

# Predição de Séries Temporais Biológicas Utilizando Ferramentas da Lógica Nebulosa

Bianca Borem Ferreira, Departamento de Engenharia Mecânica e de Materiais, IME,  
e-mail: [biaborem@gmail.com](mailto:biaborem@gmail.com)

Jorge Audrin Morgado de Gois, Departamento de Engenharia Mecânica e de Materiais, IME,  
e-mail: [audrin@ime.br](mailto:audrin@ime.br)

## Introdução

A descrição de fenômenos biológicos e biomecânicos através de modelos matemáticos tem ganhado importância nos últimos anos. Os modelos matemáticos podem identificar em que situações a alteração de parâmetros fisiológicos pode acarretar a substituição de processos normalmente ritmados por processos erráticos e caóticos (Silva e Savi, 2002). A simulação da dinâmica de fenômenos vitais através de dados de séries temporais pode contribuir tanto no sentido de definir as condições mais adequadas aos seres vivos quanto no sentido de determinar o tratamento de afecções (Savi e Pacheco, 1999), tornando possível a tomada de decisões e ações antecipadamente.

A identificação de sistemas dinâmicos complexos tem despertado a atenção crescente de diversas áreas, tais como: engenharia, física, matemática e biomedicina. Várias dificuldades encontradas no desenvolvimento desse assunto têm mostrado uma necessidade real em usar alguns tipos de aproximações inteligentes (Lee et al., 2006). Sistemas de identificação baseados no conceito de lógica nebulosa vêm sendo utilizados com sucesso em áreas nas quais as técnicas tradicionais podem não ser tão eficientes. Modelos baseados na lógica nebulosa têm por objetivo fazer com que as decisões tomadas pela máquina se aproximem cada vez mais das decisões humanas, principalmente ao trabalhar com uma grande variedade de informações vagas e incertas (Ferreira e Gois, 2008).

Neste artigo, é proposto um método de aprendizagem automática para identificação dos parâmetros de um sistema de inferência nebuloso utilizando algoritmo genético convencional e como ferramentas de apoio as técnicas de agrupamento de dados, aplicado a fenômenos biológicos. Para demonstrar sua eficácia, aplica-se o modelo proposto a um sistema de controle fisiológico descrito através da série temporal de Mackey-Glass.

## Metodologia Proposta

O sistema nebuloso escolhido para a modelagem das séries temporais foi o sistema Takagi-Sugeno de ordem zero, no qual o antecedente e o conseqüente de cada regra de inferência nebulosa são compostos, respectivamente, por funções de pertinência triangulares e por funções polinomiais de ordem zero, no formato de uma função impulso unitário. Esse sistema funcionará como preditor, de modo que dado um ponto da série temporal para a qual ele foi treinado, o mesmo estimará um valor da série à frente no tempo. Para tanto será necessária informação sobre a dinâmica do sistema, dada pelo espaço de estados reconstruído através do teorema de Takens, onde os estados são obtidos pela introdução de retardos fixos na série (passo de reconstrução,

$\tau$ ). A saída do sistema nebuloso será a série predita, ou seja, com um avanço no tempo.

O passo de reconstrução é dado pelo menor retardo que leve a um mínimo de informação mútua entre o sinal e sua cópia defasada. Neste trabalho, ele é calculado através do pacote TISEAN – *Nonlinear Time Series Analysis*.

A quantidade de partições do espaço de entrada é dada pela dimensão de imersão ( $m$ ) ótima, sendo calculada através do algoritmo de agrupamento de dados nebuloso *c-means* utilizado por (Jiang e Adeli, 2003 e Ferreira, 2008).

A quantidade de regras que vão compor o sistema de inferência nebuloso proposto será igual à quantidade de agrupamentos encontrados através da aplicação do algoritmo de agrupamento de dados subtrativo, implementado através da função *subclust.m* do *Matlab*<sup>®</sup>.

Para otimizar os parâmetros do sistema nebuloso foi utilizado o algoritmo genético convencional com uma população composta por 10 indivíduos, sendo que, cada parâmetro que compõem a cadeia de cromossomos contém 5 bits. A função objetivo minimizada foi o erro médio quadrático, conforme descrito pela EQ. 1 abaixo:

$$f_{\text{objetivo}} = \frac{1}{n} \sum_{k=1}^n (\hat{y}_k - y_k)^2 \quad (1)$$

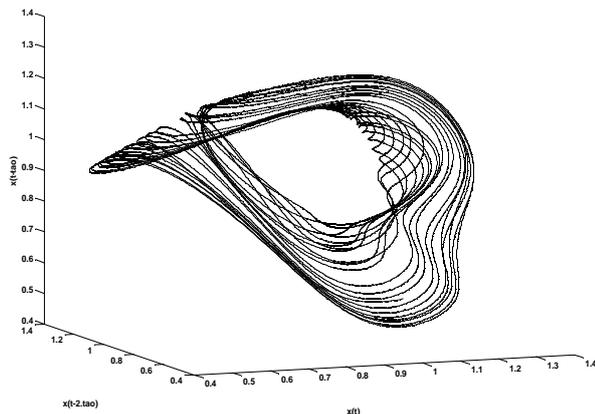
onde  $y_k$  é a saída real e  $\hat{y}_k$  é a saída predita estimada pelo sistema de inferência nebuloso.

## Série Temporal de Mackey-Glass

Um dos casos de estudo mais utilizados na identificação de sistemas consiste na predição da série temporal de Mackey-Glass. A equação de Mackey-Glass é uma equação diferencial com atraso no tempo que descreve um sistema de controle fisiológico (Jang e Sun, 1993, Ferreira e Gois, 2008, Lee et al., 2006). Ela foi proposta primeiramente como um modelo de produção de glóbulos brancos do corpo humano porque taxas de proliferação de células envolvem um atraso no tempo, sendo que a dinâmica periódica e o caos podem ser obtidos. Certamente, Mackey e Glass sugeriram que as flutuações de longo prazo nas contagens das células observadas em determinados formulários de leucemia fossem evidenciadas para estes comportamentos (Lee et al., 2006). A série temporal de Mackey-Glass é gerada através da integração da equação diferencial abaixo:

$$\frac{dy}{dt} = \frac{0.2y(t-\xi)}{1+y(t-\xi)^{10}} - 0.1y(t) \quad (2)$$

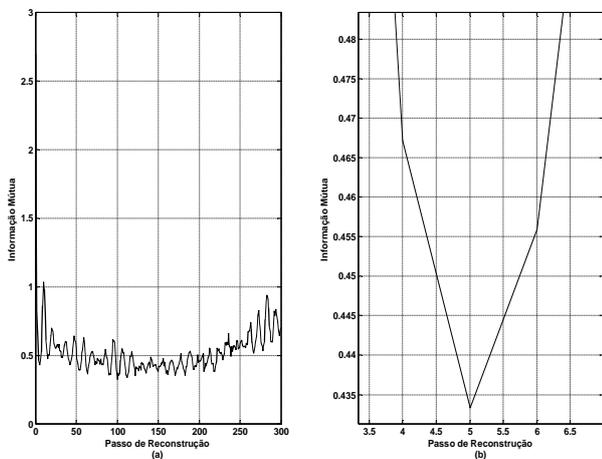
onde o parâmetro de atraso  $\xi$  determina o comportamento da EQ. 2 e para  $\xi > 16.8$  o caos se desenvolve (Lee et al., 2006).



**Figura 1: Atrator de Mackey-Glass**

As soluções numéricas da forma pontual são geradas com base no algoritmo de Runge-Kutta modificado, implementado através da função *dde23.m* do *Matlab*<sup>®</sup> com condição inicial  $y(0)=1.2$ , função histórico  $y(t)=1.2$  para  $t \in \mathcal{R}_{\leq 0}$  e atraso no de tempo  $\xi = 17$ . Por conveniência todos os dados gerados foram normalizados para estarem entre 0 e 1. A FIG. 1 mostra a órbita espacial de  $(y(t), y(t - \xi), y(t - 2\xi))$ .

Na FIG. 2 (a) está ilustrado o resultado da informação mútua e na FIG. 2 (b) está ampliada a região onde se encontra o primeiro mínimo local do gráfico da informação mútua, calculado a partir dos dados da série temporal de Mackey-Glass. Através da análise desses dados, verifica-se que  $\tau = 5$  (amostras).

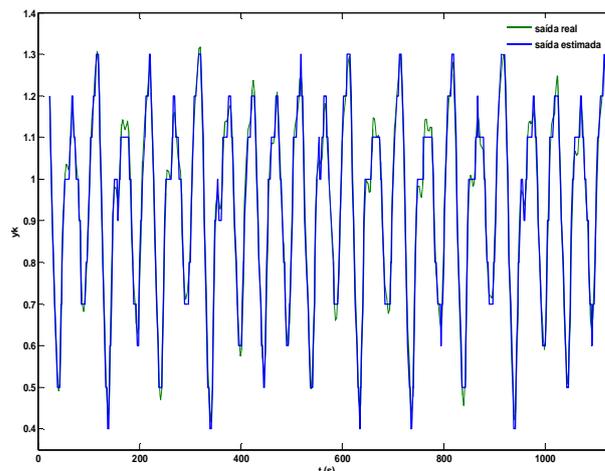


**Figura 2: (a) Resultado obtido através do método da informação mútua aplicado aos dados da série temporal de Mackey-Glass e (b) Localização do primeiro mínimo local no gráfico da informação mútua**

Através do agrupamento de dados nebuloso *c-means*, verifica-se que a dimensão de imersão ótima encontrada foi  $m = 3$  e, por consequência, serão utilizadas 3 entradas e, portanto, 3 funções de pertinência no antecedente de cada regra do sistema de inferência nebuloso proposto.

Aplicando-se os resultados obtidos à rotina *subclust.m* do *Matlab*<sup>®</sup>, encontra-se o número de agrupamentos do agrupamento de dados subtrativo igual a 7, ou seja, a quantidade de regras utilizadas no sistema de inferência nebuloso proposto é 7.

Na FIG. 3 está ilustrada uma comparação entre a saída real da série temporal de Mackey-Glass e a saída predita estimada pelo sistema nebuloso de identificação proposto.



**Figura 3: Comparação entre a saída da série temporal de Mackey-Glass real (verde) e a estimada através sistema de inferência nebuloso proposto (azul)**

### Comentários Finais

Os resultados apresentados mostram que os modelos nebulosos Takagi-Sugeno são ferramentas que fornecem um bom desempenho quando tratamos o problema de modelagem de séries temporais que representam a dinâmica de sistemas biológicos. O algoritmo de agrupamento de dados nebuloso *c-means* apresentou uma dimensão de imersão igual à dimensão real do sistema estudado. O algoritmo de agrupamento de dados subtrativo é vantajoso porque propiciou a determinação da quantidade de regras que irão compor o sistema de inferência nebuloso, o que possibilitou a modelagem o sistema de inferência nebuloso com estrutura mínima e com número mínimo de regras.

### Referências Bibliográficas

- Ferreira, B. B., Aplicação de Ferramentas da Lógica Nebulosa à Predição de Séries Temporais. Dissertação de Mestrado. Instituto Militar de Engenharia, 2008.
- Ferreira, B. B.; Gois, J. A. M., Identificação de Parâmetros de Modelos Nebulosos para Sistemas Não-Lineares, V Congresso Nacional de Engenharia Mecânica, 2008.
- Jang, J. S. R. e Sun, C. T., Predicting Chaotic Time Series with Fuzzy If-Then Rules, IEEE Second International Conference on Fuzzy Systems, 2, p. 1079–1084, 1993.
- Jiang, X.; Adeli, H., Fuzzy Clustering Approach for Accurate Embedding Dimension Identification in Chaotic Time Series, Integrated Computer-Aided Engineering, 10, p. 287-302, 2003.
- Lee, H. J.; Park, J. B.; Joo, Y. H., Model Identification using a Hybrid mGA Scheme whit Application to Chaotic System Modeling, Integration of Fuzzy Logic and Chaos Theory, p. 81-97, 2006.
- Savi, M. A.; Pacheco, P. M C. L., Modelos Constitutivos para o Pulmão: Caso Unidimensional, Revista Brasileira de Engenharia Biomédica, v. 15, n. 3, p. 125-133, 1999.
- Silva, S. R. F. A; Savi, M. A., Análise da Dinâmica da Eutrofização de Copos D'Água a Partir de um Modelo Matemático, II CONEM, 2002.