Evolução Lamarckiana Baseada em Programação Evolutiva e Método de Hooke-Jeeves Aplicada à Otimização de um Sistema Nebuloso

Leandro dos Santos Coelho¹, Viviana Cocco Mariani² ¹ Pontificia Universidade Católica do Paraná Programa de Pós-Graduação em Engenharia de Produção e Sistemas Laboratório de Automação e Sistemas, LAS/PPGEPS/CCET/PUCPR Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil ² Pontificia Universidade Católica do Paraná Programa de Pós-Graduação em Engenharia Mecânica, LST/CCET/PUCPR Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil E-mails: Iscoelho@rla01.pucpr.br, mariani@rla01.pucpr.br

Abstract

An approach to design of Takagi-Sugeno-Kang fuzzy systems via Lamarckian evolution is presented based on antecedent and consequent parts optimization. The new conception of Lamarckian evolution is a combination of fast evolutionary programming and Hooke-Jeeves optimizaton method. The proposed methodology involves two levels of optimization, namely (fast evolutionary programming) and individual learning (Hooke-Jeeves method), which cooperate in a global procedure of optimization. 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 (Mackey-Glass system). The simulation results indicate that the fuzzy system optimization based on Lamarckian evolution presents enhancement in solution quality, reliability, and accuracy properties for nonlinear prediction of chaotic time series.

1. Introdução

Nos últimos anos, diversos pesquisadores, entre os quais [1]-[3], 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* [4], [5] 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 [6]. Além disso, os modelos nebulosos de *TSK* apresentam alto poder de interpolação com um número reduzido de regras.

Este artigo apresenta o projeto de um sistema nebuloso de *TSK* baseado em otimização através de uma nova abordagem de evolução Lamarckiana. A abordagem de evolução Lamarckiana proposta é utilizada na otimização dos parâmetros do antecedente e conseqüente do sistema de *TSK*. O desempenho do sistema nebuloso de *TSK* 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 de Mackey-Glass.

O artigo é organizado da seguinte forma. Na seção 2, os fundamentos do sistema nebuloso de *TSK* são apresentados. Na seção 2, o algoritmo de otimização baseado em evolução Lamarckana também é descrito. Os dois estudos de caso de previsão de séries temporais são abordados na seção 3. As simulações e a análise dos resultados obtidos da aplicação da evolução Lamarckiana são discutidas na seção 4. Na seção 5 são apresentadas as conclusões e os trabalhos futuros a serem desenvolvidos.

2. Sistema nebuloso de *TSK*

O desenvolvimento do sistema nebuloso de *TSK* é inspirada na teoria clássica de sistemas e, alguns desenvolvimentos no campo das redes neurais. O sistema nebuloso de *TSK* trata-se de um equivalente funcional da rede neural de base radial. Neste caso, quando a rede neural apresenta o mesmo número de funções de ativação na camada oculta que o número de regras do modelo nebuloso *TSK* de ordem zero [7].

Um aspecto relevante do sistema *TSK* é o seu poder de representação, especialmente para a descrição de processos complexos. Este sistema nebuloso permite a decomposição de um sistema complexo em subsistemas simples. A identificação de sistemas e/ou previsão de séries temporais, 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 visando-se a 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. Os modelos nebulosos de *TSK* consistem de regras de produção IF-THEN (SE <condição> ENTÃO <ação>) que podem ser representadas na forma geral:

$$R^{(j)} : IF z_1 IS A_1^j AND ... AND z_m THEN g_j = w_0^j + w_1^j u_1^j + ... + w_{qj}^j u_{qj}^j , \quad (1)$$

onde o antecedente *IF* define a parte antecedente (premissa) enquanto as funções da regra *THEN* constituem-se na parte conseqüente do sistema nebuloso; $\underline{z} = [z_1,...,z_m]^T$ é o vetor de entradas da parte premissa; e A_i^j são *labels* dos conjuntos nebulosos; $\underline{u} = [u_1^j,...,u_{qj}^j]^T$ 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 $\underline{w}^j = [w_0^j, w_1^j ..., w_{qj}^j]^T$ são os coeficientes polinomiais que formam o conjunto de parâmetros dos conseqüentes. A cada *label* lingüístico A_i^j é associada com a função de pertinência; enquanto $\mu_{A_i^j}(z_i)$ é

descrita por

$$\mu_{A_{i}^{j}}(z_{i}) = exp\left[-\frac{1}{2}\frac{(z_{i} - m_{ij})^{2}}{\sigma_{ij}^{2}}\right],$$
(2)

onde m_{ij} e σ_{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

$$\mu j(\underline{z}) = \mu_{A_1^j}(z_1) \cdot \mu_{A_2^j}(z_2) \cdots \mu_{A_m^j}(z_m).$$
(3)

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

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

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

$$v_{j}(\underline{z}) = \frac{\mu_{j}(\underline{z})}{\sum_{j=1}^{M} \mu_{j}(\underline{z})}$$
(5)

Quando a função $g_j = w_0^j + w_1^j u_1^j + ... + w_{qj}^j u_{qj}^j$ é um polinômio de primeira ordem, o sistema de inferência nebuloso é denominado de *modelo nebuloso TSK de primeira ordem*, sendo este o escolhido para ser abordado neste artigo.

2.1. Otimização do sistema nebuloso de *TSK* usando evolução Lamarckiana

Nos algoritmos evolutivos (*AEs*), um conjunto de soluções (população) é manipulado a cada iteração, em contraste com outros métodos de otimização, onde apenas uma solução para o problema é utilizada a cada iteração. A chance de que um indivíduo da população seja selecionado na próxima geração depende da função de aptidão (*fitness*) do indivíduo, que consiste, geralmente, de uma função objetivo ou mesmo uma transformação simples desta para o tratamento do problema em questão. Um compromisso entre convergência (*explotation*) e diversidade dos membros que constituem a população (*exploration*) é um problema constante em *AEs* e deve ser considerado na configuração de uma metodologia de otimização eficiente.

Os *AEs* são especialmente úteis em tarefas de otimização global, onde os métodos determinísticos podem levar a soluções de mínimos locais. Entretanto, a configuração de abordagens compostas por técnicas híbridas (busca global e local) de otimização é uma alternativa relevante apresentada na literatura [8]-[10].

Para obter-se os benefícios de uma configuração híbrida, uma forma eficiente é executar, inicialmente, um AE (fase de evolução) para "localizar" a região próxima de ótimo global e após aplicar-se outra metodologia de otimização para a realização da busca local (fase de aprendizado individual). Esta abordagem pode ser denominada de evolução Lamarckiana. Jean Baptiste Lamarck acreditava na herança das características adquiridas. O Lamarckianismo requer um mapeamento inverso do fenótipo e ambiente para o genótipo. No contexto da biologia, este mapeamento inverso não é plausível. Por outro lado, embora o Lamarckianismo não seja correto biologicamente, ele é útil para o desenvolvimento de AEs, pois organismos vivos não modificam seu DNA (ácido desoxirribonucléico) baseados em sua experiência, mas pode-se simular a evolução Lamarckiana em um computador [11]. Diversos autores têm utilizado o termo evolução memética ou algoritmo memético [12], apesar de controvérsias da origem do termo meme [13], como sinônimo de evolução Lamarckiana.

Este artigo propõe a implementação de um algoritmo de evolução Lamarckiana [9], [14] combinando uma técnica de programação evolutiva rápida (fase de evolução ou fase de busca global) e o método de Hooke-Jeeves (fase de aprendizado individual ou fse de busca local), estes descritos a seguir em concepção de forma isolada e conjunta para concepção de evolução Lamarckiana.

2.1.1. Programação evolutiva

Na programação evolutiva (*PE*), a população inicial de soluções (valores reais) é gerada aleatoriamente de acordo uma função densidade, sendo após toda população classificada em relação a um dado objetivo.

As soluções-descendentes são geradas de soluçõesancestrais através de operações de mutação. Tipicamente, cada indivíduo é composto de uma variável-objeto (vetor solução) acompanhada de um desvio padrão. Neste artigo a *PE* tem o indivíduo modificado por uma variável aleatória com distribuição de Cauchy [15], [16]. A utilização do operador de mutação com distribuição de Cauchy necessita de uma função densidade de probabilidade centrada na origem e definida por

$$f_t = \frac{1}{\pi} \frac{w}{w^2 + x^2},$$
 (6)

onde $-\infty < w < \infty$, e w > 0 é um parâmetro de escala. A função de distribuição correspondente é

$$F_t(x) = \frac{1}{2} + \frac{1}{\pi} \arctan\left(\frac{x}{w}\right). \tag{7}$$

A forma de $f_t(x)$ parece-se com a função de densidade Gaussiana (normal), mas nas proximidades o eixo $f_t(x)$ decresce mais vagarosamente. Como um resultado disto, a variância da distribuição de Cauchy é infinita. O operador de mutação, com distribuição de Cauchy é útil para escapar de ótimos locais. A figura 1 apresenta as funções densidade de Cauchy e Gaussiana com média zero e desvio padrão, σ .



Cauchy e Gaussiana.

2.1.2. Método de Hooke-Jeeves

Os métodos diretos baseiam-se na comparação dos valores da função objetivo e são particularmente atrativos em situações onde derivadas da função objetivo e das funções restrições não são viáveis. O método de Hooke-Jeeves [17] baseia-se em uma seqüência de movimentos exploratórios, começando em um ponto base, x_0 , e tendo um tamanho padrão, h.

Na próxima etapa do método a função objetivo é testada através de perturbações sucessivas no ponto inicial, x_0 , em direções de busca $\{v_i\}$, onde v_i é a *i*-ésima coluna de uma matriz de direção, V, no presente V = I. O movimento exploratório inicia com a avaliação da função objetivo em x_0 e dois outros pontos, $x_0 + hv_i$ e x_0

- hv_i , afastados de x_0 por um tamanho de passo prédefinido, h.

Duas situações podem surgir com o movimento exploratório: (i) se um destes pontos resulta em um decrescimento do valor da função objetivo, para o caso de minimização, então a exploração sucedeu-se de forma satisfatória, e o ponto particular que produziu o sucesso é armazenado como um ponto temporário, x_1 , e x_0 é substituído por x_1 . (ii) se nenhum dos pontos produziu um decrescimento no valor da função objetivo, o tamanho do passo pré-definido, h, é reduzido pela metade e o movimento exploratório com x_0 é repetido.

A amostragem é conduzida primeiro através da avaliação da função objetivo em $x_0 + hv_i$ e só testa-se $x_0 - hv_i$ se $f(x_0 + hv_i) \ge f(x_0)$. A fase exploratória pode produzir um ponto base novo ou pode falhar, conforme comentado anteriormente, se a fase exploratória obtém sucesso a direção de busca é,

$$d = x_1 - x_0, \tag{8}$$

e o novo ponto base é x_1 . O método de Hooke-Jeeves concentra o próximo movimento exploratório em

$$x_2 = x_0 + 2d = x_1 + d. \tag{9}$$

Se este segundo movimento exploratório falha na melhora (minimização) de $f(x_1)$, então um movimento exploratório com x_1 como o centro é tentado. Se este movimento falhar então h é reduzido e o processo é repetido. Se depois do primeiro movimento exploratório $x_1 = x_0$, então x_0 não é substituído, h é reduzido e o processo repetido.

2.1.3. Algoritmo de evolução Lamarckiana proposto

O algoritmo de evolução Lamarckiana proposto é implementado da seguinte forma:

- (i) a população inicial de parâmetros a serem otimizados compresende *nv* parâmetros. Cada uma das soluções consiste de vetores x_i ∈ 𝔅^t e σx_i, onde *i*={1,...,*nv*}, com suas dimensões correspondendo ao valor de *nv* do controlador. Os componentes de cada x_i, *i*={1,...,*nv*}, são selecionados de acordo com uma distribuição uniforme no intervalo [0;κ]. Os componentes de σ_{xi} são selecionados de acordo com uma distribuição uniforme no intervalo [0;κ];
- (ii) cada solução, x_i, i={1,...,nv}, é classificada com relação a função de adaptação F(J);
- (iii) cada indivíduo ancestral (x_i, σ_{xi}'), i={1,...,nv}, gera um descendente (x_i', σ_{xi}'), através das equações:

$$x'_{i}(j) = \sigma_{xi}(j)\delta j(0, \sigma'_{xi'}(j)),$$
(10)
$$\sigma'_{xi}(t) = \sigma_{xi}(t) \exp[\tau' \delta(0, 1) + \tau \delta_{j}(0, 1)],$$
$$j = \{1, ..., nv\} (11)$$

onde $x_i(j)$, $x_i'(j)$, $\sigma_{xi}(j)$, e $\sigma_{xi}'(j)$ denotam o *j*-ésimo componente dos vetores x_i , x_i' , σ_{xi} , e σ_{xi}' , respectivamente; $\delta \in \delta_j$ são variáveis aleatórias com distribuição de Cauchy centradas em zero com parâmetro de escala de 1. Os fatores $\tau \in \tau'$ são usualmente são usualmente configurados para

$$1/(\sqrt{2 * nv}) = 1/(\sqrt{2\sqrt{nv}})$$
, respectivamente

- (iv) cada vetor descendente x_i', i={1,...,nv}, é avaliado com relação a uma função de adaptação F(J);
- (v) as comparações são conduzidas sobre todas as x_i e x_i ' soluções, $i=\{1,...,nv\}$. Para cada solução, 15 oponentes (seleção por torneio) são selecionados aleatoriamente dos vetores ancestrais (x_i) e descendentes (x_i') com igual probabilidade. Em cada comparação, se a solução condicionada oferece pelo menos um desempenho tão adequado quanto o oponente selecionado aleatoriamente, então recebe uma "vitória";
- (vi) as soluções de x_i e x_i' , $i=\{1,...,nv\}$, que possuem mais vitórias são selecionadas para serem pais na próxima população, sendo que os vetores a eles associados são também incluídos;
- (vii) cada vetor descendente x_i', i={1,...,nv}, é avaliado com relação a uma função de adaptação F(J);
- (viii) aplicação do método de Hooke-Jeeves (avaliações da função de adaptação *F(J)*) de 10% dos melhores membros da população (maiores valores de *F(J)*);
- (ix) enquanto um critério de parada não é satisfeito, o ciclo evolutivo retorna ao passo (iii). O critério de parada adotado neste artigo é de 100 gerações.

3. Descrição dos estudos de caso

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. A seguir são descritos os dois estudos de caso abordados neste artigo.

3.1. Estudo de Caso 1: Mapa de Lozi

O mapa de Lozi [18] constitui-se de uma série temporal que apresenta mapas envolvendo funções nãodiferenciáveis e é descrito pela seguinte equação

$$y(t) = -P \cdot |y(t-1)| + Q \cdot y(t-2) + 1, \qquad (12)$$

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 nebuloso 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 [19] descreve um sistema de controle fisiológico. A equação de Mackey e Glass é uma série temporal obtida pela integração da equação diferencial

$$\frac{dy(t)}{dt} = \frac{Fy(t-\tau)}{1+y^{G}(t-\tau)} - Hy(t).$$
 (13)

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. Nos experimentos realizados, os dados da série temporal de Mackey e Glass são obtidos pela aplicação do método de Runge-Kutta de 4ª ordem para condições iniciais de x(0) = 1,2 e $x(t-\tau) = 0$, para $0 \le t \le \tau$ e passo de tempo unitário.

4. Aplicações e análise de resultados

A análise dos resultados obtidos, nos estudos de caso abordados, é organizada nas seguintes etapas: (i) obtenção dos dados do sistema dinâmico (dados de entrada e/ou 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 (evolução Lamarckiana) para identificação do sistema dinâmico, (iv) estimação dos parâmetros do modelo matemático (*fase de estimação de parâmetros*), e (v) a validação do modelo matemático (*fase de validação ou de testes*).

O critério de desempenho para otimização do sistema nebuloso é regido pela equação

$$F(J) = \frac{1}{1 + ISE}, \qquad (13)$$

onde *ISE* é a soma do erro quadrático entre a saída real, y(t), e saída estimada, $\hat{y}(t)$, do sistema dinâmico avaliado. O objetivo da otimização é maximização do critério F(J). Os resultados obtidos para um número de diferente de funções de pertinência (*fps*) em forma sino para cada entrada do sistema nebuloso de *TSK* usando otimização por algoritmo de evolução Lamarckiana são resumidos nas tabelas 1 e 2, respectivamente.

Os resultados para otimização do sistema nebuloso de *TSK* foram adequados para identificação dos dois estudos de caso, conforme observado nas 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.

(childua 1. y(i-1), childua 2. y(i-2), salua. y(i))							
s da	fase de estimação do sistema						
ada	nebuloso de TSK						
2	ISE	erro	erro	erro			
		(máximo)	(média)	(desvio			
				padrão)			
4	0,501	0,052	7,6x10 ⁻⁵	0,022			
6	0,285	0,049	$4,1x10^{-4}$	0,016			
7	0,101	0,023	7,0x10 ⁻⁵	0,010			
8	0,085	0,037	1,3x10 ⁻⁴	0,009			
s da	fase de validação do sistema						
ada	nebuloso de TSK						
2	ISE	erro	erro	erro			
		(máximo)	(média)	(desvio			
				padrão)			
4	0,501	0,0525	7,6x10 ⁻⁵	0,022			
6	0,285	0,0492	$4,1x10^{-4}$	0,016			
7	0,101	0,0236	$7,0x10^{-5}$	0,010			
8	0.085	0.0379	1.3×10^{-4}	0.009			
	$\begin{array}{c} s \text{ da} \\ a \text{da} \\ 2 \\ \hline \\ 4 \\ 6 \\ \hline \\ 7 \\ 8 \\ s \text{ da} \\ a \text{da} \\ 2 \\ \hline \\ 4 \\ 6 \\ \hline \\ 7 \\ 8 \\ \end{array}$	$\begin{array}{c c c c c c c c c c c c c c c c c c c $	s da fase de estimaç ada fase de estimaç 2 ISE erro 2 ISE erro $(máximo)$ $(máximo)$ 4 $0,501$ $0,052$ 6 $0,285$ $0,049$ 7 $0,101$ $0,023$ 8 $0,085$ $0,037$ s da fase de validaç ada nebuloso 2 ISE erro $(máximo)$ 4 $0,501$ $0,0525$ 6 $0,285$ $0,0492$ 7 $0,101$ $0,0236$ 8 $0,025$ $0,0270$	Initial I. $y(r-1)$, cirital 2. $y(r-2)$, sate s da fase de estimação do siste ada nebuloso de TSK 2 ISE erro (máximo) (média) 4 0,501 0,052 6 0,285 0,049 7 0,101 0,023 7 0,101 0,023 8 0,085 0,037 1,3x10 ⁻⁴ s da fase de validação do siste ada nebuloso de TSK 2 ISE erro (máximo) (média) 4 0,501 0,0525 7,6x10 ⁻⁵ 6 0,285 0,0525 7,6x10 ⁻⁵ 6 0,285 0,0492 4 0,501 0,0525 6 0,285 0,0492 4 0,101 0,0236 7 0,101 0,0236			

Tabela 1: Sistema nebuloso de *TSK* para o mapa de Lozi (entrada 1: v(t-1); entrada 2: v(t-2); saída: $\hat{v}(t)$)

Tabela 2: Sistema nebuloso de *TSK* para o sistema de Mackey e Glass (entrada 1: y(t-1); entrada 2: y(t-6); entrada 3: v(t-12): entrada 4: v(t-18): saída: $\hat{y}(t)$)

entrada 5. $y(i 12)$, entrada 4. $y(i 10)$, salad. $y(i)$							
n <u>•</u> fps da entrada			ada	fase de estimação do sistema			
				nebuloso de TSK			
1	2	3	4	ISE	erro	erro	
					(máximo)	(média)	
4	4	4	4	0,501	0,052	7,6x10 ⁻⁵	
6	6	6	6	0,285	0,049	$4,1x10^{-4}$	
7	7	7	7	0,101	0,023	$7,0x10^{-5}$	
8	8	8	8	0,085	0,037	$1,3x10^{-4}$	
n <u>^o</u> <i>fps</i> da entrada							
nº	fps da	a entr	ada	fase de	estimação d	o sistema	
n⁰_	fps da	a entra	ada	fase de n	estimação d ebuloso de T	o sistema TSK	
nº1	fps da	a entra	ada 2	fase de n ISE	estimação d ebuloso de T erro	o sistema TSK erro	
nº. 1	fps da	a entra	ada 2	fase de n ISE	estimação d ebuloso de T erro (máximo)	o sistema TSK erro (média)	
nº1 4	fps da 1 4	a entra 1 4	ada 2 4	fase de n ISE 0,501	estimação d ebuloso de T erro (máximo) 0,0525	o sistema TSK erro (média) 7,6x10 ⁻⁵	
nº 1 4 6	fps da 1 4 6	1 4 6	ada 2 4 6	fase de n ISE 0,501 0,285	estimação d ebuloso de T erro (máximo) 0,0525 0,0492	o sistema TSK erro (média) 7,6x10 ⁻⁵ 4,1x10 ⁻⁴	
nº 1 4 6 7	fps da 1 4 6 7	1 1 4 6 7	ada 2 4 6 7	fase de n ISE 0,501 0,285 0,101	estimação d ebuloso de 1 erro (máximo) 0,0525 0,0492 0,0236	o sistema TSK erro (média) 7,6x10 ⁻⁵ 4,1x10 ⁻⁴ 7,0x10 ⁻⁵	
nº_ 1 4 6 7 8	fps da 1 4 6 7 8	a entra 1 4 6 7 8	ada 2 4 6 7 8	fase de n ISE 0,501 0,285 0,101 0,085	estimação d ebuloso de 1 erro (máximo) 0,0525 0,0492 0,0236 0,0379	o sistema TSK erro (média) 7,6x10 ⁻⁵ 4,1x10 ⁻⁴ 7,0x10 ⁻⁵ 1,3x10 ⁻⁴	





Figura 2. Melhor resultado da previsão do sistema de Mackey e Glass.

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 parâmetros das funções de pertinência, em termos de quantidade e posição.

Neste caso, o algoritmo de evolução Lamarckiana mostrou-se promissor, 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* da otimização da parte antecedente e parte conseqüente usando uma nova abordagem de evolução Lamarckiana. Esta concepção de otimização foi avaliada 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 promissores 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. 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 de *TSK* visando-se aplicações de identificação multivariável e não-linear.

As perspectivas de futuros trabalhos estão direcionadas para um estudo comparativo e análise de convergência de diversas abordagens de algoritmos de evolução Lamarckiana em problemas de otimização com múltiplos objetivos.

Referências

- R. Rovatti and R. Guerrieri. Fuzzy sets of rules for system identification. *IEEE Transactions on Fuzzy Systems*, 4(2): 89-102, 1996.
- [2] L. -X. Wang. Designing fuzzy models for nonlinear discrete-time systems with guaranteed performance. *Proceedings of the American Control Conference*, Philadelphia, USA, vol. 3, pages 1864-1865, 1998.

- [3] A. Le Schiavo and A. M. Luciano. Powerful and flexible fuzzy algorithm for nonlinear dynamic system identification. *IEEE Transactions on Fuzzy Systems*, 9(6): 828-835, 2001.
- [4] T. Takagi and M. Sugeno. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics*, 15(1): 116-132, 1985.
- [5] M. Sugeno and G. T. Kang. Structure identification of fuzzy model. *Fuzzy Sets and Systems*, 28: 15-33, 1988.
- [6] H. Ying. General SISO Takagi-Sugeno fuzzy systems with linear rule consequent are universal approximators. *IEEE Transactions on Fuzzy Systems*, 6(4): 582-587, 1998.
- [7] A. Wu and P. K. S. Tam. A simplified model of fuzzy inference system constructed by using RBF neurons. *Proceedings of IEEE International on Fuzzy Systems Conference*, Vol. 1, Seoul, Korea, pages 50-54, 1999.
- [8] S. Tsutsui, M. Yamamura, and T. Higuchi. Multi-parent recombination with simplex crossover in real coded genetic algorithms. *Proceedings of Genetic and Evolutionary Computation Conference*, Orlando, FL, pages 657-664, 1999.
- [9] J. Yen, J. C. Liao, B. Lee, and D. Randolph. A hybrid approach to modeling metabolic systems using a genetic algorithm and simplex method. *IEEE Transactions on Systems, Man, and Cybernetics — Part B: Cybernetics*, 28(2): 173-191, 1998.
- [10] L. S. Coelho and A. A. R. Coelho. Algoritmos evolutivos em identificação e controle de processos: uma visão integrada e perspectivas. SBA Controle & Automação, 10(1): 13-30, 1999.
- [11] P. Turney. Myths ad legends of the Baldwin effect. Proceedings of the Workshop on Evolutionary Computing and Machine Learning, at the 13th International Conference on Machine Learning, Bari, Italy, pages 135-142, 1996.
- [12] P. Moscato and M. G. Norman. A 'memetic' approach for the traveling salesman problem — implementation of computational ecology for combinatorial optimisation on message-passing systems. *International Conference on Parallel Computing and Transputer Applications*, IOS Press, 1992.
- [13] R. Dawkins. *The selfish gene*, Oxford University Press, Oxford, UK, 1976.
- [14] J. -M. Renders and S. P. Flasse. Hybrid methods using genetic algorithms for global optimization, *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 26(2): 243-258.
- [15] X. Yao and Y. Liu. Fast evolutionary programming. Proceedings of 5th Annual Conference on Evolutionary Programming, San Diego, CA, The MIT Press, pages 451-460, 1996.
- [16] K. Chellapilla. Combining mutation operators in evolutionary programming. *IEEE Transactions on Evolutionary Computation*, 2(3): 91-96, 1998.
- [17] R. Hooke and T. A. Jeeves. Direct search solution of numerical and statistical problems. *Journal of the Association for Computing Machinery*, 8: 212-229, 1961.
- [18] G. Chen, Y. Chen, and H. Ogmen. Identifying chaotic systems via a Wiener-type cascade model. *IEEE Control Systems*, 17(5): 29-36, 1997.
- [19] M. C. Mackey and L. Glass. Oscillation and chaos in physiological control systems. *Science*, 197: 287-289, 1977.