

MECTIP: MÉTODO COMPUTACIONAL PARA TRATAMENTO, IDENTIFICAÇÃO E PREVISÃO APLICADO A SISTEMAS DINÂMICOS NATURAIS

LUCIANO HEITOR GALLEGOS MARIN¹; PAULO MARCELO TASINAFFO¹

¹ Instituto Tecnológico de Aeronáutica – Departamento de Engenharia Eletrônica e Computação
Praça Marechal Eduardo Gomes, 50 – Vila das Acácias – CEP: 12243-380

São José dos Campos - Brasil

e-mail: marin@ita.br

RESUMO

Este trabalho propõe um método computacional para tratamento, identificação e previsão de sistemas dinâmicos naturais aplicado a séries temporais de dados. Para este método computacional é utilizada a técnica estatística de suavização exponencial para o tratamento de dados, a técnica *Nonlinear Auto Regressive Moving Average with eXogenous inputs* - NARMAX integrada a redes neurais artificiais do tipo *feedforward* para identificação, simulação e previsão, permitindo que estes procedimentos sejam efetuados de forma automática, isentando o tratamento manual de dados e a escolha de modelos analíticos específicos para este tipo de trabalho. Para a validação, o método foi implementado como protótipo e aplicado a um estudo de caso real, tendo por cenários a Bacia do Rio Amazonas.

PALAVRAS CHAVES: Redes Neurais Artificiais, Técnicas Estatísticas, Sistemas Dinâmicos Não-lineares

ABSTRACT

COMTIF: COMPUTATIONAL METHOD TO TREAT, IDENTIFY AND FORECAST NATURAL DYNAMIC SYSTEMS

This work proposes a computational method to treat, identify and forecast natural dynamic systems applied in temporal data series. This method uses the exponential smoothing statistic technique on data treatment, the Nonlinear Auto Regressive Moving Average with eXogenous inputs - NARMAX statistic technique integrated to a feedforward neural network to identify, simulate and forecast temporal data series without manual treatment or choice of analytical models. The method was validated as a prototype applied in a real case study in the Amazonian Basin scenario.

KEYWORD: Neural Network, Statistical Techniques, Nonlinear Dynamic Systems

1 – INTRODUÇÃO

A maior parte dos eventos climáticos naturais existentes podem ser entendidos como sistemas dinâmicos naturais [1]. Muitos destes sistemas possuem características não-estacionárias, dificultando sobremaneira a obtenção de bons resultados de simulação e previsão [2]. Problemas, tais como defeitos em sensores para coleta de dados, medições humanas incorretas e a complicada escolha de modelos analíticos apropriados para a simulação e previsão de sistemas dinâmicos naturais comprometem a obtenção de bons resultados.

As técnicas de Suavização Exponencial - SE são capazes de tratar dados com ruídos, contribuindo para posteriores mapeamentos e processamentos de sistemas dinâmicos naturais [3]. As Redes Neurais Artificiais - RNA estão, ao longo dos anos, demonstrando-se promissoras na identificação e representação de sistemas dinâmicos por serem capazes de aproximar complexos sistemas não-lineares [4, 5]. Integrada a uma RNA para a identificação de sistemas dinâmicos, a técnica *Nonlinear Auto Regressive Moving Average with eXogenous inputs* - NARMAX auxilia a aproximação e o mapeamento de uma ampla classe de sistemas dinâmicos não-estacionários [6].

1.1 – Trabalhos Relacionados

O primeiro trabalho investigado apresenta a utilização da técnica *Autoregressive Moving Average* - ARMA e de técnicas de composição de especialistas locais para simulação e para previsão, aplicando-as a um estudo de caso envolvendo dados reais de cheias na Bacia do Rio Itajaí [7].

Em outro trabalho relacionado, emprega-se a técnica das Ondas (Wavelets) para auxiliar a identificação das características de sistemas dinâmicos não-estacionários integrada a uma RNA para trabalhar na aproximação de funções, aplicado um estudo de caso envolvendo o Rio Itajaí-Açu para a validação da identificação, simulação e previsão de séries temporais de dados [8].

Ambos os trabalhos relacionados não fazem tratamento de dados e uso de métodos para o aumento do desempenho da RNA, demonstrando a possibilidade de aplicação de outras formas de solução que possam auxiliar o processo.

2 – TÉCNICAS UTILIZADAS

Para o tratamento de dados ruidoso utilizaram-se as técnicas de suavização exponencial dupla e tripla. A técnica da suavização exponencial dupla - SED é utilizada em séries temporais de dados que apresentam tendências e não-estacionariedade [9]. Neste artigo, atua-se somente no primeiro período das séries temporais de dados com a SED. Pode-se expressar a SED pelas seguintes equações de suavização e tendência, respectivamente:

$$S_t = \alpha * X_t + (1 - \alpha) * (S_{t-1} + b_{t-1}) \quad (1)$$

$$b_t = \gamma * (S_t - S_{t-1}) + (1 - \gamma) * b_{t-1} \quad (2)$$

Onde:

- S_t : suavização do dado atual;
- t : tempo;
- α : parâmetro inicial e constante de suavização, $0 \leq \alpha \leq 1$;
- X_t : valores originais da série temporal de dados;
- b_t : resultado da tendência atual; e
- γ : parâmetro inicial e constante de tendência, $0 \leq \gamma \leq 1$.

A técnica da Suavização Exponencial Tripla - SET é empregada em séries temporais de dados não-estacionários com tendências e sazonalidades [10]. São necessários, no mínimo, dois períodos completos na série temporal de dados para que a característica da sazonalidade possa exercer efeito de suavização na série temporal de dados [11].

O SET pode ser apresentado nos formatos aditivo ou multiplicativo [3]. No formato multiplicativo a série temporal de dados possui tendência crescente, não sendo possível determinar o limite máximo amplitudinal da série. Na forma aditiva a tendência da série

temporal de dados permanece dentro de um mínimo e de um máximo aproximadamente constante.

Neste trabalho é utilizado o formato aditivo devido às características de tendência existentes na série temporal de dados do estudo de caso. A técnica SET é representada pelas seguintes equações de suavização, tendência e sazonalidade, respectivamente:

$$S_t = \alpha * (X_t - I_{t-L}) + (1 - \alpha) * (S_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \gamma * (S_t - S_{t-1}) + (1 - \gamma) * b_{t-1} \quad (4)$$

$$I_t = \beta * (X_t - S_t) + (1 - \alpha) * I_{t-1} \quad (5)$$

Onde as variáveis adicionadas à técnica SED anteriormente citada são:

- I_t : resultado da tendência atual;
- β : parâmetro inicial e constante de sazonalidade, $0 \leq \beta \leq 1$; e
- L : tamanho do período.

Valores próximos a um para os parâmetros α , γ e β no SED e no SET dão maior importância aos dados mais recentes numa série temporal. Ocorre o inverso em valores próximos a zero [3].

As RNA do tipo *feedforward* são redes sem ciclos [12]. Uma RNA multicamadas (*Multi-Layer Perceptron* – MLP) do tipo *feedforward* são aproximadores universais de funções [13]. Cybenko [14] afirma que uma rede multicamadas com apenas uma camada intermediária aproxima qualquer função contínua suave. Em RNA do tipo *feedforward* pode-se utilizar o algoritmo de aprendizado de retropropagação para a execução do gradiente descendente no treinamento neural [15].

A técnica NARMAX integrada a uma RNA pode realizar a identificação não-linear de entradas atrasadas para a saída atual [16]. É uma opção de integração interessante para a redução do custo computacional e do aumento da precisão na modelagem de sistemas dinâmicos naturais [17]. O NARMAX é descrito pela equação (6) e o significado de suas variáveis exposto na Tabela 1 [18]:

$$y_{(t)} = F^l * (y_{(t-1)}, y_{(t-2)}, \dots, y_{(t-n_y)}, u_{(t-d)}, u_{(t-d-1)}, \dots, u_{(t-d-n_u+1)}, e_{(t-1)}, e_{(t-2)}, \dots, e_{(t-n_e)} + e_{(t)}) \quad (6)$$

TABELA 1 – Variáveis do NARMAX

Variável	Significado
F^l	Função Não-linear.
$y_{(t)}$, $u_{(t)}$ and $e_{(t)}$	Saída, entrada e ruído do sistema, respectivamente.
n_y , n_u and n_e	Atraso máximo de saída, entrada e ruído.
d	Atraso do sistema.

3 – MECTIP

O Método Computacional para Tratamento, Identificação e Previsão de Sistemas Dinâmicos Naturais - MECTIP é uma nova proposta de integração de técnicas computacionais apresentada neste trabalho. Permite tratar séries temporais de dados contendo ruídos, efetuar a identificação de sistemas dinâmicos desconhecidos analiticamente, realizar simulações destas séries e previsões para pequenos períodos de tempo. O MECTIP é representado por seis etapas, ilustradas na Figura 1.

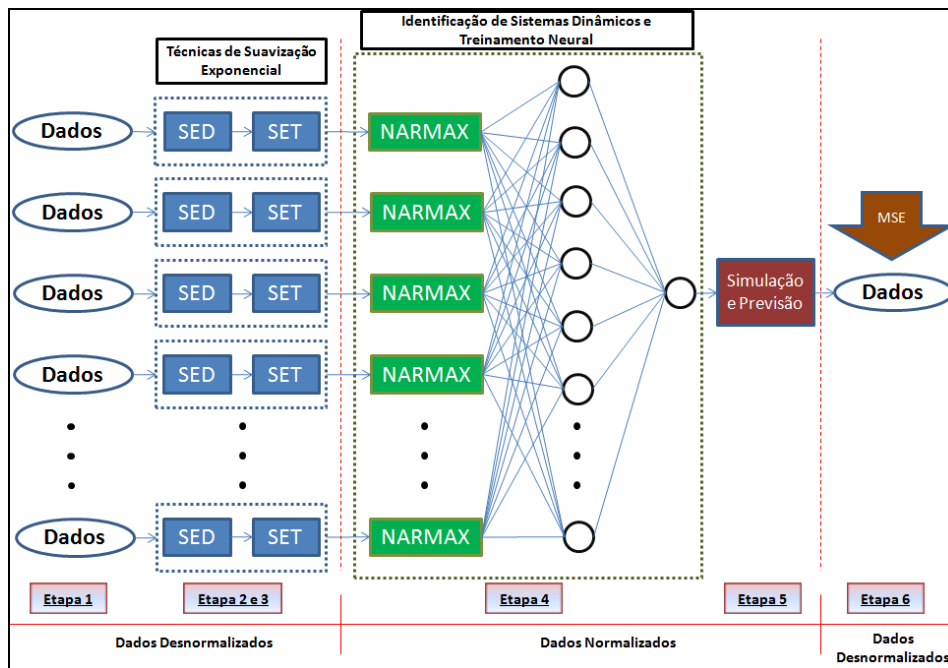


Figura 1 – MECTIP com suas seis etapas

3.1 – As Seis Etapas do Método Proposto

- Etapa 1: consiste no fornecimento de uma ou mais séries temporais de dados para a inicialização do método;
- Etapas 2 e 3: a técnica SED é aplicada na suavização do primeiro período da série temporal. A partir do segundo período, é executado o SET na forma sazonal aditiva, onde cada série temporal de dados é processada de forma individualizada;
- Etapa 4: inicialmente é efetuada a normalização dos dados entre zero e um, para que não haja problemas no processamento neural. Na sequência efetua-se o arranjo dos dados de entrada e saídas desejadas na técnica NARMAX. Uma vez organizado os dados pela técnica NARMAX, passa-se ao treinamento da RNA tendo por meta o progressivo decaimento do gradiente descendente e a generalização do aprendizado no treinamento;
- Etapa 5: esta etapa ocorre após os resultados obtidos no treinamento neural. A simulação é feita no formato de série temporal de dados até o presente e, a partir do último dado simulado, faz-se a previsão de dados até um período determinado no futuro. A previsão é iniciada pelo último valor simulado X_n e projetado um passo

adiante X_{n+1} . Na sequência, projeta-se mais um passo adiante X_{n+2} , tendo por referência o valor de X_{n+1} , até atingir o limite "m" em X_{n+m} .

- Etapa 6: nesta etapa é feita a desnormalização dos dados para a comparação dos resultados obtidos. Neste trabalho, optou-se pelo uso do erro quadrático médio (*mean square error* - MSE) para efetuar uma medida de desempenho dos dados desnormalizados obtidos da simulação e previsão resultante comparando-o aos dados originais, verificação assim do desempenho do MECTIP.

4 – APLICAÇÃO PRÁTICA

Tendo por objetivo validar o MECTIP esta seção apresenta um estudo de caso com dados reais tendo por cenário, com características do tipo vazão-vazão, a Bacia Hidrográfica Amazônica. O protótipo do MECTIP foi implementado por meio do Matrix Laboratory – MATLAB, versão 7.6. Foram utilizados dados reais obtidos na Bacia do Rio Amazonas em quatro estações fluviométricas: Canutama, localizada no Rio Purus; Porto Velho, localizado no Rio Madeira; Tabatinga, localizada no Rio Javari; e Manacapuru, localizado no Rio Amazonas. Ressalta-se que as cheias no Rio Madeira podem represar o Rio Amazonas.

Cada estação fluviométrica é representada por uma série temporal composta por 744 dados, completando um período de dois anos (01/jan/2003 à 31/dez/2004). Mais 9 dados diários foram coletados para a estação fluviométrica de Manacapuru (Manaus) no período de 01/jan/2005 à 09/jan/2005, para que a previsão feita pelo MECTIP possa ser comparado à série temporal original. Todos os dados mencionados foram obtidos no banco de dados da Agência Nacional de Águas - ANA, no sítio Hidroweb [19].

As séries temporais de dados dos rios sofreram tratamento de dados de SED e de SET, respeitando as suas características de tendência e sazonalidade. As estações fluviométricas dos rios e os respectivos parâmetros de suavização de dados, escolhidos de forma empírica, são apresentados na Tabela 2:

TABELA 2 – Parâmetros de SED e SET

Estação Fluviométrica	Suavização	Tendência	Sazonalidade
Canutama	0,1	0,08	0,05
Porto Velho	0,08	0,05	0,05
Tabatinga	0,08	0,06	0,02
Manacapuru	0,2	0,04	0,05

Todos os dados aplicados neste experimento possuem vazão de amplitude mínima em zero. A vazão de amplitude máxima varia de estação fluviométrica para estação fluviométrica. As séries temporais de dados de vazão originais dos rios e o tratamento de dados efetuado em relação aos dados originais de vazão podem ser visualizados na ilustração da Figura 2:

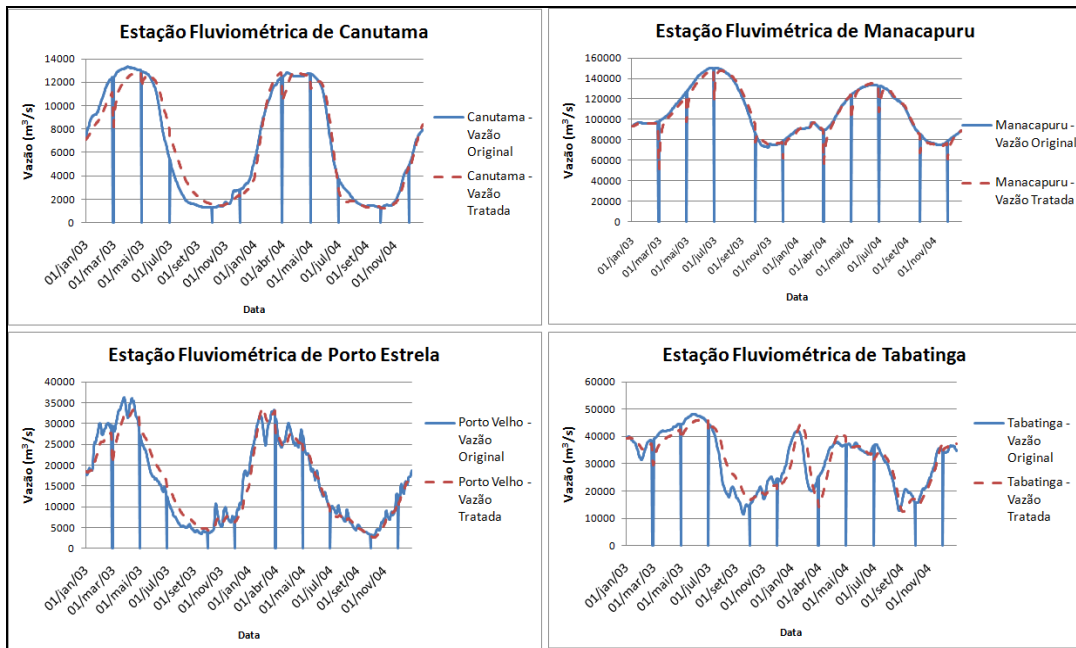


Figura 2 – Bacia do Rio Amazonas e suas Quatro Estações Fluvimétricas

Após o tratamento das séries temporais de dados efetuados pelo uso do SED e SET, pode-se utilizar a representação do sistema dinâmico natural. Para tanto, torna-se necessária a configuração empírica da RNA apresentada na Tabela II:

TABELA 3 – Configuração empírica da RNA

Variável	Parâmetro
Quantidade máxima de épocas	10.000.000
Taxa de aprendizado	0,1
Constante de <i>momentum</i>	0,9
Gradiente mínimo a ser atingido	$1,00 * 10^{-7}$
Neurônios nas camadas de entrada, oculta e de saída	4, 20, 4
Função de ativação	Tangente Hiperbolica (tansig)
Saída de dados da RNA	Puramente linear

Os resultados obtidos no treinamento da RNA foram os seguintes:

- Erro quadrático médio da RNA: $7,97 * 10^{-5}$;
- Gradiente atingido: $6,72 * 10^{-6}$.

Observa-se que os resultados de simulação apresentados pelo MECTIP foram muito bons, devido principalmente às características de tendência e sazonalidade bem definidas nas séries temporais de dados da Bacia do Rio Amazonas. Constata-se o efeito positivo do tratamento de dados feito pelo SED e pelo SET para o posterior processamento neural. Os resultados das vazões simuladas podem ser visualizados na Figura 3.




Figura 3 – Simulação dos Resultados da Vazão das Quatro Estações com o MECTIP

Após a simulação, é feita a previsão para o período de nove dias (01/jan/2005 à 09/jan/2005), conforme ilustra a Figura 4.

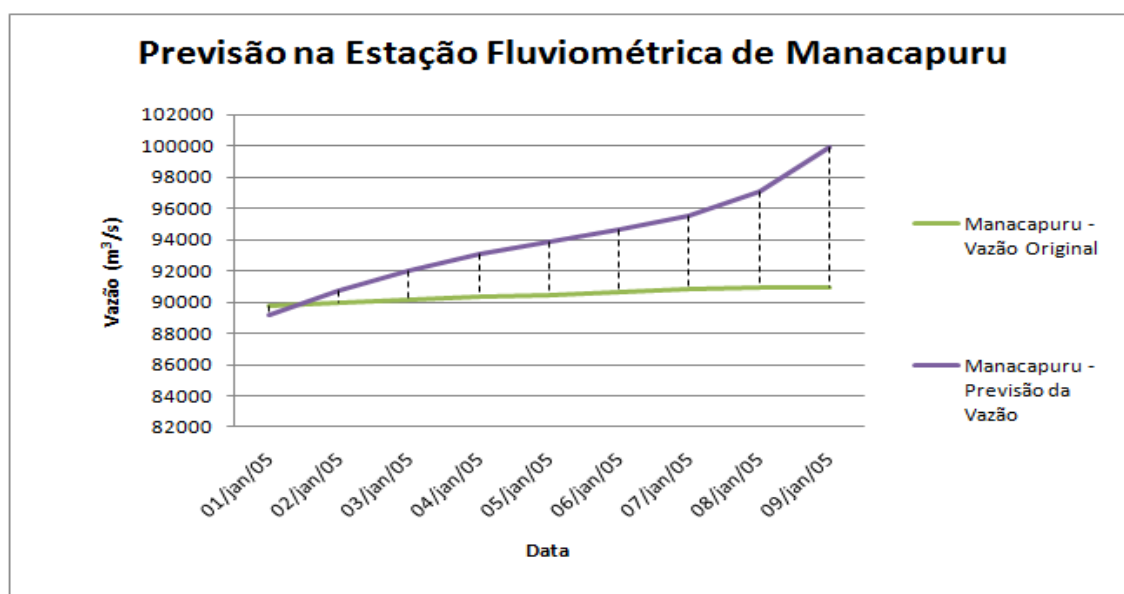


Figura 4 – Previsão da Série Temporal de Dados na Estação Fluv. de Manacapuru

Observa-se que a previsão, que se encontra desnormalizada, conseguiu acompanhar a tendência da série temporal de dados original em nove dias adiante na estação fluviométrica de Manacapuru, porém sem a mesma amplitude. Isto ocorre pela baixa variação da vazão em pequenos períodos de tempo na estação fluviométrica de Manacapuru, como o utilizado no estudo de caso. O erro quadrático médio entre a previsão e os dados observados foi de $4,48 * 10^3$.

4 – CONCLUSÃO

O método computacional apresentou bons resultados de simulação e previsão, demonstrando a viabilidade do MECTIP como uma nova solução para tratamento, identificação e previsão de séries temporais naturais.

O MECTIP torna-se uma boa alternativa quando não há modelo analítico específico para uso ou desconhecimento do tipo de série temporal natural a ser analisado e previsto, pois não exige o seu conhecimento prévio.

5 – REFERÊNCIAS

- [1] LENCASTRE A.; Franco F. M. Lições de hidrologia, 2. ed. Lisboa: Serviços Editoriais da Universidade Nova de Lisboa, 1992.
- [2] AGUIRRE L. A.; MENDES E. M. A. M. Global nonlinear polynomial models, International Journal of Bifurcation and Chaos, vol. 6, no. 2, p. 279-294, 1996.
- [3] MAKRIDAKIS S.; WHEELWRIGHT S. C.; MCGEE V. E. Forecasting, 2. ed. Canada: John Wiley & Sons, Inc., 1983.
- [4] TASINAFFO P.M. Estruturas de integração neural *feedforward* testadas em problemas de controle preditivo, Doutorado em Engenharia e Tecnologia Espaciais, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003, (INPE-10475-TDI/945).
- [5] TASINAFFO P.M.; RIOS NETO A. Modelagem de sistemas dinâmicos com integrador neural de Euler baseado em derivadas médias, Congresso Brasileiro de Automática. Gramado: CBA, 2004, 1 CD-ROM.
- [6] AZEVEDO F. M.; BRASIL L. M.; OLIVEIRA R. C. L. Redes neurais com aplicações em controle e em sistemas especialistas. Florianópolis: Bookstore, 2000.
- [7] OLIVO A. A. Modelos matemáticos para previsão de cheias, Doutorado em Engenharia Eletrônica e Computação, Instituto Tecnológico de Aeronáutica, São José dos Campos, 2004.
- [8] SPAETH F. Modelo para previsão de vazão fluvial baseado em *wavelets* e redes neurais, Mestrado em Ciências da Computação, Universidade Federal de Santa Catarina, Santa Catarina, 2008.
- [9] HOLT C. C. Forecasting seasonal and trends by exponentially weighted moving averages, International Journal of Forecasting, 2004.
- [10] WINTERS P. R. Forecasting sales by exponentially weighted moving average, Journal of Management Science, p. 324-342, 1960.
- [11] KALEKAR P. S. Time series forecasting using holt-winters exponential smoothing, 2004.
- [12] HAYKIN S. Neural networks. New York: Macmillan College, 1994.
- [13] HORNIK K.; STINCHCOMBE M.; WHITE H. Multilayer feedforward networks are universal approximators, Neural Networks, vol. 2, no. 5, p. 359-366, 1989.
- [14] CYBENKO G. Continuous valued neural networks with two hidden layer are sufficient. Medford: Tufts University, 1988, (Technical Report).

- [15] BRAGA A.; LUDEMIR T. B.; CARVALHO A. C. P. L. F. Redes neurais artificiais. Rio de Janeiro: LTC, 2000.
- [16] SJOBERG J. Non-linear system identification with neural networks, Tese (Doctor in Electrical Engineering), Linkoping Univeristy, Linkoping, 1995.
- [17] GUARIZE R. Uso de redes neurais na análise de resposta dinâmica de estruturas, Dissertação de Mestrado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2004.
- [18] BILLINGS S. A.; CHEN S. Representation of non-linear systems, International Journal of Control, vol. 49, pp. 1012-1032, 1989.
- [19] HIDROWEB, Sistemas de informações hidrológicas, 2009. [Online]. Disponível em: <http://hidroweb.ana.gov.br/>