

## SISTEMA NEBULOSO-EVOLUTIVO APLICADO A IDENTIFICAÇÃO DE SISTEMAS DINÂMICOS NÃO-LINEARES

**Leandro dos Santos Coelho**

Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS)  
Laboratório de Automação e Sistemas, Centro de Ciências Exatas e de Tecnologia  
Pontifícia Universidade Católica do Paraná  
Rua Imaculada Conceição, 1155, CEP 80215-030, Curitiba, PR, Brasil  
e-mail: lscoelho@rla01.pucpr.br

**Resumo.** *Este artigo apresenta o projeto de um sistema nebuloso do tipo Takagi-Sugeno-Kang. Neste projeto é utilizada uma estratégia evolutiva para otimização da parte antecedente do sistema nebuloso, enquanto o algoritmo dos mínimos quadrados é utilizado no projeto da parte conseqüente. O sistema nebuloso é avaliado em dois estudos de caso: (i) previsão de um sistema caótico denominado mapa de Lozi, e (ii) previsão do sistema de controle de um sistema fisiológico. Os resultados de simulação indicam que a proposta de otimização baseada em uma estratégia evolutiva é uma abordagem promissora para aplicações de identificação não-linear e previsão de séries temporais.*

**Palavras-chave:** *sistema nebuloso, identificação de sistemas, sistemas não-lineares.*

### 1. INTRODUÇÃO

A concepção de modelos matemáticos para a representação de sistemas dinâmicos complexos é um procedimento relevante com aplicação prática. Entretanto, em geral, não é uma tarefa simples a construção de modelos matemáticos adequados para os propósitos de engenharia. Nas últimas décadas diversas concepções de algoritmos para modelagem e identificação de sistemas dinâmicos complexos têm sido propostos na literatura, tais como: métodos freqüenciais, técnicas baseadas em estimativas de modelos Wiener, Hammerstein, bilinear e Volterra, regressão não-linear, *wavelets* e identificação recursiva (Haber & Unbehauen, 1990; Ljung, 2001).

Uma abordagem relevante entre tantas outras para representação de sistemas complexos é a dos sistemas nebulosos. Nos últimos anos, os pesquisadores (Rovatti e Guerrieri, 1996; Wang, 1998; Le Schiavo & Luciano, 2001) têm proposto um variado espectro de metodologias de identificação baseadas em sistemas nebulosos, a citar os modelos nebulosos de Mamdani, Larsen, Tsukamoto, relacional e Takagi-Sugeno-Kang (*TSK*), para lidarem com sistemas não-lineares, “mal definidos” e que apresentam incertezas.

Os modelos nebulosos de *TSK* (Takagi & Sugeno, 1985; Sugeno & Kang, 1988) apresentam características que os tornam promissores para aplicações de identificação de sistemas complexos, entre as quais a de serem aproximadores universais de funções com precisão arbitrária como algumas abordagens de projeto com redes neurais artificiais (Ying, 1998; Giiven & Passino, 2001). Além disso, os modelos nebulosos de *TSK* apresentam alto poder de interpolação com um número reduzido de regras de produção.

Este artigo apresenta o projeto de um sistema nebuloso de *TSK* baseado em otimização através de uma estratégia evolutiva (*EE*) com adaptação do sistema independente de coordenadas da distribuição normal do operador de mutação. A *EE* é utilizada para o projeto da parte antecedente, enquanto o algoritmo dos mínimos quadrados é utilizado na otimização da parte conseqüente do

sistema nebuloso. Este sistema nebuloso é avaliado para dois estudos de caso: (i) previsão do comportamento dinâmico do mapa de Lozi, e (ii) previsão de um sistema de controle fisiológico regido pela equação diferencial de Mackey-Glass.

O artigo é organizado da seguinte forma. Na seção 2, os fundamentos do sistema nebuloso de *TSK* e a otimização baseada em uma *EE* e algoritmo dos mínimos quadrados são apresentados. A descrição dos dois estudos de caso de identificação de sistemas é abordada na seção 3. As simulações e a análise dos resultados obtidos da aplicação da abordagem nebuloso-evolutiva são apresentadas na seção 4. Na seção 5 são apresentadas a conclusão e os futuros trabalhos.

## 2. SISTEMA NEBULOSO DE TAKAGI-SUGENO-KANG

A identificação de sistemas através de modelos nebulosos de *TSK* é realizada utilizando-se os dados de entrada(s) e/ou saída(s) do sistema dinâmico em estudo como entradas do sistema nebuloso para obtenção de uma previsão da(s) saída(s) atual(is) do sistema dinâmico. O procedimento de identificação, neste caso, é composto de duas partes: (i) identificação da estrutura, e (ii) identificação dos parâmetros.

Na identificação da estrutura do sistema nebuloso é necessário identificar a estrutura do antecedente e do conseqüente. Os parâmetros do conseqüente são coeficientes de equações lineares, sendo estes parâmetros obtidos pelo algoritmo dos mínimos quadrados. Esta forma de desenvolvimento de sistema nebuloso é inspirada na teoria clássica de sistemas e, alguns desenvolvimentos no campo das redes neurais. Os modelos nebulosos de *TSK* consistem de regras de produção IF-THEN (SE <condição> ENTÃO <ação>) que podem ser representadas na forma geral:

$$R^{(j)} : \text{IF } z_1 \text{ IS } A_1^j \text{ AND } \dots \text{ AND } z_m \text{ THEN} \quad (1)$$

$$g_j = w_0^j + w_1^j u_1^j + \dots + w_{q_j}^j u_{q_j}^j$$

onde o antecedente *IF* define a parte antecedente (premissa) enquanto as funções da regra *THEN* constituem-se na parte conseqüente do sistema nebuloso;  $\underline{z} = [z_1, \dots, z_m]^T$  é o vetor de entradas da parte premissa; e  $A_i^j$  são *labels* dos conjuntos nebulosos;  $\underline{u} = [u_1^j, \dots, u_{q_j}^j]^T$  representa o vetor de entradas para parte conseqüente de  $R^{(j)}$  que é constituída de  $q_j$  termos;  $g_j = g_j(\underline{u}^j)$  denota a  $j$ -ésima regra de saída que é um polinômio linear dos termos de entrada do conseqüente  $u_i^j$ ; e  $\underline{w}^j = [w_0^j, w_1^j, \dots, w_{q_j}^j]^T$  são os coeficientes polinomiais que formam o conjunto de parâmetros dos conseqüentes. Cada *label* lingüístico  $A_i^j$  é associada com a função de pertinência; enquanto  $\mu_{A_i^j}(z_i)$  é descrita por

$$\mu_{A_i^j}(z_i) = \exp\left[-\frac{1}{2} \frac{(z_i - m_{ij})^2}{\sigma_{ij}^2}\right] \quad (2)$$

onde  $m_{ij}$  e  $\sigma_{ij}$  são o valor médio e o desvio padrão da função de pertinência do tipo Gaussiana, respectivamente. A união de todos estes parâmetros define o conjunto de parâmetros da premissa. O poder da regra  $R^{(j)}$  representa seu grau de excitação e é regido pela equação

$$\mu_j(\underline{z}) = \mu_{A_1^j}(z_1) \cdot \mu_{A_2^j}(z_2) \cdot \dots \cdot \mu_{A_m^j}(z_m) \quad (3)$$

Os conjuntos nebulosos que dizem respeito a uma regra formam uma região nebulosa (*cluster*) dentro do espaço da premissa,  $A_1^j \times A_2^j \times \dots \times A_m^j$ , com uma distribuição de pertinência descrita pela equação (3). Dado os vetores de entrada  $\underline{z}$  e  $\underline{u}^j$ ,  $j=1, \dots, M$ , a saída final do sistema nebuloso é inferido pela média ponderada das saídas locais  $g_j(\underline{u}^j)$ , onde

$$y = \sum_{j=1}^M v_j(\underline{z}) \cdot g_j(\underline{u}^j) \quad (4)$$

onde  $M$  denota o número de regras e  $v_j(\underline{z})$  é a intensidade do poder normalizado de  $R^{(j)}$  que é definida por

$$v_j(\underline{z}) = \frac{\mu_j(\underline{z})}{\sum_{j=1}^M \mu_j(\underline{z})} \quad (5)$$

## 2.1. Otimização do sistema nebuloso de *TSK* através de uma estratégia evolutiva

O desempenho de uma *EE* comparado com o de outros algoritmos evolutivos (*AEs*) depende da configuração adequada dos seus parâmetros internos de controle. As *EEs* apresentam facilidades no ajuste de tais parâmetros através da utilização de procedimento de auto-adaptação. Enquanto, nos algoritmos genéticos, outro *AE*, os parâmetros de controle são ajustados, usualmente, através de métodos heurísticos de tentativa e erro.

O princípio da auto-adaptação é facilitar o controle implícito dos parâmetros da *EE* pela incorporação deste princípio na representação do indivíduo com a evolução usual das variáveis-objeto (possíveis soluções do problema). O termo denominado parâmetros da estratégia (ou parâmetros de controle) referem-se aos parâmetros que controlam o procedimento de busca evolutiva, tais como: taxa de mutação, variância da mutação e taxa de recombinação de um *AE* (Bäck *et al.*, 1997).

Muitas das pesquisas relacionadas aos princípios de auto-adaptação em *AEs* tratam de parâmetros relacionados com operador de mutação. A técnica de auto-adaptação é geralmente empregada com sucesso nos ajustes de variâncias e de covariâncias em relação a uma distribuição normal  $n$ -dimensional.

Angeline (1995) afirma que é possível adaptar-se dinamicamente os aspectos de processamento de um *AE* antecipando as regularidades do ambiente, aprimorando o procedimento de otimização e enfatizando a rapidez na busca dos parâmetros. Os *AEs* que apresentam mecanismos adaptativos (*AEMAs*) distinguem-se pela configuração dinâmica dos parâmetros selecionados ou mesmo operadores durante o ciclo evolutivo de otimização. Os *AEMAs* têm uma vantagem sobre os *AEs* básicos, pois são mais reativos em antecipar as particularidades do problema, ou mesmo em algumas formulações podem dinamicamente adquirir informação sobre as regularidades no problema e explorá-las. Segundo Angeline (1995), os *AEMAs* podem ser separados em três níveis onde os parâmetros adaptativos estão presentes, que são:

- (i) *nível populacional*: os métodos adaptativos ajustam dinamicamente os parâmetros, que são globais à população inteira;
- (ii) *nível individual*: os métodos adaptativos modificam a maneira que um indivíduo da população é afetado pelos operadores de mutação;
- (iii) *nível de componente*: os métodos adaptativos alteram a forma pela qual os componentes de cada indivíduo são manipulados independentemente dos outros indivíduos da população.

Os mecanismos de auto-adaptação, no âmbito de componente dos parâmetros da estratégia adaptativa, providenciam uma das características principais do sucesso das *EEs*. As *EEs* utilizam princípios de busca no espaço de variáveis-objeto e estratégia interna de controle dos parâmetros, simultaneamente (Beyer, 1995). A abordagem de *EEs* com adaptação do sistema independente de coordenadas para o operador de mutação, tratada neste artigo, foi proposta por Hansen & Ostermeier, (1996) e Ostermeier & Hansen (1999).

O operador de mutação é o operador principal de uma *EE* e sem a mudança na distribuição do operador de mutação durante a seqüência de gerações do ciclo evolutivo, existe uma diminuição na probabilidade da solução evoluir para uma solução adequada.

O caminho de evolução — “caminho” de distribuição da população no espaço de busca ao longo de um número de gerações — revela informações do ciclo evolutivo, principalmente pelas correlações entre os passos de mutação que são sucessivamente selecionados na seqüência de gerações. Se os passos de mutação selecionados são correlacionados paralelamente (produto escalar maior que zero), ou seja, os passos de evolução estão na mesma direção, o caminho de evolução é comparativamente longo. Se, por outro lado, os passos de mutação são correlacionados de forma anti-paralela (produto escalar menor que zero), o caminho de evolução é comparativamente mais curto. Conseqüentemente, para realizar-se passos de mutação mais eficientes é melhor não se possuir uma correlação entre os passos de mutação selecionados no caminho de evolução (Hansen & Ostermeier, 1996).

Hansen & Ostermeier (1996) sugerem o *princípio da adaptação fundamental* para remover a correlação entre os passos de mutação selecionados sucessivamente, que diz: “*Uma adaptação aceitável necessita reduzir a diferença entre as distribuições do caminho de evolução atual e um caminho de evolução, através de uma seleção aleatória com relação aos parâmetros adaptados*”.

Uma abordagem baseada no princípio da adaptação fundamental é adotada neste artigo. A abordagem é denominada de adaptação da matriz de covariância e é aplicada a uma  $(\mu, \lambda)$ -*EE*, onde os  $\lambda$  descendentes competem para sobreviver e os  $\mu$  ancestral(is) é(são) completamente substituído(s) a cada geração. A seguir são apresentadas equações que regem esta abordagem de  $(\mu, \lambda)$ -*EE* para  $\mu=1$ . As equações são apresentadas de forma detalhada em Hansen & Ostermeier (1996). O passo de mutação para o vetor variável objeto (vetor solução),  $x$ , para cada descendente  $k = 1, \dots, \lambda$  é dado pela equação,

$$x^{D_k} = x^A + \delta^A B^A z_k \quad (6)$$

onde  $x = (x_1, \dots, x_n)^t \in \mathfrak{R}^n$  é o vetor variável-objeto (variáveis que são as soluções para o problema de otimização) a ser otimizado,  $n$  é a dimensão do problema;  $A$  é o índice para o Ancestral;  $D_k$  é o índice para o Descendente  $k = 1, \dots, \lambda$ ;  $z = (z_1, \dots, z_n)^t : z_i$  são variáveis independentes com distribuição normal,  $N(0,1)$ ,  $z_k \in \mathfrak{R}^n$  ( $k = 1, \dots, \lambda$ ) são realizações independentes de  $z$ ;  $\delta > 0$  é o tamanho de passo global;  $B \in \mathfrak{R}^{n \times n}$  é a matriz que transforma linearmente  $z$  (a matriz  $B$  pode ser vista como a base em que a distribuição normal trabalha).

A adaptação da distribuição da mutação é separada em duas etapas. Primeiro, a matriz de covariância é adaptada, depois toda a variância é adaptada. A soma acumulada em  $s$  e a adaptação da matriz covariância,  $C$ , são dadas pelas equações:

$$s^{D_k} = (1 - c) \cdot s^A + c_u B^A z_k \quad (7)$$

$$C^{D_k} = (1 - c_{cov}) \cdot C^A + c_{cov} \cdot s^{D_k} (s^{D_k})^t \quad (8)$$

onde  $c \in ]0,1[$  determina o tempo acumulado para  $s$ ;  $c_u = \sqrt{c \cdot (2 - c)}$  normaliza a variância de  $s$  para resolver a equação  $1^2 = (1 - c)^2 + c_u^2$ ;  $s^{início} = 0$ ;  $C \in ]0,1[$  é a matriz de covariância da distribuição

de mutação. O valor de  $C$  determina  $B$ , ainda que  $Bz \sim N(0, C)$  seja mantido, ou seja,  $C = BB^t$ ; e  $c_{cov} \in ]0,1[$  determina o tempo da média das distribuições  $ss^t$  sobre uma seqüência de gerações.

A equação (8) é bastante similar a regra de atualização de métodos quase-Newton utilizados em otimização clássica. Em ambos os casos, a estimação de segunda ordem da topologia do problema é realizada. O tamanho de passo global,  $\delta$ , é adaptado de uma forma similar ao proposto em Ostermeier *et al.* (1994) e é denominada de “adaptação do tamanho de passo acumulado”. Neste caso, a soma dos tamanhos de mutação e adaptação de  $\delta$  são regidos pelas seguintes equações:

$$s_{\delta}^{D_k} = (1 - c) \cdot s_{\delta}^A + c_u B_{\delta}^A z_k \quad (9)$$

$$\delta^{D_k} = \delta^A \cdot \exp\left\{\beta \cdot \left(\|s_{\delta}^{D_k}\| - \hat{\chi}_n\right)\right\} \quad (10)$$

onde  $B_{\delta}^A \in \mathfrak{R}^{n \times n}$  é igual a  $B^A$  com colunas normalizadas;  $c \in ]0,1[$  determina o tempo acumulado para  $s$ ;  $c_u = \sqrt{c \cdot (2 - c)}$  normaliza a variância de  $s$  para resolver a equação  $1^2 = (1 - c)^2 + c_u^2$ ;  $s_{\delta}^{inicio} = 0$ ;  $\beta$  é um parâmetro para diminuição da variação do tamanho de passo entre as sucessivas gerações;  $\hat{\chi}_n = \sqrt{n} \left(1 - \frac{1}{4n} + \frac{1}{21n^2}\right)$  aproxima a expectativa da distribuição de  $\chi_n$ , em que é a distribuição do comprimento de uma vetor aleatório com distribuição  $N(0, I)$  em  $\mathfrak{R}^n$ .

A equação (9) é quase igual a equação (7). A diferença é a normalização das colunas em  $B_{\delta}$  que é importante para derivar o comprimento esperado de  $s_{\delta}$ . A equação (10) adapta  $\delta$  para reduzir a diferença entre o comprimento do caminho de evolução “normalizado” atual  $\|s_{\delta}\|$  e seu comprimento esperado. Os parâmetros de projeto adotados no procedimento de otimização do sistema nebuloso de *TSK* são os recomendados por Hansen & Ostermeier (1996), ou seja,  $c = 1/\sqrt{n}$ ,  $\beta = 1/n$  e  $c_{cov} = 2/n^2$ .

A parte consequente do sistema nebuloso é realizada pelo algoritmo dos mínimos quadrados em batelada. Os detalhes deste algoritmo são apresentados em Box *et al.* (1994).

### 3. DESCRIÇÃO DOS ESTUDOS DE CASO

#### 3.1. Estudo de Caso 1: Mapa de Lozi

Uma série temporal pode ser definida como uma função de uma variável independente (tempo  $t$ ), vinculada a um sistema dinâmico em que uma descrição matemática é desconhecida (ou considerada como tal). A característica principal de tais séries é que o seu comportamento futuro não pode ser previsto exatamente, como pode ser previsto de uma função determinística conhecida em  $t$ . Contudo, o comportamento de uma série temporal pode algumas vezes ser antecipado através de procedimentos estocásticos. O mapa de Lozi (Chen *et al.*, 1997) constitui-se de uma série temporal que apresenta mapas envolvendo funções não-diferenciáveis e é descrito pela seguinte equação:

$$y(t) = -P \cdot |y(t-1)| + Q \cdot y(t-2) + 1 \quad (11)$$

onde  $t$  é a variável tempo (amostras) e  $y$  é a saída do sistema. O mapa de Lozi, abordado neste artigo, apresenta um comportamento de atrator caótico, pois foi utilizado valores de  $P = 1,8$  e  $Q = 0,4$  nas simulações. Nas simulações realizadas adota-se 100 amostras para aprendizado (fase de estimação) do sistema nebulosos de *TSK* e outras 100 amostras para validação do sistema nebuloso obtido.

### 3.2. Estudo de Caso 2: Sistema fisiológico de Mackey e Glass

A série temporal determinada pela equação diferencial de Mackey e Glass (Mackey & Glass, 1977) descreve um sistema de controle fisiológico. A equação de Mackey e Glass é uma série temporal obtida pela integração da equação diferencial

$$\frac{dy(t)}{dt} = \frac{Fy(t-\tau)}{1+y^G(t-\tau)} - Hy(t) \quad (12)$$

As simulações deste artigo são realizadas para  $F=0,2$ ;  $H=0,1$ ;  $G=10$  e  $\tau=17$ . Neste caso, o sistema fisiológico exibe um comportamento caótico. O conjunto de dados utilizado consiste de 2000 amostras. As amostras 1 a 1000 são empregadas na fase de estimação e as amostras 1001 a 2000 para a fase de validação do sistema nebuloso de *TSK*. Nos experimentos realizados, os dados da série temporal de Mackey e Glass são obtidos pela aplicação do método de Runge e Kutta de 4ª ordem para condições iniciais de  $x(0) = 1,2$  e  $x(t-\tau) = 0$ , para  $0 \leq t \leq \tau$  e passo de tempo unitário.

## 4. APLICAÇÕES E RESULTADOS

O procedimento de análise dos resultados obtidos nos problemas de identificação não-linear é dividido nas seguintes etapas: (i) obtenção dos dados do sistema dinâmico (dados de entrada e saída do estudo de caso), (ii) escolha da estrutura utilizada para representar o modelo (modelo nebuloso de *TSK*), (iii) determinação de um procedimento de otimização adequado para o tratamento do modelo do processo (usando uma estratégia evolutiva e algoritmo dos mínimos quadrados), (iv) estimação dos parâmetros do modelo matemático (*fase de estimação*), e (v) a validação do modelo matemático (*fase de validação ou de testes*). O critério de desempenho avaliado é a soma do erro quadrático, *ISE*, entre a saída real,  $y(t)$ , e saída estimada,  $\hat{y}(t)$ , do sistema dinâmico. Os resultados obtidos para o modelo nebuloso de *TSK* com otimização através da estratégia evolutiva e mínimos quadrados são apresentados nas tabelas 1 e 2, respectivamente.

Tabela 1: Resultados obtidos para um número diferente de funções de pertinência (*fp*) através do sistema nebuloso de *TSK* para o mapa de Lozi (usando como entradas:  $y(t-1)$  e  $y(t-2)$  e saída:  $y(t)$ )

<i>fp</i>	<i>fase de estimação (aprendizado)</i>				<i>fase de validação (teste)</i>			
	<i>ISE</i>	<i>erro máximo</i>	<i>erro médio</i>	<i>desvio padrão do erro</i>	<i>ISE</i>	<i>erro máximo</i>	<i>erro médio</i>	<i>desvio padrão do erro</i>
4	6,9024	0,6357	-0,0175	0,2635	5,1976	0,6659	0,0160	0,2309
5	2,7478	0,3913	-0,0037	0,1666	2,1185	0,3913	0,0042	0,1477
6	3,2374	0,4316	-0,0052	0,1808	2,3594	0,3676	0,0056	0,1559
7	2,3561	0,3787	0,0011	0,1543	1,8573	0,3080	-0,0011	0,1384
8	2,2594	0,3676	-0,0050	0,1510	2,0202	0,3834	0,0053	0,1442
9	1,1431	0,3631	$-9,6 \times 10^{-4}$	0,1074	0,7896	0,2533	0,0010	0,0902
10	0,8955	0,2911	$-2,5 \times 10^{-4}$	0,0951	0,6952	0,2458	$3,1 \times 10^{-4}$	$3,0 \times 10^{-4}$
11	0,6754	0,1897	-0,0014	0,0826	0,5118	0,2038	0,0014	0,0726
12	0,6536	0,1912	-0,0014	0,0812	0,4973	0,2017	0,0014	0,0716
15	0,6310	0,3034	-0,0013	0,0798	0,3989	0,1797	0,0015	0,0641
20	0,2024	<b>0,1218</b>	-0,0019	0,0452	0,1869	0,1302	-0,0031	0,0438
25	<b>0,1617</b>	0,1265	<b><math>5,9 \times 10^{-4}</math></b>	<b>0,0404</b>	<b>0,1483</b>	<b>0,1258</b>	<b>-0,0027</b>	<b>0,0390</b>

Tabela 2: Resultados obtidos com o sistema nebuloso de *TSK* (usando  $y(t-1)$ ,  $y(t-6)$ ,  $y(t-12)$ ,  $y(t-18)$  como entradas e  $y(t)$  como saída) para a identificação do sistema de Mackey e Glass

<i>fp</i>	<i>fase de estimação (aprendizado)</i>				<i>fase de validação (teste)</i>			
	<i>ISE</i>	<i>erro máximo</i>	<i>erro médio</i>	<i>desvio padrão do erro</i>	<i>ISE</i>	<i>erro máximo</i>	<i>erro médio</i>	<i>desvio padrão do erro</i>
4	0,5019	0,0525	$7,6 \times 10^{-5}$	0,0224	0,5110	0,0521	$-7,5 \times 10^{-5}$	0,0229
6	0,2857	0,0492	$4,1 \times 10^{-4}$	0,0169	0,2773	0,0331	$-4,3 \times 10^{-4}$	0,0169
7	0,1016	<b>0,0236</b>	<b><math>7,0 \times 10^{-5}</math></b>	0,0101	0,1032	0,0241	<b><math>-5,1 \times 10^{-5}</math></b>	0,0103
8	<b>0,0858</b>	0,0379	$1,3 \times 10^{-4}$	<b>0,0093</b>	<b>0,0782</b>	<b>0,0215</b>	$-1,4 \times 10^{-4}$	<b>0,0089</b>

Os resultados para o sistema nebuloso de *TSK* com a estratégia evolutiva e técnica dos mínimos quadrados foram adequados para identificação dos dois estudos de caso (ver tabelas 1 e 2). Nas figuras 1 e 2 são apresentados os melhores resultados obtidos com o modelo nebuloso de *TSK* para os dois estudos de caso.

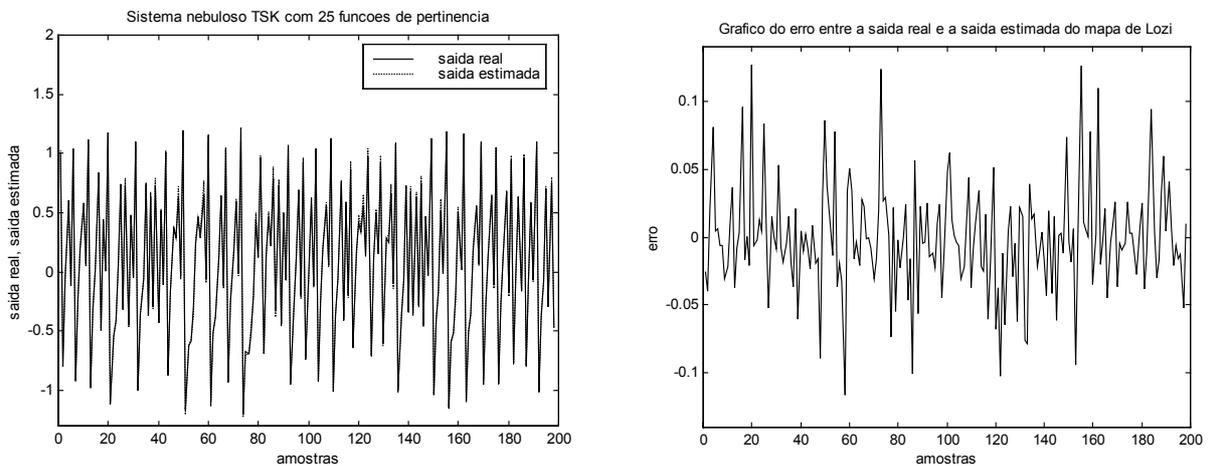


Figura 1. Resultados da previsão do modelo de Lozi com otimização do modelo de *TSK* via *EE* e algoritmo dos mínimos quadrados (25 funções de pertinência para cada entrada).

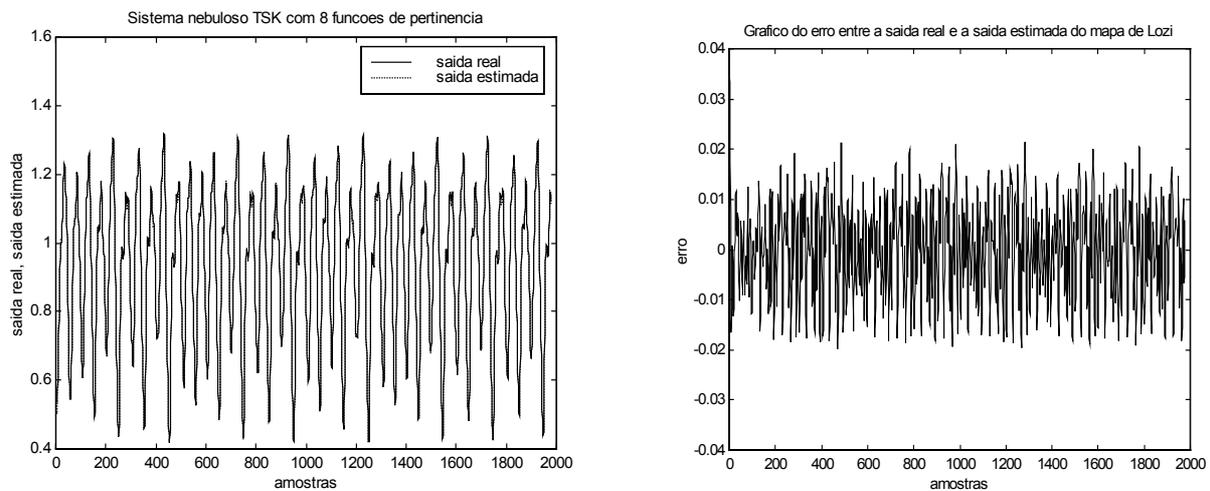


Figura 2. Resultados da previsão do modelo de Mackey e Glass via modelo de *TSK* com otimização via *EE* e algoritmo dos mínimos quadrados (8 funções de pertinência para cada entrada).

Os resultados obtidos mostram a robustez do sistema nebuloso de *TSK* na previsão das séries temporais. Entretanto, alguns questionamentos podem ser realizados. A solução do problema de seleção estrutural que está presente em um sistema nebuloso de *TSK* depende dos valores atribuídos para os centros da função de base, em termos de quantidade e posição. Neste caso, a estratégia evolutiva com operador de mutação adaptativo mostrou-se promissora, apresentando uma minimização do critério de desempenho *ISE* adequada para os dois estudos de caso. Em síntese, existe um compromisso entre o número de funções de pertinência escolhidas no projeto e a qualidade de aproximação do sistema nebuloso de *TSK* para a previsão de séries temporais.

## 5. CONCLUSÃO

Os sistemas nebulosos são usualmente denominados de estimadores livres de modelo, pois os sistemas nebulosos estimam relações de entrada e saída sem a necessidade de um modelo analítico de como as entradas dependem das saídas. Além disso, codificam a informação amostrada em uma estrutura distribuída de forma paralela denominada de estrutura nebulosa. Existem diversas abordagens de sistemas nebulosos utilizados para propósitos de identificação e previsão, tais como os modelos nebulosos relacionais, modelos nebulosos baseados em regras e modelos nebulosos interpolativos.

Neste artigo é tratada a aplicação de sistemas nebulosos interpolativos (funcionais) do tipo *TSK* para o tratamento de problemas de identificação de sistemas complexos. O sistema nebuloso de *TSK* com otimização através de uma estratégia evolutiva adaptativa (parte antecedente) e mínimos quadrados (parte conseqüente) foi avaliado em dois estudos de casos: (i) previsão do comportamento dinâmico do mapa de Lozi, e (ii) previsão da equação diferencial de Mackey e Glass que esta descreve um sistema de controle fisiológico.

Os resultados obtidos são encorajadores e serviram para constatar-se que o sistema nebuloso de *TSK* com otimização evolutiva constitui-se de uma ferramenta promissora em aplicações de previsão de séries temporais e mapeamentos não-lineares. Estas aplicações estão presentes em análise de mercado financeiro, identificação de sistemas produtivos e controle preditivo.

O sistema nebuloso de *TSK* apresentou potencialidades para a previsão de séries temporais devido a sua capacidade de aproximar funções não-lineares e eficiência do aprendizado, possibilitando a obtenção de resultados promissores. Entretanto, necessita-se de estudos mais aprofundados em trabalhos futuros quanto aos aspectos de aprimoramento das potencialidades do sistema nebuloso de *TSK*. Neste aspecto deseja-se utilizar procedimentos de otimização com múltiplos objetivos para obtenção de um melhor compromisso entre interpolação, generalização e aprendizado dos sistemas nebulosos visando-se aplicações de identificação multivariável e não-linear.

## 6. REFERÊNCIAS

- Angeline, P.J., 1995, "Adaptive and Self-adaptive Evolutionary Computations", Computational Intelligence: A Dynamic Systems Perspective, Palniswami, M.; Attikiouzel, Y.; Marks, R.; D. Fogel & T. Fukuda (eds.), Piscataway, NJ: IEEE Press, pp. 152-163.
- Bäck, T., Fogel, D.B. and Michalewicz, Z. (eds.), 1997, Handbook of Evolutionary Computation, Bristol, Philadelphia: Institute of Physics Publishing, NY, Oxford: Oxford University Press.
- Beyer, H.G., 1995, "Toward a Theory of Evolution Strategies: Self-Adaptation", Evolutionary Computation, Vol. 3, No. 3, pp. 311-348.
- Box, G., Jenkins, G. and Reinsel, G., 1994, Time Series Analysis, Forecasting and Control, 3rd ed., Englewood Cliffs, NJ: Prentice Hall.
- Chen, G., Chen, Y. and Ogmen, H., 1997, "Identifying Chaotic Systems via a Wiener-type Cascade Model", IEEE Control Systems, Vol. 17, No. 5, pp. 29-36.
- Giiven, M. K.; Passino, K. M., 2001, "Avoiding Exponential Parameter Growth in Fuzzy Systems", IEEE Transactions on Fuzzy Systems, Vol. 9, No. 1, pp. 194-199.

- Haber, R.; Unbehauen, H., 1990, "Structure Identification of Nonlinear Dynamic Systems — A Survey on Input/Output Approaches, Automatica, Vol. 26, No. 4, pp. 651-677.
- Hansen, N. and Ostermeier, A., 1996, "Adapting Arbitrary Normal Mutation Distributions in Evolution Strategies", IEEE International Conference on Evolutionary Computation, Nagoya, Japan, pp. 312-317.
- Le Schiavo, A. and Luciano, A. M., 2001, "Powerful and Flexible Fuzzy Algorithm for Nonlinear Dynamic System Identification", IEEE Transactions on Fuzzy Systems, Vol. 9, No. 6, pp. 828 – 835.
- Ljung, L., 2001, "Black-box Models from Input-output Measurements", Proceedings of the 18th IEEE Instrumentation and Measurement Technology Conference, Vol. 1, pp. 138 –146.
- Mackey, M.C. and Glass, L., 1977, "Oscillation and Chaos in Physiological Control Systems", Science, Vol. 197, pp. 287-289.
- Ostermeier, A. and Hansen, N., 1999, "An Evolution Strategy with Coordinate System Invariant Adaptation of Arbitrary Normal Mutation Distributions Within the Concept of Mutative Strategy Parameter Control", Genetic and Evolutionary Computation Conference, GECCO, Orlando, FL, pp. 902-909.
- Ostermeier, A., Gawelczyk, A. and Hansen, N., 1994, "Step-size Adaptation Based on Non-local Use of Selection Information", Proceedings of Parallel Problem Solving from Nature, PPSN III, Berlin: Springer, Jerusalem, Israel, pp. 189-198.
- Rovatti, R.; Guerrieri, R., 1996, "Fuzzy Sets of Rules for System Identification", IEEE Transactions on Fuzzy Systems, Vol. 4, No. 2, pp. 89-102.
- Sugeno, M. and Kang, G.T., 1988, "Structure Identification of Fuzzy Model", Fuzzy Sets and Systems, Vol. 28, pp. 15-33.
- Takagi, T. and Sugeno, M., 1985, "Fuzzy Identification of Systems and its Applications to Modeling and Control", IEEE Transactions on Systems, Man and Cybernetics, Vol. 15, No. 1, pp. 116-132.
- Wang, L. -X., 1998, "Designing Fuzzy Models for Nonlinear Discrete-time Systems with Guaranteed Performance", Proceedings of the American Control Conference, Philadelphia, Pennsylvania, Vol. 3, pp. 1864-1865.
- Ying, H., 1998, "General SISO Takagi-Sugeno Fuzzy Systems with Linear Rule Consequent are Universal Approximators", IEEE Transactions on Fuzzy Systems, Vol. 6, No. 4, pp. 582-587.

## 7. DIREITOS AUTORAIS

### EVOLUTIONARY-FUZZY SYSTEM APPLIED TO IDENTIFICATION OF NONLINEAR DYNAMIC SYSTEMS

**Leandro dos Santos Coelho**

Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS)  
 Laboratório de Automação e Sistemas, Centro de Ciências Exatas e de Tecnologia  
 Pontifícia Universidade Católica do Paraná  
 Rua Imaculada Conceição, 1155, CEP 80215-030, Curitiba, PR, Brazil  
 e-mail: lscoelho@rla01.pucpr.br

*Abstract.* This paper presents the design of a Takagi-Sugeno-Kang fuzzy system based on evolution strategy for the antecedent part design and least mean squares algorithm is utilized for consequent part design. The fuzzy system is evaluated in two case studies: (i) prediction of chaotic system called Lozi map, and (ii) prediction of a physiological control system. The simulation results indicate that the fuzzy system optimization based on an evolution strategy is attractive to applications of nonlinear identification and prediction of time series.

**Keywords:** fuzzy system, system identification, nonlinear systems.