

Observador Adaptativo Estável Usando Redes Neurais Artificiais

José Alfredo Ruiz Vargas¹, Elder Moreira Hemerly²

^{1,2} Instituto Tecnológico de Aeronáutica, Divisão de Engenharia Eletrônica, CTA-ITA-IEE-IEES
12228-900 São José dos Campos, SP, BRAZIL

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

Abstract

In this paper, an adaptive observer for multivariable nonlinear systems that present an unknown general state equation and known linear output equation is developed. The observer is based on linearly parameterized neural networks and Lyapunov methods are used for stability analysis. We consider a more general class of systems than in previous works and the usual SPR (strictly positive real) assumption is not required here.

1. Introdução

O problema de observadores adaptativos, em termos gerais, consiste no projeto de algoritmos de adaptação para as tarefas de estimação de estados e identificação paramétrica em um sistema dinâmico desconhecido. Para tanto, são usadas as entradas e saídas medidas, e, as duas tarefas são executadas simultaneamente. Devido à complexidade deste procedimento (pois o algoritmo de estimação de estados tem que trabalhar na presença de parâmetros incertos e vice-versa), o projeto de observadores adaptativos principalmente para sistemas não-lineares constitui em geral um problema aberto, e relevante para o controle de sistemas dinâmicos.

Por outro lado, na última década as redes neurais artificiais (RNA) têm atraído a atenção de muitos pesquisadores como uma alternativa viável e de fácil aplicação para a identificação e controle de sistemas dinâmicos não-lineares. Embora os primeiros trabalhos sobre o tema tenham sido de natureza principalmente empírica [1-5], recentemente, objetivando-se garantir estabilidade, robustez e desempenho conveniente, têm sido desenvolvidos esquemas de identificação e controle neural baseados na teoria de estabilidade de Lyapunov (vide por exemplo [6-10]).

Neste sentido, o uso de RNA para o projeto de observadores adaptativos não-lineares estáveis constitui uma abordagem relevante que vem sendo atualmente investigada na literatura [11-13]. Desta forma contorna-se em parte a necessidade de se verificar a priori que o sistema original satisfaz certas condições estruturais que permitam transformá-lo em formas canônicas especiais, e conseqüentemente que um observador adaptativo possa ser projetado, fatos usuais

no projeto de observadores adaptativos não-lineares (vide por exemplo [14-18]).

Contudo, os observadores neurais propostos em [11-13] são de aplicação limitada, pois consideram sistemas SISO de estrutura peculiar onde uma condição de SPR tem que ser assumida (objetivando-se o projeto de leis de adaptação estáveis).

As suposições anteriores são restritivas e não se verificam para uma ampla classe de interesse.

Neste trabalho, usando-se RNA parametrizáveis linearmente, é proposto um observador adaptativo que é robusto a erros de reconstrução e distúrbios limitados. São considerados sistemas MIMO que apresentam uma estrutura geral e desconhecida nos estados e uma forma linear e conhecida na equação de saída. No contexto da teoria de estabilidade de Lyapunov, é provado que uma lei de aprendizado tipo *switching σ -Modification* [19] para os pesos da RNA garante a estabilidade do observador. Ao contrário de trabalhos prévios, nenhuma suposição de SPR é feita aqui objetivando-se provar estabilidade, e é considerada uma classe de sistemas mais geral que em [11-13].

2. Sistema Não-Linear

Considere o problema de projeto de um observador adaptativo para a classe de sistemas contínuos não-lineares representados por

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

$$y(t) = C\chi(t) \quad (2.2)$$

onde $\chi \in \mathcal{K} \subset \mathfrak{R}^n$ é o estado do sistema, $u \in u \subset \mathfrak{R}^m$ é a entrada do sistema (contínuo por partes), $y \in \mathcal{Y} \subset \mathfrak{R}^q$ e $f: \mathcal{K} \times u \rightarrow \mathfrak{R}^n$ é um campo vetorial desconhecido, $C = [c_{ij}] \in \mathfrak{R}^{q \times n}$.

De forma a se garantir a existência e unicidade de solução para a equação de estado (2.1) dados qualquer condição inicial $\chi_0 \in \mathcal{K}$ e $u \in u$, devemos admitir as seguintes suposições moderadas para (2.1) [9]:

(S1) Para qualquer $u \in u$, χ_0 finito e $T > 0$ finito, tem-se $\|\chi(T)\| < \infty$.

(S2) O campo vetorial $f: \mathcal{K} \times u \rightarrow \mathfrak{R}^n$ é contínuo

com respeito aos seus argumentos, satisfaz a condição de Lipschitz local tal que a solução $\chi(t)$ da equação de estado (2.1) é única para qualquer $\chi_0 \in \mathcal{K}$ e $u \in U$.

3. RNA Parametrizáveis Linearmente

Neste artigo, serão empregadas RNA parametrizáveis linearmente para reconstruir adaptativamente os estados em (2.1). RNA parametrizáveis linearmente foram inicialmente usadas por Polycarpou et alli [9] 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 suposições, etc [6,8]. Em geral tais redes são descritas matematicamente como

$$y = WS(x, u) \quad (3.1)$$

onde $x \in \mathcal{R}^n$ e $u \in \mathcal{R}^m$ são os vetores de entrada, $y \in \mathcal{R}^p$ é o vetor de saída, $W \in \mathcal{R}^{p \times L}$, $L \geq n + m$ é a matriz de pesos, $S : \mathcal{R}^{n+m} \mapsto \mathcal{R}^L$ é uma função vetorial não-linear das entradas à rede pre-processadas por uma função $s(\cdot)$ sigmoidal. Adicionalmente, se a rede considerada satisfaz a condição de aproximação universal e a condição de regularidade, pode ser provado (vide [6,9] para maiores detalhes), que ela pode aproximar com qualquer grau de precisão, funções não-lineares e consequentemente sistemas dinâmicos arbitrários.

4. Observador Neural Adaptativo e Dinâmica do Erro de Estimção

Nesta seção, são explicitadas a dinâmica do erro de observação e estrutura do observador neural proposto. Basicamente uma RNA parametrizável linearmente é usada para substituir uma não-linearidade desconhecida na planta. Desta forma, o problema original de parametrização é transformado para outro mais simples no qual a estrutura da parametrização neural é conhecida e os pesos desconhecidos.

Somando e subtraindo-se $A\chi$, a equação (2.1) pode ser expressa como

$$\dot{\chi}(t) = A\chi + g(\chi, u) \quad (4.1)$$

onde $g(\chi, u) := f(\chi, u) - A\chi$, $A := \text{diag}(-a_i)$, $a_i > 0$ para $i=1, 2, \dots, n$.

Devido à condição de aproximação universal [9], a função não-linear $g(\chi, u)$ pode ser representada por uma RNA parametrizável linearmente (com uma matriz de pesos ideal e constante) mais um termo limitado que considera os erros de reconstrução neural.

Mais especificamente, a equação (4.1) pode ser escrita como

$$\dot{\chi}(t) = A\chi + BW^*S(\chi, u) + v(t) \quad (4.2)$$

onde $g(\chi, u) = BW^*S(\chi, u) + v(t)$, $v(t)$ é um vetor de erros de reconstrução que por (S1) é limitado, isto é, $\|v(t)\| \leq \bar{v}$ para alguma constante positiva \bar{v} .

$S : \mathcal{R}^{n+m} \mapsto \mathcal{R}^L$ conforme definido em (3.1), $B := \text{diag}(b_i)$, $b_i \neq 0$ para $i=1, 2, \dots, n$, é uma matriz diagonal de projeto necessária para aprimorar as estimativas, $W^* \in \mathcal{R}^{n \times L}$ (que é requerida unicamente para fins analíticos) é uma matriz de pesos ótimos, que similarmente a [9], pode ser definida como

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

onde \hat{W} é uma estimativa de W^* .

Com base em (4.2), um observador de estados pode ser escolhido como

$$\dot{\hat{x}}(t) = A\hat{x} + B\hat{W}S(\hat{x}, u) \quad (4.3)$$

$$\hat{y}(t) = C^T \hat{x} \quad (4.4)$$

e consequentemente o problema de projeto do observador neural adaptativo resume-se na obtenção de leis de adaptação estáveis para a matriz de pesos \hat{W} da RNA nas quais não seja necessária a utilização do erro de estimação de estado $\tilde{x} := \hat{x} - \chi$, já que isto implicaria a necessidade de se medir os estados que assume-se não disponíveis para medida.

Considerando-se (4.2) e (4.3), a dinâmica do erro de observação satisfaz

$$\dot{\tilde{x}}(t) = A\tilde{x} + B\tilde{W}S(\hat{x}, u) + \omega(t) - v(t) \quad (4.5)$$

$$\tilde{y}(t) = C^T \tilde{x} \quad (4.6)$$

onde $\tilde{W} := \hat{W} - W^*$, $\omega(t) := BW^*(S(\hat{x}, u) - S(\chi, u))$ é um termo de distúrbio, sendo obviamente $\|\omega(t)\| \leq \bar{\omega}$ para alguma constante $\bar{\omega}$ positiva, devido à função sigmoidal.

O observador neural adaptativo proposto é mostrado na fig. 4.1. Basicamente, uma RNA parametrizável linearmente é usada para aproximar uma parte da equação de estados da planta desconhecida. O ajuste dos pesos da rede é feito considerando-se o erro de estimação das saídas, que é disponível, pois conforme assumido, a matriz C em (2.2) é conhecida.

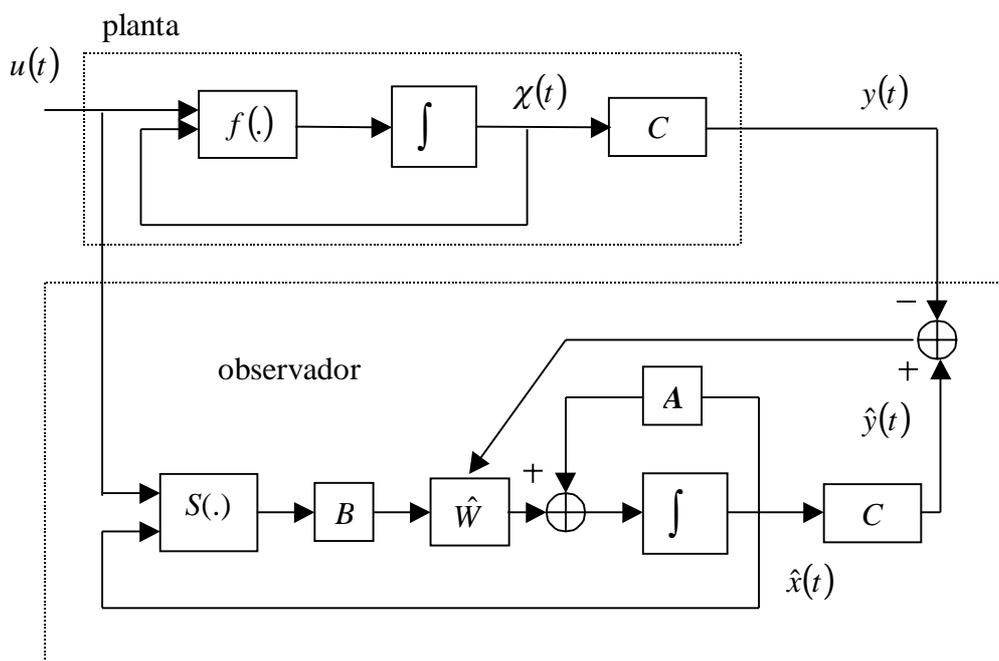


Fig. 4.1- Planta e observador adaptativo neural.

5. Algoritmo de Aprendizado Robusto e Propriedades do Observador

Nesta seção, no contexto da teoria de estabilidade de Lyapunov, será projetado um algoritmo de aprendizado robusto frente ao erro de reconstrução $v(t)$ e ao distúrbio $\omega(t)$. Com esta finalidade, empregaremos uma lei de adaptação tipo *switching σ -modification* [19] para o ajuste dos pesos em (4.3).

Teorema 5.1:

Considere a classe de sistemas descritos por (2.1)-(2.2), o observador neural (4.3) e a seguinte lei de adaptação para os pesos da RNA

$$\dot{\hat{w}}_i = \begin{cases} -K_i S(\hat{x}, u) \varphi(\tilde{y}) & \text{se } \|\hat{w}_i\| \leq M_i \\ -K_i S(\hat{x}, u) \varphi(\tilde{y}) - \sigma_i K_i \hat{w}_i & \text{se } \|\hat{w}_i\| > M_i \end{cases} \quad (5.1)$$

onde $\varphi(\tilde{y}) = C_s \tilde{x}$, $C_s = [c_{sij}] \in \text{span}$ (linhas de C),

$$\sigma_i \geq \frac{n S_0^2 \|\Delta_{si}^T\|^2}{2n_2 \lambda_{\min}(Q)}, \quad S_0 = \sup_{t \geq 0} [S(\hat{x}(t), u(t))], \quad n_2 \in (0, 1),$$

$$\Delta_s \in \mathfrak{R}^{nm}, \quad \hat{W}^T = [\hat{w}_1 \mid \hat{w}_2 \mid \dots \mid \hat{w}_n], \quad P = P^T > 0,$$

$K_i = K_i^T > 0 \in \mathfrak{R}^{L \times L}$. Então para $i=1, 2, \dots, n$
 $\tilde{x}_i, \tilde{w}_i, \tilde{y} \in L_\infty$.

Prova:

A prova é efetuada considerando-se uma função positiva definida e sua derivada em relação ao tempo, que é avaliada ao longo das trajetórias (4.5) e (5.1). É mostrado que a derivada da função positiva definida é menor ou igual a zero a partir de um valor V_0 fixo e constante, e conseqüentemente que todos os erros de estimação são limitados.

Considere a seguinte função positiva definida

$$V(\tilde{x}, \tilde{W}) = \tilde{x}^T R \tilde{x} + \frac{1}{2} \sum_{i=1}^n \tilde{w}_i^T K_i^{-1} \tilde{w}_i \quad (5.2)$$

onde $R > 0 \in \mathfrak{R}^{nm}$.

Derivando-se (5.2) em relação ao tempo, obtém-se

$$\dot{V} = \sum_{i=1}^n \left\{ \dot{\tilde{x}}_i \sum_{j=1}^n \{v_{ij} \tilde{x}_j\} + \tilde{x}_i \sum_{j=1}^n \{v_{ij} \dot{\tilde{x}}_j\} + \tilde{w}_i^T K_i^{-1} \dot{\tilde{w}}_i \right\} \quad (5.3)$$

Uma vez que C_s pode ser expressa como $C_s = BP - \Delta_s$, avaliando-se (5.3) ao longo das trajetórias (4.5) e (5.1), resulta

$$\begin{aligned}
\dot{V} = & \sum_{i=1}^n \left\{ -a_i \tilde{x}_i \sum_{j=1}^n \{r_{ij} \tilde{x}_j\} - \tilde{x}_i \sum_{j=1}^n \{r_{ij} a_j \tilde{x}_j\} + \right. \\
& + b_i \tilde{w}_i^T S \sum_{j=1}^n \{r_{ij} \tilde{x}_j\} + \tilde{x}_i \sum_{j=1}^n \{r_{ij} b_j \tilde{w}_j^T S\} - \\
& - b_i \tilde{w}_i^T S \sum_{j=1}^n \{p_{ij} \tilde{x}_j\} + \tilde{w}_i^T S \sum_{j=1}^n \{\Delta_{sij} \tilde{x}_j\} - \\
& - (v_i - \omega_i) \sum_{j=1}^n \{r_{ij} \tilde{x}_j\} - \tilde{x}_i \sum_{j=1}^n \{r_{ij} (v_j - \omega_j)\} - \\
& \left. - I^* \sigma_i \tilde{w}_i^T \hat{w}_i \right\} \quad (5.4)
\end{aligned}$$

onde I^* é uma função indicadora definida como $I^*=1$ se $\|\hat{w}_i\| > M_i$ e $I^*=0$ se $\|\hat{w}_i\| \leq M_i$.

Defina agora

$$P := R + R^T \quad (5.5)$$

Então, é fácil mostrar que existe uma matriz $Q = Q^T > 0$ tal que

$$A^T R + R A = -Q \quad (5.6)$$

Usando-se agora (5.5) em (5.4), resulta

$$\begin{aligned}
\dot{V} = & \sum_{i=1}^n \left\{ -2a_i r_{ii} \tilde{x}_i^2 - \sum_{\substack{j=1 \\ j \neq i}}^n \{(a_i + a_j) r_{ij} \tilde{x}_i \tilde{x}_j\} + \right. \\
& + \tilde{w}_i^T S \sum_{j=1}^n \{\Delta_{sij} \tilde{x}_j\} - \tilde{x}_i \sum_{j=1}^n \{p_{ij} (v_j - \omega_j)\} - \\
& \left. - I^* \sigma_i \tilde{w}_i^T \hat{w}_i \right\} \quad (5.7)
\end{aligned}$$

onde, por (5.6)

$$\sum_{i=1}^n \left\{ 2a_i r_{ii} \tilde{x}_i^2 + \sum_{\substack{j=1 \\ j \neq i}}^n \{(a_i + a_j) r_{ij} \tilde{x}_i \tilde{x}_j\} \right\} = \tilde{x}^T Q \tilde{x}.$$

Suponha agora que $n_1 + n_2 + n_3 = 1$, $n_1, n_2, n_3 \in (0,1)$.

Então, a equação (5.7) implica

$$\begin{aligned}
\dot{V} \leq & \sum_{i=1}^n \left\{ -n_1 \lambda_{\min}(Q) \tilde{x}_i^2 - \sigma_i \|\tilde{w}_i\|^2 - \right. \\
& - \frac{n_2 \lambda_{\min}(Q)}{n} \|\tilde{x}\|^2 + S_0 \|\Delta_{si}^T\| \|\tilde{w}_i\| \|\tilde{x}\| + \frac{\sigma_i}{2} \|\tilde{w}_i\|^2 - \\
& - \frac{n_3 \lambda_{\min}(Q)}{n} \|\tilde{x}\|^2 + (\bar{v} + \bar{\omega}) \|p_i\| \|\tilde{x}\| + \\
& \left. + \frac{1}{2} (1 - I^*) \sigma_i \|\tilde{w}_i\|^2 + \frac{I^* \sigma_i}{2} \|\hat{w}_i^*\|^2 \right\} \quad (5.8)
\end{aligned}$$

onde foi usada a seguinte desigualdade

$$\tilde{w}_i^T \hat{w}_i \geq \frac{1}{2} \left(\|\tilde{w}_i\|^2 - \|\hat{w}_i^*\|^2 \right).$$

Além disso, tendo em mente que

$$\frac{1}{2} (1 - I^*) \sigma_i \|\tilde{w}_i\|^2 \leq \begin{cases} \frac{\sigma_i M_i^2}{2} & \text{se } \|\hat{w}_i\| \leq M_i \\ 0 & \text{se } \|\hat{w}_i\| > M_i \end{cases} \quad (5.9)$$

e completando-se o quadrado adequadamente em (5.8), resulta

$$\begin{aligned}
\dot{V} \leq & \sum_{i=1}^n \left\{ -n_1 \lambda_{\min}(Q) \tilde{x}_i^2 - \sigma_i \|\tilde{w}_i\|^2 + \right. \\
& \left. + \frac{n(\bar{v} + \bar{\omega})^2 \|p_i\|^2}{4n_3 \lambda_{\min}(Q)} + \sigma_i M_i^2 \right\} \quad (5.10) \\
\leq & -\alpha V + k
\end{aligned}$$

onde

$$\alpha := \min \left\{ \frac{n_1 \lambda_{\min}(Q)}{\lambda_{\max}(R)}, \frac{\sigma_i}{\lambda_{\max}(K_i^{-1})}; i = 1, 2, \dots, n \right\} \quad (5.11)$$

$$k := \sum_{i=1}^n \left\{ \frac{n(\bar{v} + \bar{\omega})^2 \|p_i\|^2}{4n_3 \lambda_{\min}(Q)} + \sigma_i M_i^2 \right\}$$

Por conseguinte, $\dot{V} \leq 0$ em (5.10) sempre que $V \geq V_0 = k/\alpha$, implicando que V é limitada por um V_0 fixo e constante. Então, $\tilde{w}_i, \tilde{x}_i \in L_\infty$ e por (4.6) $\tilde{y} \in L_\infty$. ■

Comentário 5.1:

Na prova de estabilidade, um limitante para V e por conseguinte para os erros de estimação é fornecido por (5.11). Consequentemente, estes erros poderão ser diminuídos escolhendo-se convenientemente as

matrizes Δ_s , A , B e K_i . Por outro lado, o efeito negativo de \bar{v}_j e $\bar{\omega}_j$ na estimação também pode ser atenuado com uma escolha adequada de $S(\hat{x}, u)$ e $s(\cdot)$.

Comentário 5.2:

É importante ressaltar que o observador neural proposto unicamente pode ser aplicado em sistemas observáveis localmente. Mais especificamente, a existência de uma matriz C_s que permita uma adequada estimação de todos os estados está garantida quando pelo menos alguma combinação linear das saídas

medidas, isto é $C_{sk}^T \chi = \sum_{j=1}^{\bar{q}_i} \{\eta_j^k y_j\}$, para algum $\eta^k \neq 0$

e $\bar{q}_i \in \{1, 2, \dots, q\}$, é tal que o sistema (2.1) é observável em uma vizinhança U_{χ_0} de χ_0 , isto é, $\text{rank} \{d(L_f^j C_{sk}^T \chi), 0 \leq j \leq n-1\} = n, \forall \chi \in U_{\chi_0}$ [15].

Comentário 5.3:

Embora a análise de estabilidade do observador proposto empregue argumentos usuais na teoria de controle adaptativo de sistemas lineares, a principal característica da análise reportada aqui consiste em que nenhuma suposição de SPR ou dissipatividade é feita objetivando-se o projeto de leis de adaptação estáveis. Este resultado pode ser considerado como uma contribuição para estender as técnicas de projeto de observadores não-lineares.

Comentário 5.4:

Conforme reportado na literatura, leis de adaptação tipo *switching* σ -*Modification* podem ser de difícil aplicação. Principalmente porque é necessário conhecer *a priori* um limitante inferior para a constante de projeto M_i , tal que $M_i \geq \|w_i^*\|$, podendo resultar instabilidade quando está hipótese é violada. Neste sentido, objetivando-se contornar a dificuldade supracitada, também podem ser empregadas leis de adaptação tipo *e-Modification* e *dynamic* σ -*Modification* em combinação com os mesmos argumentos usados neste artigo (vide [21-22] para maiores detalhes).

6. Conclusões

Neste artigo, foi proposto um observador adaptativo neural para sistemas MIMO que apresentam uma estrutura geral e desconhecida nos estados e uma forma linear na equação de saída. São usadas RNA parametrizáveis linearmente para aproximar uma parte da planta que é desconhecida, e via métodos de

Lyapunov é provada a estabilidade do observador. Convém ressaltar que nenhuma hipótese de condição SPR é feita na análise, facilitando a extensão para sistemas com saídas que dependem não linearmente dos estados.

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] WERBOS, P. J. - Neural Networks for Control and System Identification, *Proceedings of the 28-th CDC*, Tampa, FL., 1989.
- [2] SHOURESHI, R.; CHU, R.; TENORIO, M. - Neural Networks for Systems Identification, *Proceedings 1989 Amer. Contr. Conf.*, Vol. 1, p. 916-21, 1989.
- [3] NARENDRA, K.S. & PARTHASARATHY, K. - Identification and Control of Dynamical Systems Using Neural Networks, *IEEE Transactions on Neural Networks*, 1:252-62, march 1990.
- [4] GUPTA, M.M. & RAO, D.H. (Eds.) - *Neuro Control Systems: Theory and Applications*, IEEE Press, New York, 1994.
- [5] MILLER, W.T.; SUTTON, R.S.; WERBOS, P.J. (Eds.) - *Neural Networks for Control*, MIT Press., Cambridge, Massachusetts, 1995.
- [6] KOSMATOPOULOS, E.B.; POLYCARPOU, M.M.; CHRISTODOULOU, M.A.; IOANNOU, P.A. - High-Order Neural Networks Structures for Identification of Dynamical Systems, *IEEE Transactions on Neural Networks*, Vol. 6, No. 2, p. 422-31, march 1995.
- [7] ROVITHAKIS, G.A. & CHRISTODOULOU, M.A. - Neural Adaptive Regulation of Unknown Nonlinear Dynamical Systems, *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 27, No. 5, p. 810-21, october 1997.
- [8] SUN, F.; SUN, Z.; WOO, P.Y. - Stable Neural-Network-Based Adaptive Control for Sampled-Data Nonlinear Systems, *IEEE Transactions on Neural Networks*, Vol. 9, No. 5, september 1998.
- [9] POLYCARPOU, M.M. & IOANNOU, P.A. - 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.
- [10] CHEN, F.C. & KHALIL, H.K. - Adaptive Control of a Class of Nonlinear Discrete-Time Systems Using Neural Networks, *IEEE Transactions on Automatic Control*, Vol. 40, No. 5, p. 791-801, may 1995.
- [11] KIM, Y.H. & LEWIS, F.L. - A Dynamic Recurrent Neural-Network-Based Adaptive Observer for a Class of Nonlinear Systems, *Automatica*, Vol. 33, No. 8, p. 1539-43, 1997.
- [12] ZHU, R.; CHAI, T.; SHAO, C. - Robust Nonlinear Adaptive Observer Design Using Dynamical Recurrent Neural Networks, *American Control Conference*, Albuquerque, New Mexico, p. 1096-100, june 1997.

- [13] STROBL, U.; LENZ, U.; SCHRODER – Systematic Design of Stable Neural Observer for a Class of Nonlinear Systems, Proceedings of the *1997 IEEE International Conference on Control Applications*, Hartford, october 1997.
- [14] BASTIN, G. & GEVERS, M.R. – Stable Adaptive Observers for Nonlinear Time-Varying Systems, *IEEE Transactions on Automatic Control*, Vol. 33, No. 7, p. 650-8, july 1988.
- [15] MARINO, R. – Adaptive Observers for Single Output Nonlinear Systems, *IEEE Transactions on Automatic Control*, Vol. 35, No. 9, p. 1054-8, september 1990.
- [16] MARINO, R. & TOMEI, P. – Global Adaptive Observers for Nonlinear Systems via Filtered Transformations, *IEEE Transactions on Automatic Control*, Vol. 37, No. 8, p. 1239-45, august 1992.
- [17] MARINO, R. & TOMEI, P. – Adaptive Observers with Arbitrary Exponential Rate of Convergence for Nonlinear Systems, *IEEE Transactions on Automatic Control*, Vol. 40, No. 7, p. 1300-4, july 1995.
- [18] KRSTIC, M. & KOKOTOVIC, P.V – Adaptive Nonlinear Output-Feedback Schemes with Marino-Tomei Controller, *IEEE Transactions on Automatic Control*, Vol. 41, No. 2, p. 274-80, february 1996.
- [19] NARENDRA, K.S .& ANNASWAMY, A.M. - *Stable Adaptive Systems*, New Jersey, Prentice Hall Inc., 1989.
- [20] CHEN, C.T. – *Linear Systems Theory and Design*, CBS College Publishing, New York, 1984.
- [21] VARGAS, J.A.R. & HEMERLY, E.M. – Robust Neural Adaptive Observer for MIMO Nonlinear Systems, Proceedings of the *1999 IEEE Systems, Man and Cybernetics Conference*, october 1999.
- [22] VARGAS, J.A.R. & HEMERLY, E.M. – Stable Adaptive Observer Design via Linearly Parameterized Neural Networks, submetido ao *38th IEEE Conference on Decision and Control*, december 1999.