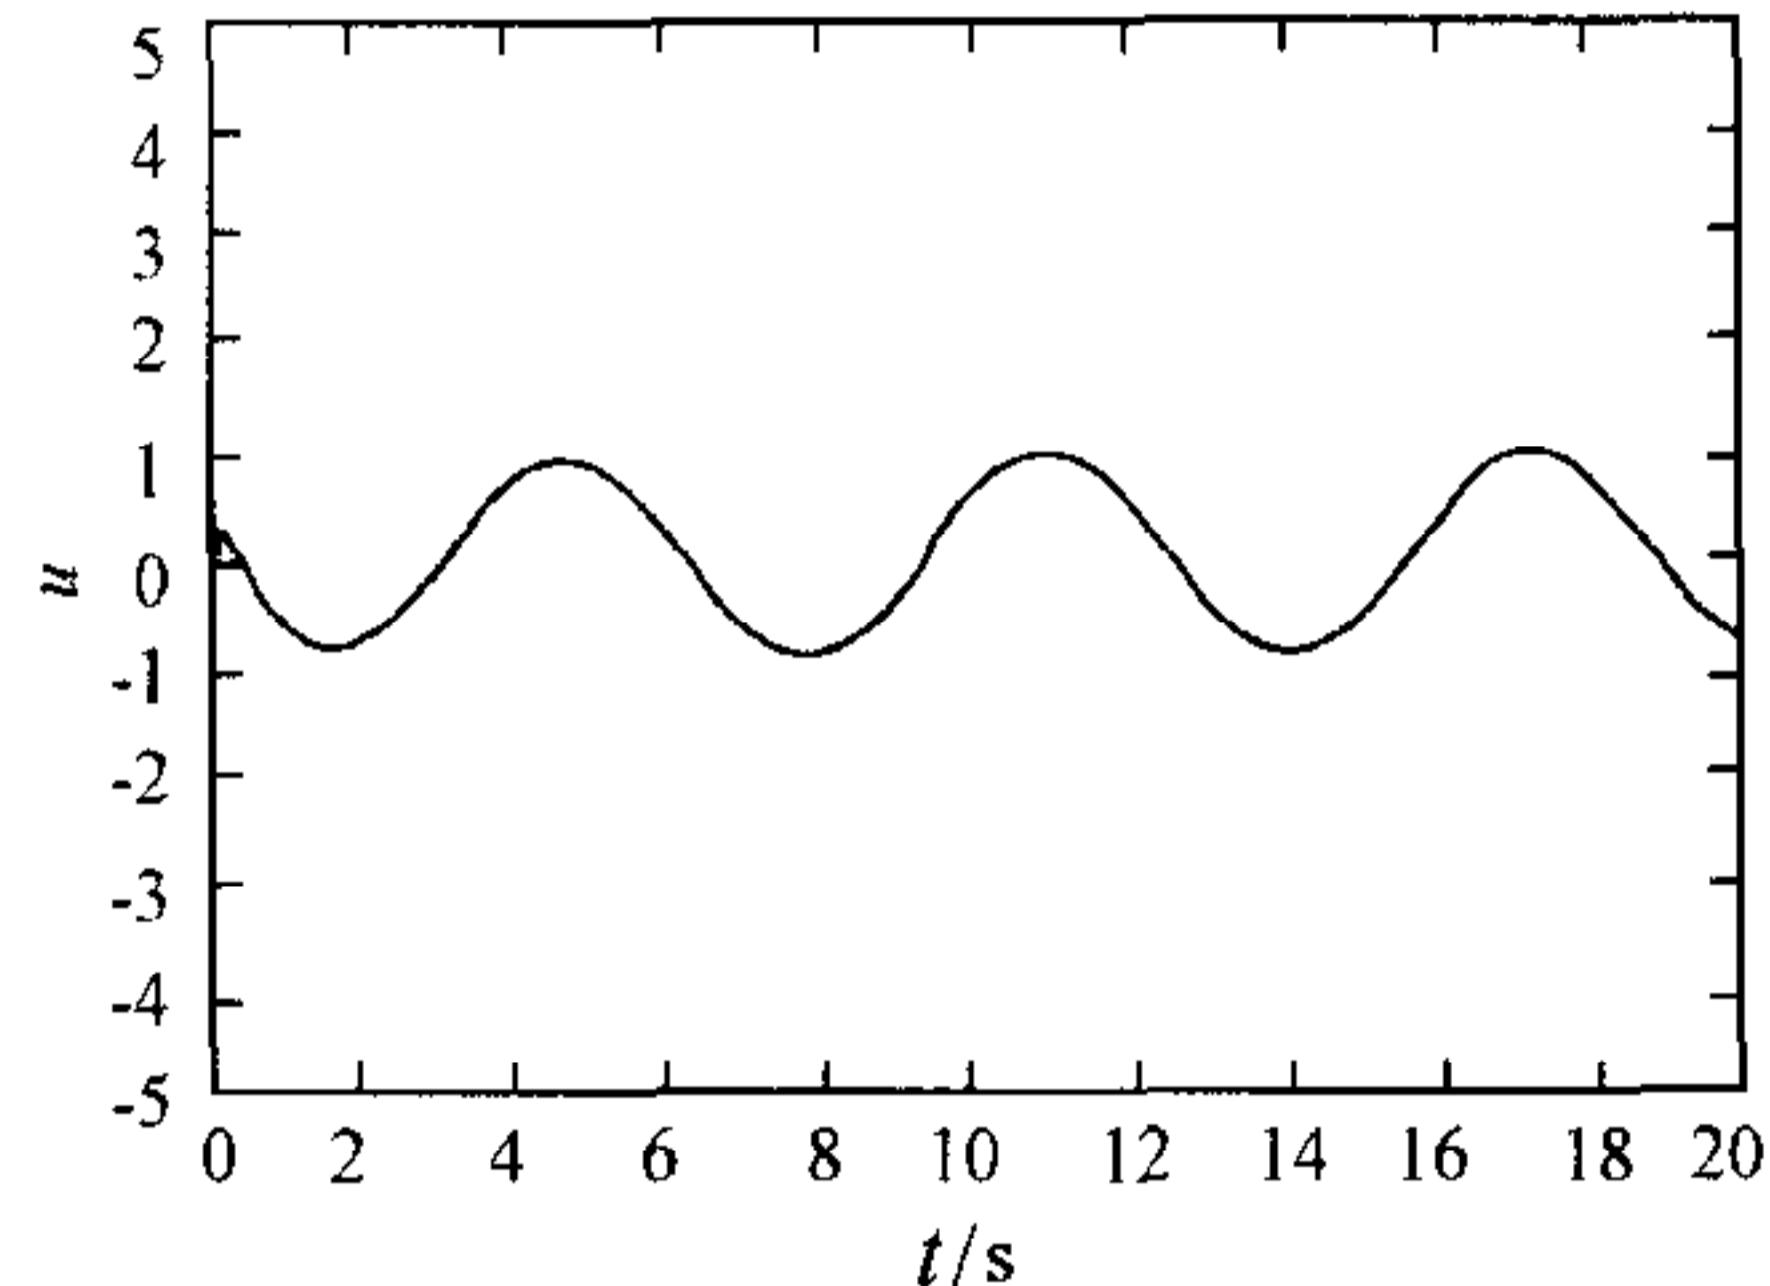


图3 系统的控制曲线

仿真结果表明,本文提出的AFNNC具有良好的跟踪性能. 另外,由于通过自适应律在线估计逼近误差,选择滑模项的增益,减轻了通常滑模控制所具有的颤动.

### 参 考 文 献

- 1 Wang L et al. Complex systems modeling via fuzzy logic. *IEEE Trans. Syst. Man & Cybern.*, 1996, **26**(1): 100~106
- 2 Wang L X. Stable adaptive fuzzy controllers with application to inverted pendulum tracking. *IEEE Trans. Syst. Man & Cybern.*, 1996, **26**(5): 677~691
- 3 Yi S C et al. Adaptive control for a class of nonlinear systems with fuzzy logic. *IEEE Trans. Fuzzy Systems*, 1994, **2**(4): 285~294
- 4 Leu Y G, Lee T T, Wang W Y. On-line tuning of fuzzy-neural network for adaptive control of dynamical systems. *IEEE Trans. Syst. Man & Cybern.*, 1997, **27**(6): 1034~1043

**马 勇** 1971年出生. 1997年和2000年分别从天津大学电力及其自动化系、上海交通大学自动化系获硕士学位和博士学位. 现在河南新飞电器有限公司负责技术工作. 研究方向为智能控制等.

**杨煜普** 1957年出生. 1996年于上海交通大学博士后出站留校至今. 研究方向为智能控制等.

**许晓鸣** 1957年生. 现任上海交通大学副校长, 博士生导师. 在国内外重要期刊、会议上发表学术论文150多篇, 目前主要从事智能控制和预测控制等.