

Controle Neural Robusto de Sistemas Não-Lineares Gerais

José Alfredo Ruiz Vargas¹, Elder Moreira Hemerly²

^{1,2} Instituto Tecnológico de Aeronáutica, Divisão de Engenharia Eletrônica, ITA-IEE-IEES

12228-900 São José dos Campos, SP, BRASIL

E-mails: jvargas_@excite.com, hemerly@ele.ita.cta.br

Abstract

This paper addresses the output feedback control of general unknown nonlinear systems. The controller is based on the linearity of the neural networks weights and Lyapunov methods are used in order to guarantee that all closed-loop signals are bounded. Only mild assumptions on the unknown system are imposed: the unknown vectorfields are continuous with respect to their arguments and satisfy a local Lipschitz condition.

1. Introdução

Apesar do sucesso de diferentes técnicas para controlar certas classes de sistemas não-lineares (*feedback linearization, backstepping, tuning functions, neural e fuzzy control systems*, etc), o problema de se controlar sistemas dinâmicos gerais permanece não resolvido, inclusive quando a dinâmica do sistema é completamente conhecida.

Assim, objetivando-se a implementação de controladores de alto desempenho para certas classes de sistemas não-lineares desconhecidos, na última década vários pesquisadores têm direcionado sua investigação para a abordagem neural [1-3]. Basicamente, este interesse é motivado pela capacidade de aproximação universal das redes neurais artificiais (RNA) [4,5] o que viabiliza que não-linearidades desconhecidas na planta possam ser substituídas por RNA, simplificando desta forma o problema de parametrização.

Embora inicialmente a maior parte da pesquisa sobre controle neural fosse de natureza empírica, ultimamente, objetivando-se resultados teóricos sobre estabilidade, têm sido desenvolvidos esquemas de controle para determinadas classes de sistemas não-lineares baseados na teoria de estabilidade de Lyapunov (vide por exemplo [3]). Assim, inicialmente em [6] foi proposto um esquema de controle baseado em várias classes de RNA supondo-se acesso total ao estado e sistemas SISO linearizáveis por realimentação. Em [7,8] foram desenvolvidos esquemas de controle neural adaptativo indireto e direto para sistemas não-lineares mais gerais que em [6], porém foram assumidas certas restrições sobre as não-linearidades desconhecidas, acesso total aos estados e que o número de entradas é igual à ordem do sistema. Neste sentido, objetivando-se a aplicação a casos mais gerais, em [9,10] foram propostos esquemas

de controle adaptativo relaxando-se a necessidade de que o número de entradas seja igual à ordem do sistema.

Contudo, a principal deficiência de todos estes trabalhos está em que são consideradas classes de sistemas não-lineares afins (i.e., o sinal de controle aparece linearmente na equação de estados) e é assumido que todos os estados estão disponíveis para medições, suposições restritivas que em geral não se verificam para sistemas não-lineares.

Assim, neste trabalho é proposto um controlador por realimentação de saída (i.e., não é necessário medir todos os componentes do vetor de estado) para sistemas não-lineares gerais desconhecidos. Mais exatamente, empregando-se um observador adaptativo similar ao proposto pelos autores em [11], um controlador é projetado para forçar os estados do sistema a rastrear uma trajetória de referência limitada. Usando-se a teoria de estabilidade de Lyapunov é provado que o erro de rastreamento é limitado, bem como todos os sinais em malha fechada.

As seguintes notações são usadas no artigo. \mathfrak{R} denota os números reais, \mathfrak{R}^n denota os vetores reais de dimensão n , $\mathfrak{R}^{n \times m}$ denota as matrizes reais de dimensão $n \times m$, o valor absoluto é denotado por $|\cdot|$. A norma euclidiana de um vetor $c \in \mathfrak{R}^n$ é denotada por $\|c\|$, se $A \in \mathfrak{R}^{n \times m}$ então $\|A\|_F$ denota a norma de Frobenius e é definida por $\|A\|_F^2 := \sum_{ij} a_{ij}^2 = \text{tr}\{A^T A\}$ onde $\text{tr}\{\cdot\}$ denota

o traço de uma matriz. A norma $\|x\|_\infty$ é definida como $\|x\|_\infty := \sup_{t \geq 0} |x(t)|$. $B(M) := \{x : \|x\| \leq M\}$ denota uma bola de raio M , $\lambda_{\max}(\cdot)$ e $\lambda_{\min}(\cdot)$ denotam o maior e o menor autovalor de uma matriz. L_∞ denota o espaço de funções Lebesgue integráveis com supremo essencial finito.

2. Formulação do problema

Considere o problema de projeto de um controlador por realimentação da saída para sistemas não-lineares gerais desconhecidos, representados por

$$\dot{\chi}(t) = f(\chi(t), u(t)) \quad (2.1)$$

$$y(t) = h(\chi(t), u(t)) \quad (2.2)$$

onde $\chi \in \mathfrak{R}^n$ é o estado do sistema (não disponível para medições), $u \in \mathfrak{R}^m$ é a entrada de controle, $y \in \mathfrak{R}^q$ é a saída do sistema e f, h são campos vetoriais desconhecidos, sendo lineares em seus argumentos e satisfazendo localmente a condição de Lipschitz.

O objetivo do controle consiste em forçar os estados do sistema a rastrear uma trajetória de referência limitada $x_r(t) \in \mathfrak{R}^n$ que pode ser expressa por

$$\dot{x}_r(t) = f_r(x_r, u_r) \quad (2.3)$$

onde u_r é uma entrada de referência e f_r é linear com respeito a seus argumentos e satisfaz localmente a condição de Lipschitz.

Objetivando-se parametrizar convenientemente o sistema (2.1)-(2.2) são empregadas redes neurais artificiais lineares nos pesos (RNALP). RNALP foram inicialmente usadas por Polycarpou et alli [6] para identificação e controle estável de sistemas não-lineares, e incluem uma ampla classe de topologias tais como *high order neural networks*, *RBF networks*, *adaptive fuzzy system*, *wavelet networks*, *multilayer neural networks* sob algumas assunções, etc (vide por exemplo [6,12]). Em geral tais redes são descritas matematicamente por

$$y = WS(x, u) \quad (2.4)$$

onde $x \in \mathfrak{R}^n$ e $u \in \mathfrak{R}^m$ são os vetores de entrada, $y \in \mathfrak{R}^p$ é o vetor de saída, $W \in \mathfrak{R}^{p \times L}$, $L \geq n + m$ é a matriz de pesos, $S : \mathfrak{R}^{n+m} \mapsto \mathfrak{R}^L$ é uma função vetorial não-linear das entradas à rede pré-processadas por uma função $s(\cdot)$ sigmoideal. Adicionalmente, se a rede considerada satisfaz a condição de aproximação universal e a condição de regularidade e L é selecionado adequadamente, pode ser provado (vide [6,12] para maiores detalhes), que ela pode aproximar, com qualquer grau de precisão, funções não-lineares e sistemas dinâmicos contínuos. É importante ressaltar que em geral o erro de aproximação diminui conforme L aumenta.

Somando e subtraindo-se $A\chi$ e Cy , as equações (2.1)-(2.2) pode ser expressas como

$$\dot{\chi}(t) = A\chi(t) + Du(t) + g(\chi, u) \quad (2.5)$$

$$y(t) = \int_0^t \bar{g}(\chi(\tau), u(\tau), \dot{u}(\tau)) d\tau \quad (2.6)$$

$$+ C \int_0^t h(\chi(\tau), u(\tau)) d\tau + y(0)$$

onde $A := \text{diag}(-a_i)$ e $C := \text{diag}(-c_j)$ com $a_i, c_j > 0$ para $i=1,2, \dots, n$ e $j=1,2, \dots, q$, $D \in \mathfrak{R}^{n \times m}$, $g(\chi, u) := f(\chi, u) - A\chi - Du$,

$$\bar{g}(\chi, u, \dot{u}) := \frac{\partial h(\chi, u)}{\partial \chi} f(\chi, u) + \frac{\partial h(\chi, u)}{\partial u} \dot{u} - Ch(\chi, u).$$

As equações (2.5)-(2.6) podem ser rescritas usando-se RNALP como

$$\dot{\chi}(t) = A\chi(t) + Du(t) + BW^*S(\chi, u) + v(t) \quad (2.7)$$

$$y(t) = \int_0^t (\bar{B}\bar{W}^*\bar{S}(\chi(\tau), u(\tau), \dot{u}(\tau)) + \bar{v}(\tau)) d\tau \quad (2.8)$$

$$+ C \int_0^t h(\chi(\tau), u(\tau)) d\tau$$

onde $g(\chi, u) = BW^*S(\chi, u) + v(t)$, $\bar{g}(\chi, u, \dot{u}) = \bar{B}\bar{W}^*\bar{S}(\chi, u, \dot{u}) + \bar{v}(t)$, $v(t)$ e $\bar{v}(t)$ são vetores de erros de aproximação limitados, isto é, $\|v(t)\| \leq v_0$ e $\|\bar{v}(t)\| \leq \bar{v}_0$ para algumas constantes positivas v_0 e \bar{v}_0 , $S : \mathfrak{R}^{n+m} \mapsto \mathfrak{R}^L$ e $\bar{S} : \mathfrak{R}^{n+2m} \mapsto \mathfrak{R}^{\bar{L}}$ conforme definidas em (2.4), $B := \text{diag}(b_i)$ e $\bar{B} := \text{diag}(\bar{b}_i)$ com $b_i, \bar{b}_i \neq 0$ para $i=1,2, \dots, n$, são matrizes diagonais de projeto necessária para aprimorar as estimativas, $W^* \in \mathfrak{R}^{n \times L}$ e $\bar{W}^* \in \mathfrak{R}^{q \times \bar{L}}$ (requeridas unicamente para fins analíticos) são matrizes constantes “ótimas”, que, similarmente a [6], podem ser definidas como

$$W^* := \arg \min_{\hat{W} \in B(\hat{M})} \left\{ \sup_{\substack{\chi \in \mathfrak{R} \\ u \in \mathfrak{R}}} |g(\chi, u) - B\hat{W}S(\chi, u)| \right\}$$

$$\bar{W}^* := \arg \min_{\hat{\bar{W}} \in B(\hat{\bar{M}})} \left\{ \sup_{\substack{\chi \in \mathfrak{R} \\ u \in \mathfrak{R}}} |\bar{g}(\chi, u) - \hat{\bar{W}}\bar{S}(\chi, u, \dot{u})| \right\}$$

onde \hat{W} e $\hat{\bar{W}}$ são estimativas das matrizes W^* e \bar{W}^* .

Com base em (2.7)-(2.8), podem ser escolhidos os seguintes modelos para identificação

$$\hat{\chi}(t) = A\hat{\chi}(t) + Du(t) + B\hat{W}S(\hat{\chi}, u) \quad (2.9)$$

$$\hat{y}(t) = \int_0^t \hat{B}\hat{\bar{W}}(\tau)\bar{S}(\hat{\chi}(\tau), u(\tau), \dot{u}(\tau)) d\tau \quad (2.10)$$

$$+ C \int_0^t \hat{y}(\tau) d\tau + \hat{y}(0)$$

Considerando-se (2.7)-(2.10), a dinâmica das equações de erro é regida por

$$\dot{\tilde{x}}(t) = A\tilde{x} + B\tilde{W}S(\hat{x}, u) + \omega(t) - v(t) \quad (2.11)$$

$$\dot{\tilde{y}}(t) = C\tilde{y} + \tilde{B}\tilde{W}S(\hat{x}, u, \dot{u}) + \bar{\omega}(t) - \bar{v}(t) \quad (2.12)$$

onde $\tilde{x} := \hat{x} - \chi$, $\tilde{y} := \hat{y} - y$, $\tilde{W} := \hat{W} - W^*$, $\tilde{\bar{W}} := \hat{\bar{W}} - \bar{W}^*$, $\omega(t) := BW^*(S(\hat{x}, u) - S(\chi, u))$ e $\bar{\omega}(t) := \tilde{B}\tilde{\bar{W}}^*(\tilde{S}(\hat{x}, u, \dot{u}) - \tilde{S}(\chi, u, \dot{u}))$ são termos de distúrbios limitados (devido às funções sigmoidais). Mais precisamente, $\|\omega(t)\| \leq \omega_0$ e $\|\bar{\omega}(t)\| \leq \bar{\omega}_0$ para algumas constantes ω_0 e $\bar{\omega}_0$ positivas.

Definindo-se o erro de rastreamento como $e = x - x_r$, decorre

$$\begin{aligned} \dot{e}(t) &= \dot{\chi}(t) - \dot{x}_r(t) \\ &= A\chi(t) + Du(t) + g(\chi, u) - \dot{x}_r(t) \\ &= A\chi(t) + Du(t) + BW^*S + v(t) - \dot{x}_r(t) \end{aligned} \quad (2.13)$$

Também, a equação (2.3) pode ser rescrita como

$$\dot{x}_r(t) = A_r x_r(t) + B_r W_r^* S_r + v_r(t) \quad (2.14)$$

onde $A_r := \text{diag}(-a_{r_i})$, $B_r := \text{diag}(b_{r_i})$, $a_{r_i} > 0$ com $i=1, 2, \dots, n$, $W_r^* \in \mathfrak{R}^{n \times L_r}$, $S_r : \mathfrak{R}^{n+m_r} \mapsto \mathfrak{R}^{L_r}$ e $\|v_r(t)\| \leq v_{r0}$ para alguma constante positiva v_{r0} .

Com base em (2.14), um observador pode ser escolhido como

$$\dot{\hat{x}}_r(t) = A_r \hat{x}_r(t) + B_r \hat{W}_r S_r \quad (2.15)$$

e conseqüentemente a equação de erro satisfaz

$$\dot{\tilde{x}}_r(t) = A_r \tilde{x}_r(t) + B_r \tilde{W}_r S_r - v_r(t) \quad (2.16)$$

Substituindo-se (2.14) em (2.13), resulta

$$\begin{aligned} \dot{e}(t) &= A\hat{x}(t) + Du(t) + BW^*S + v(t) - A_r x_r(t) \\ &\quad - B_r W_r^* S_r - v_r(t) \\ &= Ae(t) + Du(t) + BW^*S - B_r W_r^* S_r + \Delta x_r \\ &\quad + v(t) - v_r(t) \\ &= Ae(t) + Du(t) + BW^*S - B_r W_r^* S_r + \kappa(t) \end{aligned} \quad (2.17)$$

onde $\Delta = A - A_r$, $\kappa(t) = \Delta x_r - v_r$ e por conseguinte $\|\kappa(t)\| \leq \kappa_0$ para alguma constante positiva κ_0 .

Selecione agora o controle como

$$u = -D^{-1}B\hat{W}S + D^{-1}B_r \hat{W}_r S_r \quad (2.18)$$

Então, substituindo-se a equação (2.18) em (2.17), obtém-se a equação do erro de rastreamento em malha fechada,

$$\dot{e}(t) = Ae(t) + B_r \tilde{W}_r S_r + \bar{\kappa}(t) \quad (2.19)$$

onde

$\bar{\kappa}(t) := \omega_r(t) + \kappa(t)$, $\omega_r(t) := B(W^*S(\chi, u) - \hat{W}S(\hat{x}, u))$ e, por conseguinte, $\|\bar{\kappa}(t)\| \leq \bar{\kappa}_0$ para alguma constante positiva $\bar{\kappa}_0$.

3. Análise de estabilidade

Nesta seção é provada a estabilidade do sistema de controle proposto. Mais especificamente, empregando-se a teoria de estabilidade de Lyapunov é provado que todos os sinais em malha fechada são limitados. A estrutura do controlador proposto é mostrada na fig. 3.1.

Teorema:

Considere os sistemas dinâmicos gerais descritos por (2.1)-(2.2), os modelos para identificação (2.9)-(2.10), as seguintes leis de adaptação para os pesos das RNALP

$$\dot{\hat{w}}_i = -K_i S(\hat{x}, u) \varphi_i(\hat{y}, y, \hat{x}, u) - \sigma_i |\varphi_i(\hat{y}, y, \hat{x}, u)| K_i \hat{w}_i, \text{ for } i=1, 2, \dots, n \quad (3.1)$$

$$\begin{aligned} \dot{\hat{w}}_j &= -\bar{K}_j \bar{S}(\hat{x}, u, \dot{u}) \tilde{y}_j - \bar{\sigma}_j |\tilde{y}_j| \bar{K}_j \hat{w}_j, \text{ for } j=1, 2, \dots, q \end{aligned} \quad (3.2)$$

$$\begin{aligned} \dot{\hat{w}}_{ri} &= -K_{ri} S_r(x_r) \tilde{x}_{ri} - \sigma_{ri} |\tilde{x}_{ri}| K_{ri} \hat{w}_{ri}, \text{ for } i=1, 2, \dots, n \end{aligned} \quad (3.3)$$

e o controlador por realimentação da saída

$$u(t) = -D^{-1}B\hat{W}S(\hat{x}, u) + D^{-1}B_r \hat{W}_r S_r(x_r) \quad (3.4)$$

onde, $K_i = K_i^T > 0 \in \mathfrak{R}^{L \times L}$, $\bar{K}_j = \bar{K}_j^T > 0 \in \mathfrak{R}^{\bar{L} \times \bar{L}}$, $K_{ri} = K_{ri}^T > 0 \in \mathfrak{R}^{L_r \times L_r}$, $\sigma_i, \bar{\sigma}_j > 0 \in \mathfrak{R}$, $\hat{W}^T = [\hat{w}_1 \mid \hat{w}_2 \mid \dots \mid \hat{w}_n] \in \mathfrak{R}^{L \times n}$, $\hat{\bar{W}}^T = [\hat{\bar{w}}_1 \mid \hat{\bar{w}}_2 \mid \dots \mid \hat{\bar{w}}_q] \in \mathfrak{R}^{\bar{L} \times q}$, $\hat{W}_r^T = [\hat{w}_{r1} \mid \hat{w}_{r2} \mid \dots \mid \hat{w}_{rn}] \in \mathfrak{R}^{L_r \times n}$ e $\varphi(\cdot) \in \mathfrak{R}^n$ é uma função vetorial possivelmente não-linear selecionada tal que $J = \|\varepsilon(\tau)\|_\infty \leq \varepsilon_0$, onde $\varepsilon(t) := B\tilde{x}(t) - \varphi(t)$ é o erro de reconstrução do erro de estado e $\varepsilon_0 \geq 0$ é alguma constante pequena.

Então, $\tilde{x}, \tilde{x}_r, e, \tilde{W}, \tilde{\bar{W}}, \tilde{W}_r$ e $\tilde{y} \in L_\infty$.

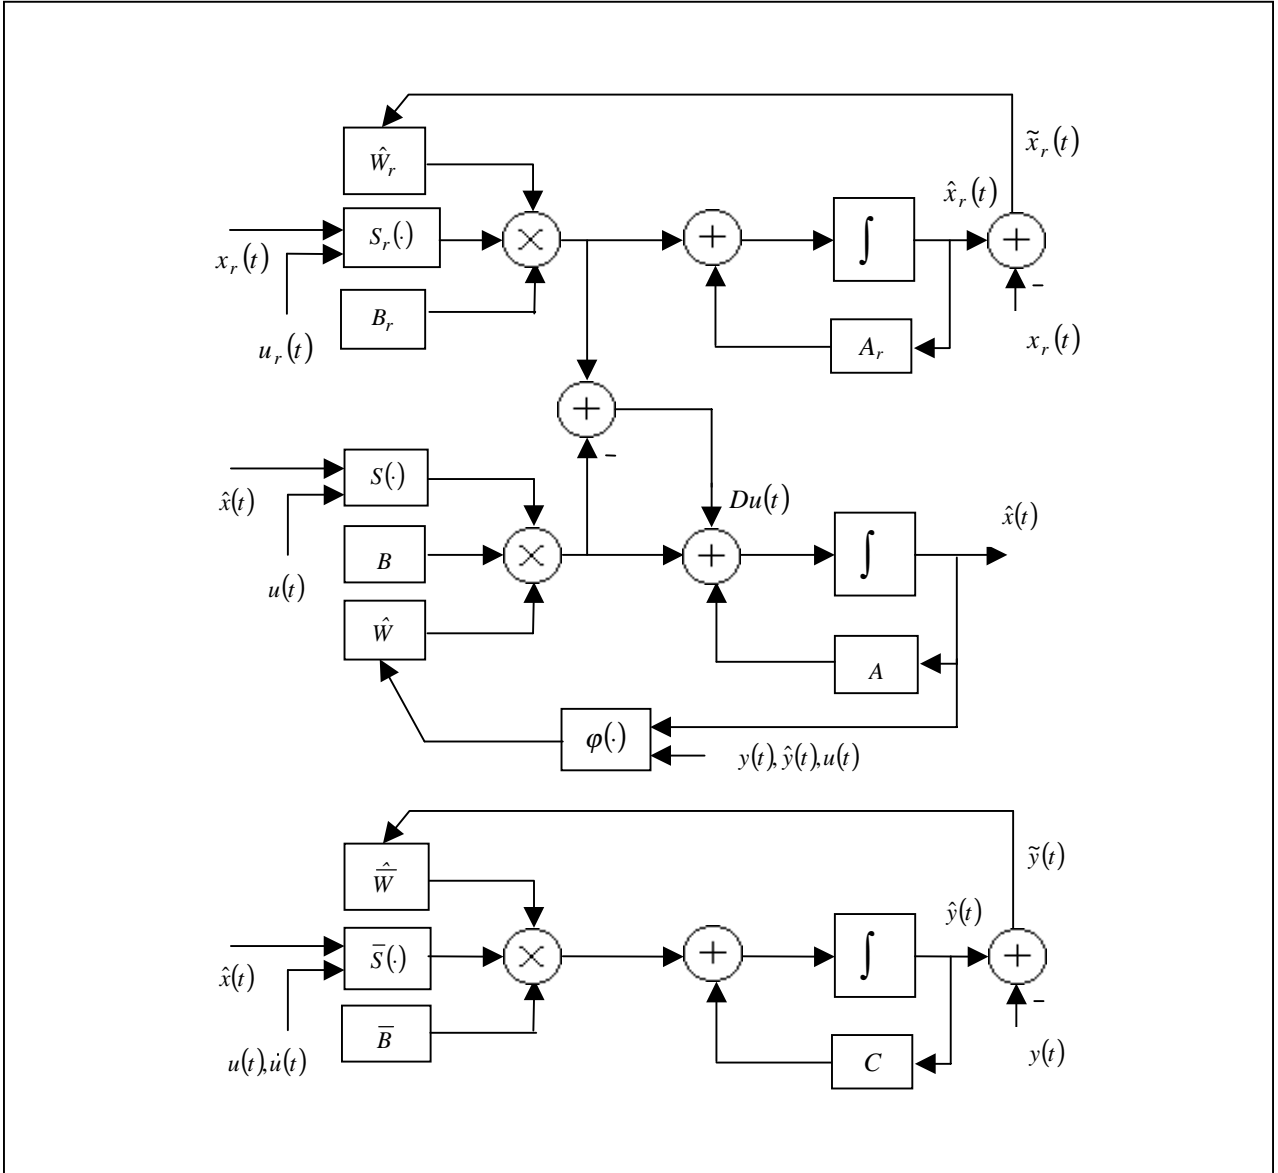


Fig. 3.1- Estrutura do controlador neural proposto.

Prova:

Usando-se as equações de erro (2.9)-(2.10), e um argumento de prova igual àquele empregado em [11], pode-se concluir que $\tilde{x}, \tilde{W}, \tilde{\bar{W}}$ e $\tilde{y} \in L_\infty$.

Objetivando-se provar a estabilidade de \tilde{x}_r e \tilde{W}_r , considere a função positiva definida

$$V(\tilde{x}_r, \tilde{W}_r) = \frac{1}{2} \left(\tilde{x}_r^T \tilde{x}_r + \sum_{i=1}^n \tilde{w}_{ri}^T \bar{K}_{ri}^{-1} \tilde{w}_{ri} \right) \quad (3.5)$$

Derivando-se (3.5) em relação ao tempo, obtém-se

$$\dot{V} = \sum_{i=1}^n \left(\tilde{x}_{ri} \dot{\tilde{x}}_{ri} + \tilde{w}_{ri}^T \bar{K}_{ri}^{-1} \dot{\tilde{w}}_{ri} \right) \quad (3.6)$$

Avaliando-se (3.6) ao longo das trajetórias (2.16) e (3.3), resulta

$$\begin{aligned} \dot{V} &= \sum_{i=1}^n \left[-a_{ri} \tilde{x}_{ri}^2 + (b_{ri} - I) \tilde{w}_{ri}^T S_{ri} \tilde{x}_{ri} \right. \\ &\quad \left. - v_{ri} \tilde{x}_{ri} - \sigma_{ri} |\tilde{x}_{ri}| \|\tilde{w}_{ri}^T \hat{w}_{ri}\| \right] \\ &\leq \sum_{i=1}^n \left[-a_{ri} \tilde{x}_{ri}^2 + S_{r0} |b_{ri} - I| \|\tilde{w}_{ri}\| |\tilde{x}_{ri}| \right. \\ &\quad \left. + v_{r0} |\tilde{x}_{ri}| - \sigma_{ri} |\tilde{x}_{ri}| \|\tilde{w}_{ri}\|^2 + \sigma_{ri} |\tilde{x}_{ri}| \|\tilde{w}_{ri}\| \|\hat{w}_{ri}^*\| \right] \end{aligned} \quad (3.7)$$

onde $\|S_r(x_r(t), u_r(t))\| \leq S_{r0}$ para alguma constante positiva S_{r0} e foi usada a seguinte desigualdade, $-\tilde{w}_{ri}^T \tilde{w}_{ri} \leq -\|\tilde{w}_{ri}\|^2 + \|\tilde{w}_{ri}\| \|\hat{w}_{ri}^*\|$.

Completando-se o quadrado em (3.7), advém

$$\dot{V} \leq \sum_{i=1}^n |\tilde{x}_{ri}| \left[-a_{ri} |\tilde{x}_{ri}| - \sigma_{ri} \left(\|\tilde{w}_{ri}\| - \frac{S_{r0} |b_{ri} - l| + \sigma_{ri} \|w_{ri}^*\|}{2\sigma_{ri}} \right)^2 + \frac{(S_{r0} |b_{ri} - l| + \sigma_{ri} \|w_{ri}^*\|)^2}{4\sigma_{ri}} + v_{r0} \right] \quad (3.8)$$

A partir de (3.8), obtém-se as condições para $\dot{V} \leq 0$,

$$\|\tilde{x}_r\| \geq \frac{\frac{1}{n^2} v_{r0}}{a_{ri\min}} + \frac{l}{a_{ri\min}} \sum_{i=1}^n \left[\frac{(S_{r0} |b_{ri} - l| + \sigma_{ri} \|w_{ri}^*\|)^2}{4\sigma_{ri}} \right]$$

ou

$$\|\tilde{w}_{ri}\| \geq \frac{S_{r0} |b_{ri} - l| + \sigma_{ri} \|w_{ri}^*\|}{2\sigma_{ri}} + \left[\frac{(S_{r0} |b_{ri} - l| + \sigma_{ri} \|w_{ri}^*\|)^2}{4\sigma_{ri}^2} + \frac{v_{r0}}{\sigma_{ri}} \right]^{\frac{1}{2}}, \quad i = 1, 2, \dots, n$$

onde

$$\frac{\frac{1}{n^2} v_{r0}}{a_{ri\min}} + \frac{l}{a_{ri\min}} \sum_{i=1}^n \left[\frac{(S_{r0} |b_{ri} - l| + \sigma_{ri} \|w_{ri}^*\|)^2}{4\sigma_{ri}} \right],$$

$$\frac{S_{r0} |b_{ri} - l| + \sigma_{ri} \|w_{ri}^*\|}{2\sigma_{ri}} + \left[\frac{(S_{r0} |b_{ri} - l| + \sigma_{ri} \|w_{ri}^*\|)^2}{4\sigma_{ri}^2} + \frac{v_{r0}}{\sigma_{ri}} \right]^{\frac{1}{2}}$$

para $i=1, 2, \dots, n$, são constantes positivas. Conseqüentemente, $\tilde{x}_r, \tilde{w}_r \in L_\infty$ e de (2.19) tem-se que $e \in L_\infty$.

Por outro lado, de (3.4) seque que $u, \dot{u} \in L_\infty$, onde \dot{u} pode ser calculado a partir de

$$\dot{u}(t) = -D^{-1} B \left[\hat{W} \dot{S}(\hat{x}, u) + \hat{W} S(\hat{x}, u) \right] + D^{-1} B_r \left[\hat{W}_r \dot{S}_r(x_r) + \hat{W}_r S_r(x_r) \right] \quad (3.9)$$

■

Comentários:

3.1- Para o ajuste dos pesos \hat{W} , \hat{W}_r e \hat{W} poderiam ter sido empregadas diversas leis de adaptação robustas (ou modificações) presentes na literatura [13,14]. Entretanto, conforme mostrado em [15], leis de adaptação com comutação podem ser de difícil aplicação e desempenho inferior quando comparadas com leis de adaptação sem comutação. Conseqüentemente, objetivando-se garantir estabilidade e desempenho conveniente, são empregadas leis de adaptação tipo *e-modification* [14] com funções de realimentação apropriadamente definidas (vide função φ_i , o erro de saída \tilde{y}_j e o erro \tilde{x}_{ri} nas equações (3.1)-(3.3)).

3.2- Em muitos casos, as funções de realimentação φ_i podem ser definidas usando-se combinações lineares dos erros das saídas para obter estimações satisfatórias (i.e. $\varphi = \Lambda(\hat{y} - y)$ onde $\Lambda \in \mathcal{R}^{q \times n}$ e $\varphi = [\varphi_1 \quad \varphi_2 \quad \dots \quad \varphi_n]^T$) [11]. Contudo, em alguns casos em que estimações mais precisas sejam requeridas, esforços adicionais terão que ser feitos para se selecionar funções de realimentação que possibilitem melhor desempenho. Assim, se os campos vetoriais do sistema são completamente desconhecidos, então será necessário um procedimento de tentativa e erro para a escolha das funções de realimentação convenientes. Por outro lado, se os campos vetoriais do sistema são conhecidos, então as funções de realimentação “ótimas” pode ser facilmente selecionadas a partir das equações dinâmicas do sistema. É importante ressaltar que uma escolha inadequada das funções de realimentação unicamente afeta a precisão das estimativas, i.e., a estabilidade é sempre garantida.

3.3- Em [11] foi investigado o impacto do uso das funções de realimentação nas leis de adaptação para os pesos. Basicamente, definido-se um erro de reconstrução do erro de estado foi provado que a magnitude do erro de estado é proporcional à magnitude dos erros de aproximação, distúrbios limitados e erros de reconstrução dos erros de estado. Para maiores detalhes, vide [11].

4. Conclusões

Neste artigo foi proposto um controlador neural por realimentação da saída para o problema de rastreamento de sistemas não-lineares gerais desconhecidos. O observador proposto em [11] foi utilizado para a geração do sinal de controle. Usando-se a teoria de estabilidade de Lyapunov, foi provado que todos os sinais em malha fechada são limitados.

Agradecimentos

Os autores agradecem à FAPESP-Fundação de Amparo à Pesquisa do Estado de São Paulo, processo 98/01449-0, e ao CNPq processo 300158/95-5, pelo suporte financeiro.

Referências

- [1] M. M. Gupta & D. H. Rao (Eds.), *Neuro Control Systems: Theory and Applications*, IEEE Press, New York, 1994.
- [2] W. T. Miller; R. S. Sutton; P. J. Werbos (Eds.), *Neural Networks for Control*, MIT Press., Cambridge, Massachusetts, 1995.
- [3] C. T. Leondes (Ed.), *Control and Dynamical Systems, Volume 7 of Neural Network Systems Techniques and Applications*, Academic Press, San Diego, California, 1998
- [4] K. Funahashi, "On the Approximate Realization of Continuous Mappings by Neural Networks," *Neural Networks*, 2(3): 183-191, 1989.
- [5] K. Funahashi & Y. Nakamura "Approximation of Dynamical Systems by Continuous Time Recurrent Neural Networks," *Neural Networks*, Vol. 6, pp. 801-806, 1993.
- [6] M. M. Polycarpou & P. A. Ioannou, "Identification and Control of Nonlinear Systems Using Neural Network Models: Design and Stability Analysis," Tech. Rep. 91-09-01, Dept. Elect. Eng. Syst., Univ. Southern Calif., Los Angeles, 1991.
- [7] G. A. Rovithakis & M. A. Christodoulou, "Adaptive Control of Unknown Plants Using Dynamical Neural Networks," *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 24, No. 3, pp. 400-412, March 1994.
- [8] G. A. Rovithakis & M. A. Christodoulou, "Direct Adaptive Regulation of Unknown Nonlinear Dynamical Systems via Dynamic Neural Networks," *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 25, No. 12, pp. 1578-1594, December 1995.
- [9] G. A. Rovithakis & M. A. Christodoulou, "Neural Adaptive Regulation of Unknown Nonlinear Dynamical Systems," *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 27, No. 5, pp. 810-821, October 1997.
- [10] G. A. Rovithakis, "Tracking Control of Multi-Input Affine Nonlinear Dynamical Systems with Unknown Nonlinearities Using Dynamical Neural Networks", *IEEE Transactions on Systems, Man and Cybernetics- Part B: Cybernetics*, Vol. 29, No. 2, pp. 179-189, April 1999.
- [11] J.A.R. Vargas & E.M. Hemerly, "Adaptive Observers for Unknown General Nonlinear Systems", submitted to *IEEE Transactions on Systems, Man and Cybernetics*, 2000.
- [12] E. B. Kosmatopoulos; M. M. Polycarpou; M. A. Christodoulou; P. A. Ioannou, "High-Order Neural Networks Structures for Identification of Dynamical Systems," *IEEE Transactions on Neural Networks*, Vol. 6, No. 2, pp. 422-431, 1995.
- [13] P.A. Ioannou, & J. Sun, *Robust Adaptive Control*, Englewood Cliffs, NJ: Prentice Hall, 1995.
- [14] K.S. Narendra & A.M. Annaswamy, *Stable Adaptive Systems*, New Jersey, Prentice Hall Inc., 1989.
- [15] J.A.R. Vargas, "Identification of Dynamical Systems via Artificial Neural Networks (in Portuguese)," M.S. dissertation, ITA, São José dos Campos, São Paulo, Brazil, 1997.