

IDENTIFICAÇÃO DE SISTEMAS NÃO-LINEARES USANDO UMA ABORDAGEM DE SISTEMA NEBULOSO COM OTIMIZAÇÃO EVOLUTIVA

Leandro dos Santos Coelho¹ Viviana Cocco Mariani²

¹Laboratório de Automação e Sistemas

Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS)

Grupo Produtônica, Centro de Ciências Exatas e de Tecnologia

Pontifícia Universidade Católica do Paraná, Rua Imaculada Conceição, 1155

80215-901, Curitiba, PR, Brasil, e-mail: leandro.coelho@pucpr.br

homepage: <http://www.produtonica.pucpr.br/leandro>

²Programa de Pós-Graduação em Engenharia Mecânica (PPGEM)

Centro de Ciências Exatas e de Tecnologia

Pontifícia Universidade Católica do Paraná, Rua Imaculada Conceição, 1155

80215-901, Curitiba, PR, Brasil, e-mail: viviana.marian@pucpr.br

Resumo - Este artigo apresenta o projeto e otimização de um sistema nebuloso do tipo Takagi-Sugeno. 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. Uma análise do sistema nebuloso foi realizada para determinar uma medida de desempenho da otimização evolutiva na aproximação de dinâmicas não-lineares. 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 não-linear, previsão de séries temporais.

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 de sistemas, identificação de processos industriais e previsão de séries temporais 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 ([1]; [2]).

Os modelos matemáticos baseados em sistemas nebulosos têm recebido atenção recentemente, tanto da comunidade científica quanto dos profissionais que atuam no meio industrial, por tratarem-se de ferramenta de projeto que oferecem soluções promissoras para problemas de previsão de séries temporais e identificação de sistemas dinâmicos complexos ([3]; [4]; [5]; [6]; [7]; [8]; [9]; [10]; [11]; [12]; [13]). Neste contexto têm sido propostas várias metodologias de identificação baseadas em sistemas nebulosos, a citar os modelos nebulosos de Mamdani, Larsen, Tsukamoto, relacional e Takagi-Sugeno (*TS*), para lidarem com sistemas não-lineares, “mal definidos” e que apresentam incertezas.

Os modelos nebulosos de *TS* ([14]; [15]) 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 ([16]; [17]). Além disso, os modelos nebulosos de *TS* apresentam alto poder de interpolação com um número reduzido de regras de produção.

Os métodos de otimização e busca estocástica são baseados nos princípios e modelos da evolução biológica natural e têm recebido um crescente interesse nas últimas décadas, devido, principalmente, a sua versatilidade para a resolução de problemas complexos, nas áreas de otimização e aprendizado de máquina ([18]; [19]). O paradigma computacional denominado computação evolutiva (ou evolucionária) engloba um número crescente de paradigmas e métodos (denominados algoritmos evolutivos ou evolucionários), dos quais incluem os algoritmos genéticos, programação evolutiva, estratégias evolutivas, programação genética e sistemas classificadores.

A contribuição deste artigo é a apresentação do projeto de um sistema nebuloso de *TS* 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 sistemas não-lineares: (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 *TS* e a otimização baseada em uma *EE* e algoritmo dos mínimos quadrados são apresentados. Algumas características da identificação de sistemas baseadas em sistemas nebulosos *TS* são apresentadas na seção 3. A descrição dos dois estudos de caso de identificação de sistemas é abordada na seção 4. As simulações e a análise dos resultados obtidos da aplicação da abordagem combinando sistemas nebulosos e estratégias evolutivas são apresentadas na seção 5. Na seção 6 são apresentadas a conclusão e os futuros trabalhos a serem desenvolvidos.

2. Sistemas nebulosos

Os fundamentos teóricos dos conjuntos nebulosos foram propostos por Zadeh [20], professor da Universidade de Califórnia (Berkeley, Estados Unidos), como uma forma alternativa de modelar os sistemas complexos, se diferenciando das técnicas convencionais. Alguns trabalhos precursores aos de Zadeh foram de suma importância para o desenvolvimento dos sistemas nebulosos, entre os quais: (i) década de 20: os desenvolvimentos da lógica multivalorada pelo matemático polonês J. Lukasiewicz; (ii) década de 30: os estudos do filósofo quântico Max Black que apresentou as noções de funções de pertinência e as definições de estruturas vagas; e (iii) década de 50: Menger, um matemático francês, propôs o termo *ensemble flou*, uma contrapartida ao termo *fuzzy set*, que seria proposto posteriormente por Zadeh ([20]; [21]).

Os sistemas nebulosos possuem um formalismo para a representação e inferência de novos conhecimentos que é similar à maneira utilizada pelos seres humanos para expressarem o conhecimento e raciocínio, ao contrário dos sistemas baseados em lógica clássica. Os sistemas nebulosos têm, recentemente, emergido como uma abordagem atrativa para o controle de processos complexos. A motivação deve-se ao conhecimento do sistema e ao comportamento dinâmico qualitativo e com incertezas, pois a teoria dos sistemas nebulosos providencia uma representação adequada para tal conhecimento. Além disso, os sistemas nebulosos são capazes de manipular simultaneamente tanto os dados numéricos quanto o conhecimento lingüístico. As características dos sistemas nebulosos, que os tornam uma alternativa atraente de projeto, nos mais variados campos do conhecimento são:

- (i) a habilidade de tratar processos não lineares: característica relevante à aplicação em identificação e previsão quando da presença de sistemas dinâmicos complexos, com ordem elevada, atraso de transporte da informação e sistemas “mal” definidos;
- (ii) a possibilidade da utilização de termos e expressões da linguagem natural;
- (iii) a possibilidade da implementação do conhecimento, dos aspectos intuitivos e da experiência do especialista em uma determinada área do conhecimento (por exemplo, mercado financeiro), utilizando regras lingüísticas (conhecimento qualitativo e estruturado) e entradas imprecisas [22];
- (iv) a facilidade de entendimento, a simplicidade de implementação, a rápida prototipação e o custo inexpressivo de desenvolvimento [23].

Existem dois tipos de conhecimento, que podem ser utilizados à resolução de problemas reais, que são: (i) *conhecimento objetivo* (representado por modelos matemáticos), e (ii) *conhecimento subjetivo* (representado por informação lingüística, que é, praticamente impossível de quantificar pela matemática convencional). Estas duas formas de conhecimento podem ser coordenadas de maneira eficiente através da utilização dos sistemas nebulosos. As formas de tratar o conhecimento via sistemas nebulosos são: abordagem baseada em modelo e livre de modelo. Neste contexto, a estrutura básica de um modelo nebuloso pode ser vista como constituindo de: (i) *base de regras*, que contém um conjunto de regras nebulosas; (ii) *base de dados*, que define as funções de pertinência das regras nebulosas; e (iii) *mecanismo de inferência*, que executa os procedimentos de inferência sobre as regras e condição para obtenção de uma saída.

Os antecedentes das regras nebulosas dividem o espaço de entrada em um número de regiões nebulosas locais, enquanto os consequentes descrevem o comportamento dentro de uma região através dos seus constituintes. Os componentes dos consequentes resultam em tipos diferentes de sistemas (modelos) nebulosos, mas seus antecedentes são essencialmente os mesmos.

Os componentes dos consequentes resultam em tipos diferentes de modelos nebulosos, mas seus antecedentes são essencialmente os mesmos. Uma classificação baseada nos componentes dos consequentes pode ser usada para classificar os sistemas nebulosos em [24]:

- (i) *modelos lingüísticos*: são originários de regras *se-então* apresentando predicados vagos e utilizando raciocínio nebuloso. Nestes modelos, as quantidades nebulosas são associadas aos termos lingüísticos, e o modelo nebuloso é essencialmente uma expressão qualitativa do sistema. Os modelos, deste tipo, formam a base de modelagem qualitativa, que descreve o comportamento do sistema através da utilização da linguagem natural. O representante mais significativo desta classe é o modelo ou sistema do tipo Mamdani [25];

- (ii) *modelos interpolativos*: são formados por regras lógicas por uma parte nebulosa antecedente e um conseqüente funcional. Estes modelos são, essencialmente, uma combinação de modelos nebulosos e não-nebulosos. Os representantes mais significativos dos modelos interpolativos são os modelos ou sistemas do tipo Takagi-Sugeno e do tipo Tsukamoto. A representação do conhecimento, nestes modelos, caracterizam-se pelo potencial de expressar informações quantitativas. Entretanto, nos modelos interpolativos perde-se a informação qualitativa.

2.1. Sistema nebuloso de Takagi-Sugeno-Kang

Os modelos nebulosos de *TS* ([14]; [15]) apresentam características relevantes que os tornam promissores para aplicações de identificação de sistemas. Os modelos nebulosos de *TS* empregam funções lineares das entradas como conseqüentes. As regras do modelo de *TS* apresentam alto poder de interpolação com um número reduzido de regras de produção. Outra característica relevante dos modelos de *TS* são aproximadores universais de funções com precisão arbitrária [16].

O sistema nebuloso de *TS* é um equivalente funcional da rede neural de base radial quando a rede neural apresenta o mesmo número de funções de ativação na camada oculta que o número de regras do modelo nebuloso *TS* de ordem zero [26]. Um aspecto relevante do sistema *TS* 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 através de modelos nebulosos de *TS* 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 *TS* consistem de regras de produção IF-THEN (SE <condição> ENTÃO <ação>) que podem ser representadas na forma geral:

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

onde o *IF* define a parte antecedente (premissa) enquanto as funções de 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 associado 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 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

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

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 inferida pela média ponderada das saídas locais $g_j(\underline{u}^j)$,

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

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

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

Uma característica relevante deste sistema nebuloso é quando a função $g_j = w_0^j + w_1^j u_1^j + \dots + w_{q_j}^j u_{q_j}^j$ é um polinômio de primeira ordem, sendo denominado de *modelo nebuloso TS de primeira ordem*. Quando $g_j = w_0^j + w_1^j u_1^j + \dots + w_{q_j}^j u_{q_j}^j$ é uma constante, tem-se um *modelo nebuloso TS de ordem zero*, que pode ser visto como um caso especial do sistema de inferência de Mamdani, em que cada regra do conseqüente é especificada por um *singleton* nebuloso (ou conseqüente previamente desnebulizado). Também, pode configurar-se em um caso especial do modelo nebuloso de Tsukamoto. Além disso, um *modelo nebuloso TS de ordem zero* é funcionalmente equivalente a uma rede neural de base radial, sob certas restrições ([27]; [28]). Na figura 1 é ilustrado um sistema de inferência do tipo TS com duas regras.




Figura 1. Exemplo do sistema nebuloso de TS.

2.2. Otimização do sistema nebuloso de TS através de uma estratégia evolutiva

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 (*exploitation*) 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.

O desempenho quanto a convergência de uma *EE* comparado com o de outros *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* [19].

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 à distribuição normal n -dimensional.

Angeline [29] afirma que é possível adaptar 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 pelos 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 [29], 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 [30]. A abordagem de *EEs* com adaptação do sistema independente de coordenadas para o operador de mutação, abordada neste artigo, foi proposta por Hansen e Ostermeier [31] e Ostermeier e Hansen [32].

A 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 possuir uma correlação entre os passos de mutação selecionados no caminho de evolução [31].

Hansen e Ostermeier [31] 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 (μ, λ) -*EE*, onde os λ descendentes competem para sobreviver e o(s) μ ancestral(is) é(são) completamente substituído(s) a cada geração. A seguir são apresentadas equações que regem esta abordagem de (μ, λ) -*EE* para $\mu=1$. As equações são apresentadas de forma detalhada em Hansen e Ostermeier [31]. 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:

$$s^{D_k} = (I - c) \cdot s^A + c_{uv} B^A z_k \quad (7)$$

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

onde $c \in]0,1[$ determina o tempo acumulado para s ; $c_{uv} = \sqrt{c \cdot (2 - c)}$ normaliza a variância de s para resolver a equação $I^2 = (I - c)^2 + c_{uv}^2$; $s^{início} = 0$; $\delta > 0$ 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 dos 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, δ , é adaptado de uma forma similar ao proposto em Ostermeier *et al.* [33] e é denominada de “adaptação do tamanho de passo acumulado”. Neste caso, a soma dos tamanhos de mutação e adaptação de δ são regidos pelas seguintes equações:

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

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

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 $I^2 = (I - c)^2 + c_u^2$; $s_{\delta}^{início} = 0$; β é um parâmetro para diminuição da variação do tamanho de passo entre as sucessivas gerações; $\hat{\chi}_n = \sqrt{n} \left(1 - \frac{1}{4n} + \frac{1}{2ln^2}\right)$ aproxima a expectativa da distribuição de χ_n , em que é a distribuição do comprimento de um vetor aleatório com distribuição $N(0, \sigma)$ em \mathfrak{R}^n .

A equação (9) é similar a equação (7), a diferença está na normalização das colunas em B_{δ} que é importante para derivar o comprimento esperado de s_{δ} . A equação (10) faz a adaptação de δ 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 *TS* são os recomendados por Hansen e Ostermeier [31], ou seja, $c = 1/\sqrt{n}$, $\beta = 1/n$ e $c_{cov} = 2/n^2$. A parte conseqüente do sistema nebuloso é realizada pelo algoritmo dos mínimos quadrados em batelada. Os detalhes deste algoritmo são apresentados em [34].

3. Sistema nebuloso de *TS* aplicado à identificação de sistemas

A configuração de modelos nebulosos, usualmente, envolve três estruturas, ilustradas pela figura 2. A primeira estrutura é relacionada com a informação do processo contida no conjunto de treinamento. A informação é providenciada pelo conhecimento sobre as características físicas do processo, por alguns dados numéricos adquiridos dele, e pelo conhecimento lingüístico, expresso através das regras. Esta estrutura envolve o *conjunto das variáveis*, que regem o comportamento do processo, e a *partição nebulosa* atribuída a cada uma destas variáveis.

A segunda estrutura é o algoritmo de aprendizado, baseado nas características da primeira estrutura. Nesta estrutura, a informação adquirida é interpretada e codificada em um conjunto de regras. A terceira estrutura executa o procedimento de inferência considerando as regras extraídas e realiza as ações sobre o processo, no caso de sistemas dinâmicos, completando o ciclo de identificação nebulosa [35].

A identificação de um sistema nebuloso *TS* utilizando-se os dados de entrada e saída é composto de duas partes: identificação da estrutura e identificação dos parâmetros. Na identificação da estrutura identifica-se a estrutura do antecedente (premissa) e do conseqüente. Os parâmetros do conseqüente são coeficientes de equações lineares. Esta forma de

desenvolvimento de sistemas nebulosos é inspirada na teoria clássica de sistemas e, alguns desenvolvimentos no campo das redes neurais artificiais. Os passos para identificação de um sistema nebuloso do tipo *TS* são apresentados na figura 3.

Entre as características de aproximação, as seguintes são relevantes à utilização dos *SNs* em identificação de processos [36]:

- (i) *o mecanismo de aproximação nebuloso*: As regras lingüísticas são utilizadas para aproximar a saída desejada. Para uma dada entrada, as saídas correspondentes do sistema nebuloso resultam da combinação de diversas regras e consistem numa aproximação da saída desejada;
- (ii) *a aproximação global limitada*: a aproximação dos sistemas nebulosos é baseada em informação local, pois a base de regras é projetada de acordo com o conhecimento local;
- (iii) *propriedade de convergência*: quando um sistema nebuloso não satisfaz uma precisão de aproximação definida, uma idéia intuitiva, para modificar o sistema e melhorar o desempenho, é dividir o espaço de entrada em mais regiões (modificação da granularidade).

Estas características são supridas pela metodologia de projeto do sistema de *TS* proposta neste artigo. A seguir são apresentados e analisados dois exemplos da aplicação de sistemas de *TS* em identificação de sistemas.

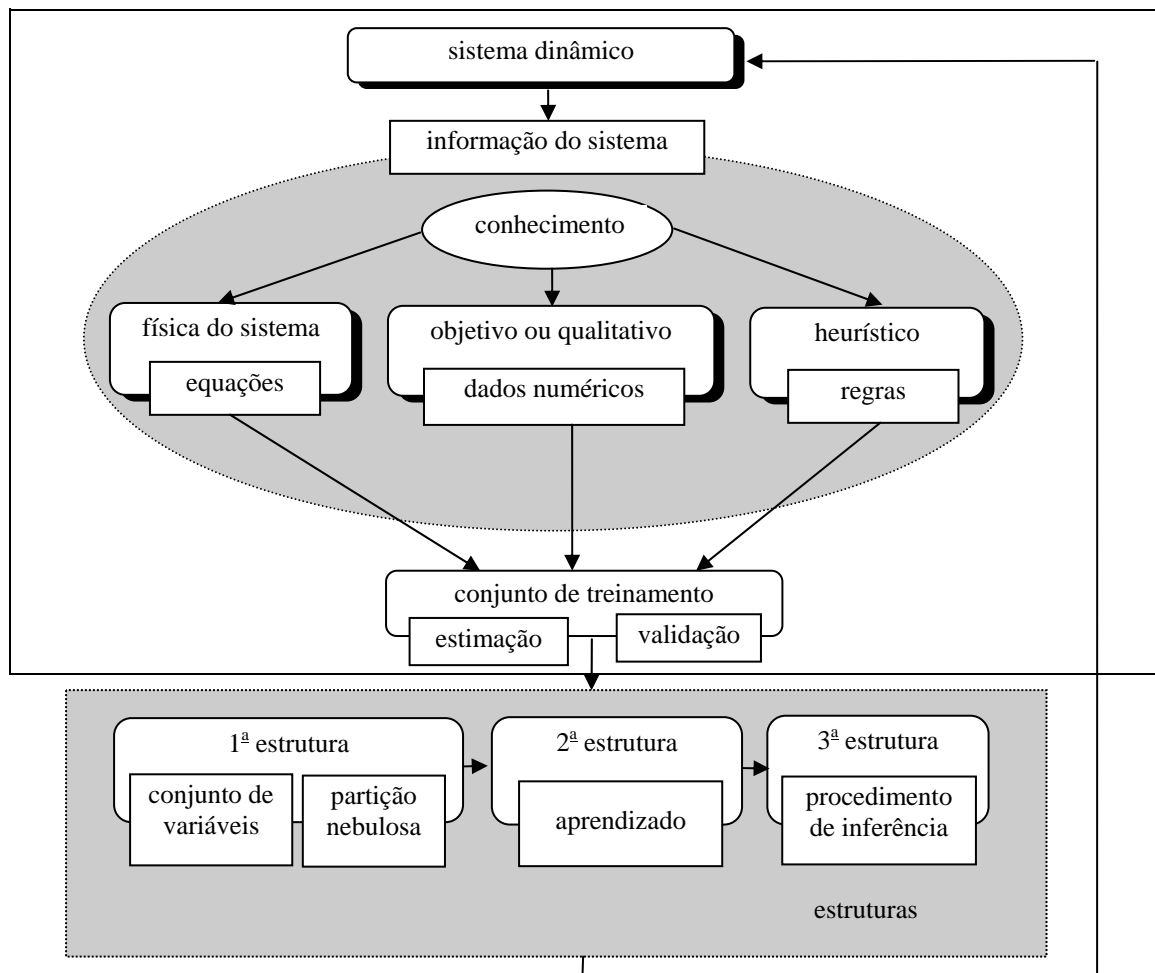


Figura 2. Esquema de configuração de identificação nebulosa e suas estruturas.

4. Descrição dos casos abordados

4.1. 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 por 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 [37] 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 foram utilizados 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 TS e outras 100 amostras para validação do sistema nebuloso obtido.

4.2 Estudo de Caso 2: Sistema fisiológico de Mackey & Glass

A série temporal determinada pela equação diferencial de Mackey e Glass [38] 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 são utilizadas na fase de validação do sistema nebuloso de TS . 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 $0 \leq t \leq \tau$ e passo de tempo unitário.

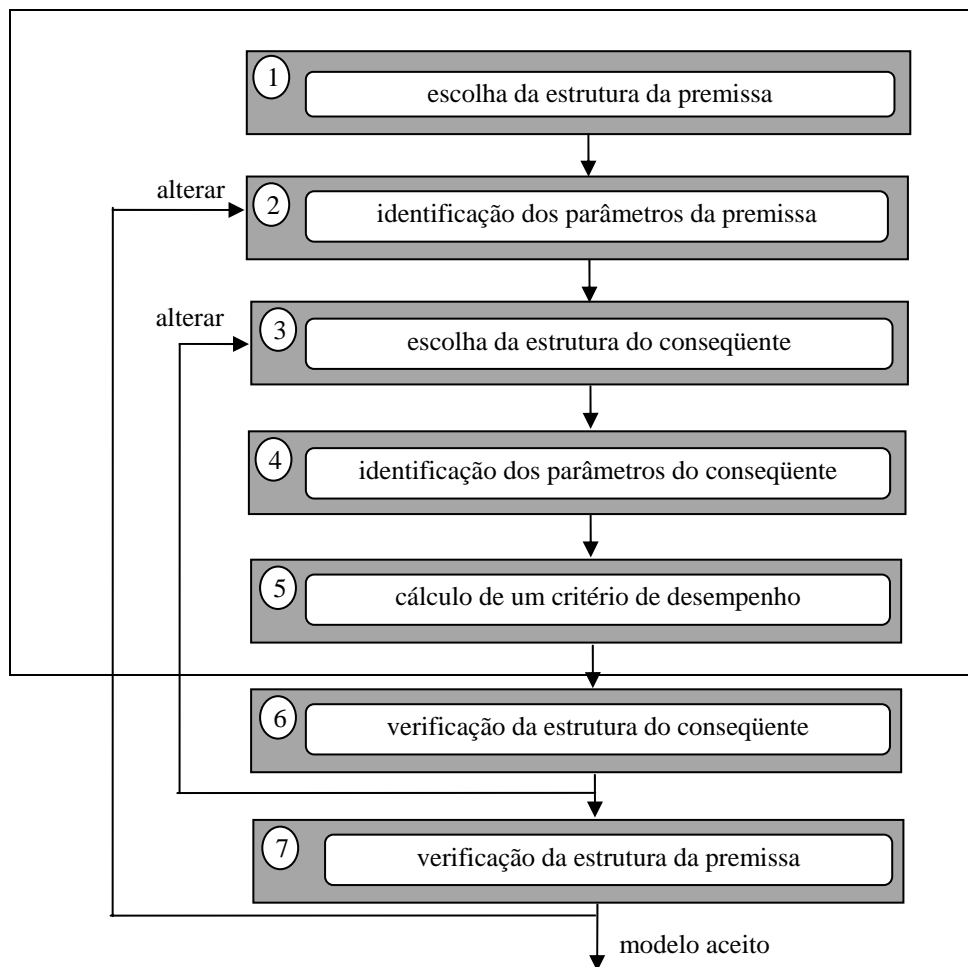


Figura 3. Passos para identificação de um modelo nebuloso do tipo TS .

5. 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 com concepção do tipo série-paralelo [39], (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) 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 a saída estimada, $\hat{y}(t)$, do sistema dinâmico. Os resultados obtidos para o modelo nebuloso de *TS* com otimização através da estratégia evolutiva e mínimos quadrados são apresentados nas tabelas 1 e 2, respectivamente.

Tabela 1: Resultados para um número diferente de funções de pertinência (*fp*) através do sistema nebuloso de *TS* para o mapa de Lozi (entradas: $y(t-1)$ e $y(t-2)$ e saída estimada: $\hat{y}(t)$)

<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	0,1218	-0,0019	0,0452	0,1869	0,1302	-0,0031	0,0438
25	0,1617	0,1265	$5,9 \times 10^{-4}$	0,0404	0,1483	0,1258	-0,0027	0,0390

Tabela 2: Resultados para o sistema nebuloso de *TS* (usando $y(t-1)$, $y(t-6)$, $y(t-12)$, $y(t-18)$ como entradas e $\hat{y}(t)$ como saída estimada) 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	0,0236	$7,0 \times 10^{-5}$	0,0101	0,1032	0,0241	$-5,1 \times 10^{-5}$	0,0103
8	0,0858	0,0379	$1,3 \times 10^{-4}$	0,0093	0,0782	0,0215	$-1,4 \times 10^{-4}$	0,0089

Os resultados para o sistema nebuloso de *TS* com a estratégia evolutiva e técnica dos mínimos quadrados foram adequados para identificação dos dois casos (ver tabelas 1 e 2). Nas figuras 4 e 5 são apresentados os melhores resultados obtidos com o modelo nebuloso de *TS* para os dois casos mencionados.

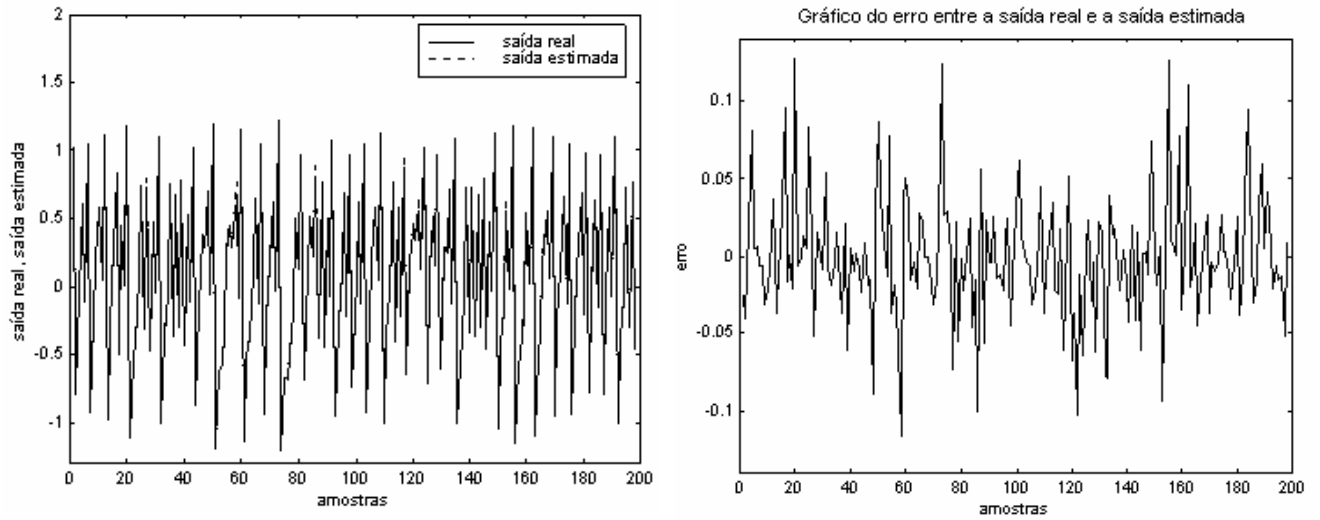


Figura 4. Resultados da previsão do modelo de Lozi com otimização do modelo de *TS* via *EE* e mínimos quadrados (25 funções de pertinência para cada entrada).

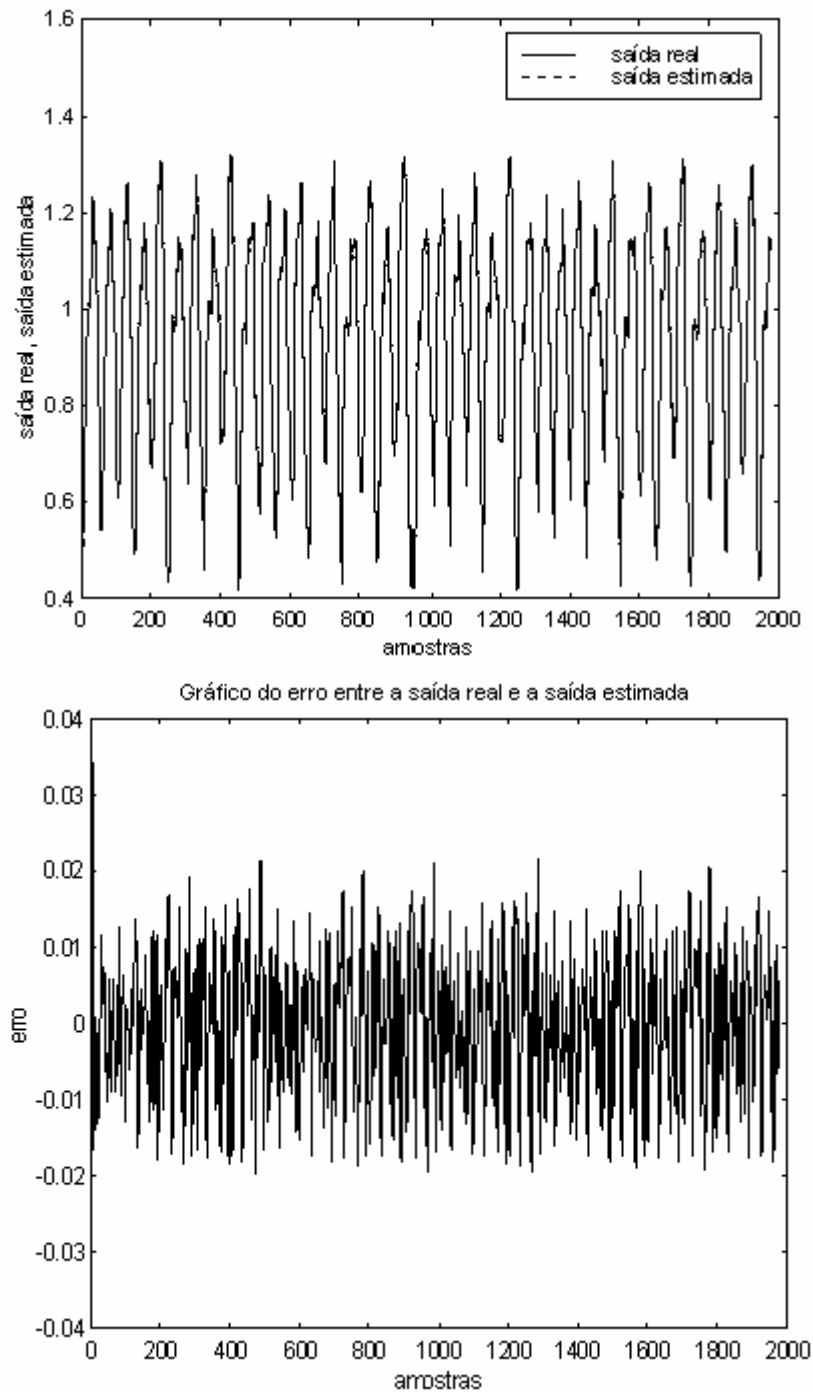


Figura 5. Resultados da previsão do modelo de Mackey e Glass via modelo de *TS* com otimização via *EE* e mínimos quadrados (8 funções de pertinência para cada entrada).

Os resultados obtidos mostram a robustez do sistema nebuloso de *TS* 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 *TS* 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 *TS* para a previsão de séries temporais.

6. 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 *TS* para o tratamento de problemas de identificação de sistemas complexos. O sistema nebuloso de *TS* 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 descreve um sistema de controle fisiológico.

Os resultados obtidos são encorajadores e serviram para constatar que o sistema nebuloso de *TS* 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 problemas de mercado financeiro, identificação de sistemas produtivos e controle preditivo.

O sistema nebuloso de *TS* 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 *TS*. 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.

Referências bibliográficas

- [1] R. Haber & H. “Unbehauen: Structure identification of nonlinear dynamic systems — a survey on input/output approaches”. *Automatica*, **26**(4), 1990, pp. 651-677.
- [2] L. Ljung: “Black-box models from input-output measurements”. *Proceedings of the 18th IEEE Instrumentation and Measurement Technology Conference*, Budapest, Hungary, **1**, 2001, pp. 138-146.
- [3] R. Rovatti & R. Guerrieri: “Fuzzy sets of rules for system identification”. *IEEE Transactions on Fuzzy Systems*, **4**(2), 1996, pp. 89-102.
- [4] L.-X. Wang: “Designing fuzzy models for nonlinear discrete-time systems with guaranteed performance”. *Proceedings of the American Control Conference*, Philadelphia, Pennsylvania, USA, **3**, 1998, pp. 1864-1865.
- [5] A. Le Schiavo & A. M. Luciano: “Powerful and flexible fuzzy algorithm for nonlinear dynamic system identification”. *IEEE Transactions on Fuzzy Systems*, **9**(6), 2001, pp. 828-835.
- [6] C. C. Chuang, S.-F. Su & S.-S. Chen: “Robust TS fuzzy modeling for function approximation with outliers”. *IEEE Transactions on Fuzzy Systems*, **9**(6), 2001, pp. 810-821.
- [7] Z. Huaguang & O. Yongbing: “Modeling, identification, and control of a class of nonlinear systems”. *IEEE Transactions on Fuzzy Systems*, **9**(2), 2001, pp. 349-354.
- [8] B. A. Park, W. Pedrycz & S.-K. Oh: “Identification of fuzzy models with the aid of evolutionary data granulation”. *IEEE Proceedings-Control Theory and Applications*, **148**(5), 2001, pp. 404-416.
- [9] S. A. Farghal, M. S. Kandil & A. Elmitwally: “Quantifying electric power quality via fuzzy modelling and analytic hierarchy processing”. *IEEE Proceedings-Electric Power Applications*, **149**(1), 2002, pp. 44-49.
- [10] H. Pomares, I. Rojas, J. Gonzalez & A. Prieto: “Structure identification in complete rule-based fuzzy systems”. *IEEE Transactions on Fuzzy Systems*, **10**(3), 2002, pp. 349-359.
- [11] M. Hojati & S. Gazor: “Hybrid adaptive fuzzy identification and control of nonlinear systems”. *IEEE Transactions on Fuzzy Systems*, **10**(2), 2002, pp. 198-210.
- [12] T. Hatanaka, K. Uosaki & N. Manabe: “Structure identification in Takagi-Sugeno fuzzy modeling”, *Proceedings of the IEEE International Conference on Fuzzy Systems*, Honolulu, HI, USA, **1**, 2002, pp. 69-74.
- [13] A. K. Palit, G. Doeding, W. Anheier & D. Popovic: “Backpropagation based training algorithm for Takagi-Sugeno type MIMO neuro-fuzzy network to forecast electrical load time series”. *Proceedings of the IEEE International Conference on Fuzzy Systems*, Honolulu, HI, USA, **1**, 2002, pp. 86-91.
- [14] T. Takagi & M. Sugeno: “Fuzzy identification of systems and its applications to modeling and control”. *IEEE Transactions on Systems, Man and Cybernetics*, **15**(1), 1985, pp. 116-132.
- [15] M. Sugeno & G. T. Kang: “Structure identification of fuzzy model”. *Fuzzy Sets and Systems*, **28**, 1988, pp. 15-33.
- [16] H. Ying: “General SISO Takagi-Sugeno fuzzy systems with linear rule consequent are universal approximators”. *IEEE Transactions on Fuzzy Systems*, **6**(4), 1998, pp. 582-587.
- [17] M. K. Giiven & K. M. Passino: “Avoiding exponential parameter growth in fuzzy systems”. *IEEE Transactions on Fuzzy Systems*, **9**(1), 2001, pp. 194-199.
- [18] K. F. Man, K. S. Tang & S. Kwong: “Genetic algorithms: concepts and applications”. *IEEE Transactions on Industrial Electronics*, **43**(5), 1996, pp. 519-534.
- [19] T. Bäck, D. B. Fogel & Z. Michalewicz: (eds.) *Handbook of Evolutionary Computation*. Bristol, Philadelphia: Institute of Physics Publishing, NY, Oxford: Oxford University Press, 1997.
- [20] L. A. Zadeh: “Fuzzy sets”. *Information and Control*, **8**, 1965, pp. 338-353.
- [21] L. A. Zadeh: “Outline of a new approach to the analysis of complex systems and decision processes”. *IEEE Transactions on Systems, Man, and Cybernetics*, **3**, 1973, pp. 28-44.

- [22] J. L. Navarro & P. Albertos: “Fuzzy logic implementation of industrial controllers”. *Proceedings of the 13th IFAC World Congress*, San Francisco, CA, USA, 1996, pp. 409-414.
- [23] L.-X. Wang: *Adaptive Fuzzy Systems and Control, Design and Stability Analysis*. Prentice-Hall, Englewood Cliffs, NJ, USA, 1994.
- [24] R. R. Yager & D. P. Filev: *Essentials of Fuzzy Modeling and Control*, John Wiley & Sons, New York, NY, USA, 1994.
- [25] E. Mamdani & S. Assilian: “An experiment in linguistic synthesis with a fuzzy logic controller”. *International Journal of Man-Machine Studies*, **7**(1), 1975, pp. 1-13.
- [26] A. Wu & P. K. S. Tam: “A simplified model of fuzzy inference system constructed by using RBF neurons”. *Proceedings of IEEE International on Fuzzy Systems Conference*, **1**, Seoul, Korea, 1999, pp. 50-54.
- [27] J.-S.R. Jang & C.-T. Sun: “Functional equivalence between radial basis function networks and fuzzy inference systems”. *IEEE Transactions on Neural Networks*, **4**(1), 1993, pp. 156-159.
- [28] H. Bersini, G. Bontempi & C. Decaestecker: “Comparing RBF and fuzzy inference systems on theoretical and practical basis”. *Proceedings of the International Conference on Artificial Neural Networks*, Paris, France, **1**, 1995, pp. 169-174.
- [29] P. J. Angeline: “Adaptive and self-adaptive evolutionary computations”. In: *Computational Intelligence: A Dynamic Systems Perspective* [edited by M. Palniswami, Y. Attikiouzel, R. Marks, D. Fogel & T. Fukuda], Piscataway, NJ: IEEE Press, 1995, pp. 152-163.
- [30] H. G. Beyer: “Toward a theory of evolution strategies: self-adaptation”. *Evolutionary Computation*, **3**(3), 1995, pp. 311-348.
- [31] N. Hansen & A. Ostermeier: “Adapting arbitrary normal mutation distributions in evolution strategies”. *Proceedings of the IEEE International Conference on Evolutionary Computation*, Nagoya, Japan, 1996, pp. 312-317.
- [32] A. Ostermeier & N. Hansen: “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, USA, 1999, pp. 902-909.
- [33] A. Ostermeier, A. Gawelczyk & N. Hansen: “Step-size adaptation based on non-local use of selection information”. *Proceedings of Parallel Problem Solving from Nature, PPSN III*, Berlin: Springer, Jerusalem, Israel, 1994, pp. 189-198.
- [34] G. Box, G. Jenkins & G. Reinsel: *Time Series Analysis, Forecasting and Control*, 3rd ed., Englewood Cliffs, NJ: Prentice Hall, 1994.
- [35] P.J.C. Branco & J. A. Dente: “Fuzzy systems modelling in practice”. *Proceedings of the 7th International Fuzzy Systems Association World Congress, IFSA'97*, Prague, Czech Republic, **II**, 1997, pp. 360-365.
- [36] X.-J. Zeng & M. G. Singh: “Approximation theory of fuzzy systems — MIMO case”. *IEEE Transactions on Fuzzy Systems*, **3**(2), 1995, pp. 219-235.
- [37] G. Chen, Y. Chen & H. Ogmen: “Identifying chaotic systems via a Wiener-type cascade model”. *IEEE Control Systems*, **17**(5), 1997, pp. 29-36.
- [38] M. C. Mackey & L. Glass: Oscillation and chaos in physiological control systems. *Science*, **197**, 1977, pp. 287-289.
- [39] J. Van Gorp: Nonlinear identification with neural networks and fuzzy logic, Thesis, Vrije Universiteit Brussel, Faculteit Toegepaste Wetenschappen, Brussel, Belgium, 2000.