

## Utilização de Redes Neo-Fuzzy Neuron para Predição de Vazões

Aymoré de Castro Alvim Filho, Carlos Barreira Martinez, Selênio R. Silva, Walmir Matos Caminhas,  
Bruno Rabelo Versiani, Cristiane Medina Finzi Quintão

Centro de Pesquisas Hidráulicas (CPH), (EHR / DEMEC / DELT) UFMG - MG, Brasil  
martinez@cce.ufmg.br, selenio@cpdee.ufmg.br, versiani@ehr.ufmg.br

Recebido: 03/04/03 revisado: 18/12/03 aceito: 03/03/05

---

### RESUMO

A predição e modelagem da série de vazões de um rio é extremamente importante, não somente sob a ótica econômico-energética, como também do ponto de vista da segurança das populações próximas a rios. O progresso no campo de identificação de sistemas vem contribuindo significativamente para a consistência e confiabilidade da modelagem de séries de vazões, e, desde a década passada, vem-se pesquisando muito a utilização de modelos baseados em redes neurais artificiais (RNA). Outro impulso nesta área foi a integração de lógica nebulosa às RNA, constituindo os modelos neuro-nebulosos. Dentre estes, as redes Neo-Fuzzy-Neuron vêm demonstrando sucesso no mapeamento de sistemas não-lineares. Neste trabalho as redes NFN são aplicadas à predição de vazões diárias, analisando-se a viabilidade da utilização de uma estrutura NFN única para modelagem dos perfis de vazões afluentes de todas as estações pertencentes a uma sub-bacia.

Para a aplicação da metodologia foram utilizados, como estudo de caso, os dados diários de vazão de 15 estações da sub-bacia 46, sendo escolhida uma entre elas como referência para modelagem dos dados das demais. A série de referência escolhida apresenta período mais abrangente e completo.

As redes NFN apresentaram excelentes resultados na predição de vazões para as estações estudadas. Além disso, a agregação de entradas Média Móvel (MA) melhorou significativamente os resultados apresentados pelos modelos puramente autoregressivos, principalmente no que diz respeito à validação. Pode-se constatar a viabilidade da obtenção de uma estrutura NFNARMA( $p, q, np$ ) única para modelagem de toda a sub-bacia 46.

**Palavras chave:** previsão de vazões, redes neurais artificiais, modelos neuro-nebulosos

---

### INTRODUÇÃO

A busca de ferramentas matemáticas capazes de modelar sistemas reais, principalmente os associados a fenômenos diretamente vinculados à economia e segurança da sociedade, vem consumindo o tempo de pesquisadores desde a antiguidade.

Os primeiros modelos se enquadravam dentro da categoria de modelagem denominada conceitual, fenomenológica ou, ainda, modelagem caixa branca (Aguirre, 2000 e Linsley et al., 1988). Esta forma de modelagem tem como principal característica a construção de equações que tentam descrever a física do processo através da inter-relação dos fenômenos envolvidos.

Dentro do contexto da hidrologia, cita-se como exemplo de modelagem conceitual, o modelo SWM (Stanford Watershed Model) (Crawford et al., 1966), que relaciona o escoamento resultante das chuvas com a precipitação diária e o potencial diário de evapotranspiração (evaporação total mais trans-

piração vegetal). Contudo, segundo Aguirre (2000) em meados dos anos 90, intensifica-se o interesse por uma categoria de modelos denominada empírica, caixa preta, ou identificação de sistemas, cuja modelagem se dá a partir dos dados observados, e não somente partindo da utilização do conhecimento do processo.

Este fato foi motivado principalmente pela ação concomitante da diminuição dos custos de aquisição e processamento de dados, do aumento da confiabilidade dos dados obtidos, e da possibilidade de automação na obtenção e processamento destes dados. Isto, além da dificuldade na compreensão do processo de muitos sistemas reais que, devido à importância socioeconômica, não poderiam prescindir de modelos mais confiáveis. Dentro desta categoria, a classe de modelos lineares (Box e Jenkins, 1976), também conhecida por ARIMA( $p, d, q$ ) (autoregressivo, integrado, de médias móveis), veio a substituir modelos conceituais, como o SWM.

Mesmo que alguns sistemas não-lineares possam ser bem representados por modelos lineares, tal aproximação não é satisfatória em muitos dos casos que envolvem sistemas reais. Portanto, já na década de 90, surgem muitos trabalhos que utilizam modelos não-lineares para identificação de sistemas reais, principalmente representações polinomiais (Aguirre e Aguirre, 2000), modelos baseados em redes neurais artificiais (RNA), (Rosa e Martinez., 2000) , modelos baseados em sistemas nebulosos (Karnik e Mendel, 1999 ), ou ainda modelos híbridos, por exemplo, constituídos por rede neural-polinomial, ou por redes neurais-nebulosas (Kuo e Chue, 1999), ou polinomial-nebulosa (Tseng et all, 2001).

Dentre estes últimos, as redes Neo-Fuzzy-Neuron (NFN) (Yamakawa et all., 1992) vêm demonstrando sucesso no mapeamento de sistemas não-lineares. Contudo, esta ferramenta, apesar do algoritmo extremamente simples, não vem sendo devidamente aproveitada na predição de séries associadas a fenômenos naturais e/ou econômicos, muito menos na predição de vazões. No levantamento bibliográfico realizado, apenas (Alvim Filho et all, 2000) utiliza-a para este fim.

Apesar do sucesso demonstrado na predição de séries temporais de sistemas reais, a grande maioria dos trabalhos verificam a qualidade da validação através de critérios baseados na avaliação do erro de predição *1 passo* à frente, o que pode mascarar a ineficiência do modelo (Aguirre, 2000 e Menezes et all., 2000 ).

Também, a utilização exclusiva de critérios de avaliação dos erros de predição *p passos* à frente através de valores médios pode ocultar quantidades significativas de erros com amplitude elevada, principalmente quando referido a um conjunto de dados de validação grande o suficiente para dar margem a dispersões que possam comprometer o planejamento baseado na predição. Isto, além do fato de que um erro médio considerado pequeno pode mascarar erros elevados na predição dos picos de vazão, o que pode ser grave, já que estão relacionados à possíveis inundações. Outro fato observado é que modelos baseados em RNA são, geralmente, puramente auto-regressivos, não agregando os resíduos ao conjunto de entradas.

Assim, as redes NFN, apesar da simplicidade, podem ser uma excelente ferramenta na predição de séries de vazões diárias. Outros objetivos secundários são: avaliar a utilização dos resíduos como parte do conjunto de entradas, e a possibilidade de utilização de uma estrutura NFN única para predição das vazões influentes de todas as estações pertencentes a uma sub-bacia.

Para evitar possíveis mascaramentos devido à utilização de critérios baseados em erros médios, serão utilizados um critério que considera somente os erros nos picos mais importantes da série, e outro que leva em consideração a frequência de permanência dos erros abaixo de um determinado valor estipulado como referência.

A aplicação da rede NFN tem como objetivo determinação de uma estrutura única de predição de vazões baseada na metodologia apresentada. Foram utilizadas 15 estações fluviométricas dispostas na sub-bacia 46. A sub-bacia 46 pertence à bacia 4 referente ao Rio São Francisco.

As séries históricas destas estações foram avaliadas e programas gerados para o tratamento da informação hidrológica.

A metodologia de predição utilizando as redes neo-fuzzy aplicada é baseada em trabalhos de autores que utilizam modelos não-lineares para identificação de sistemas reais, principalmente representações polinomiais (Aguirre e Aguirre, 2000). Como também em trabalhos que tratam modelos híbridos constituídos por rede neural-polinomial (Ivakhnenko e Muller, 1995), ou por redes neurais-nebulosas ( Kuo e Chue, 1999 ).

Alguns autores mostram (Yamakawa et all. , 1992) que as redes Neo-Fuzzy-Neuron tem apresentado sucesso no mapeamento de sistemas não-lineares.

## REDES NEO FUZZY NEURON

### Estrutura do NFN

Redes neuro-nebulosas representam mais um conjunto de alternativas para mapeamento não linear dentre as topologias caracterizadas como híbridas, pois envolvem conceitos de Redes Neurais Artificiais (RNA) e de sistemas nebulosos para realizar o processo de aprendizagem. A figura 1 mostra a estrutura do NFN (Yamakawa et all.,1992 ).

A estrutura da rede NFN é apresentada na figura 1. O processamento sináptico é representado pela função não linear  $f_i(x_i)$  associada a um sistema de inferência nebulosa. A rede é formada por  $n$  entradas  $(x_1, x_2, \dots, x_i, \dots, x_n)$  e uma única saída  $\hat{y}$ , a qual está relacionada com as  $n$  entradas através de sinapses  $(\hat{y}_1, \dots, \hat{y}_i, \dots, \hat{y}_n)$ , cada uma das quais associada a uma única entrada  $x_i$ , sendo determinísticas tanto as entradas  $x_i$  quanto a saída  $\hat{y}$ .

Como se vê na ampliação da figura 1, as sinapses  $\hat{y}_i$  são determinadas a partir de processos de nebulização e desnebulização, através de um conjunto de Regras Nebulosas,  $R_i^j$ , do tipo “se-então”.

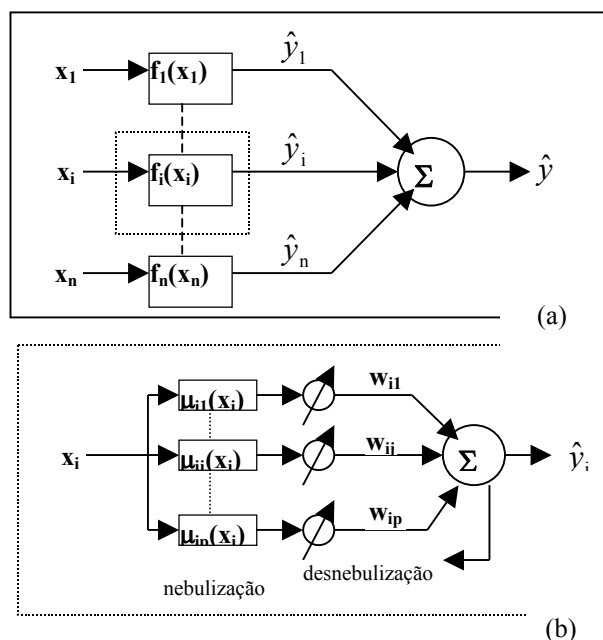


Figura 1 - (a) - Estrutura do NFN; (b) Ampliação da estrutura NFN

$R_1^1 \Rightarrow$  Se  $x_i$  é  $A_1$  Então  $y_i$  é  $w_{i1}$

$R_2^1 \Rightarrow$  Se  $x_i$  é  $A_2$  Então  $y_i$  é  $w_{i2}$

$R_j^1 \Rightarrow$  Se  $x_i$  é  $A_j$  Então  $y_i$  é  $w_{ij}$

$R_p^1 \Rightarrow$  Se  $x_i$  é  $A_p$  Então  $y_i$  é  $w_{ip}$




Figura 2 - Funções de Pertinência

Sendo  $A_j$  a  $j$ -ésima partição nebulosa, ou conjunto nebuloso;  $p$  o número total de partições, e  $w_{ij}$  o conseqüente da  $j$ -ésima regra nebulosa testada para a  $i$ -ésima entrada  $x_i$ . O termo  $w_{ij}$  também pode ser chamado de peso, denominação pela qual será referido de agora em diante. Cada uma das partições nebulosas é representada matematicamente por funções de pertinência  $\mu_j$ , triangulares, com-

plementares e igualmente espaçadas, como mostra a Figura 2.




Figura 3 - Mecanismo de Inferência

A figura 2 mostra que, sendo as partições complementares e igualmente espaçadas, cada entrada  $x_i$  poderá ativar, no máximo, duas partições, que serão indexadas por  $k_i$  e  $k_i+1$ . Ou seja, apenas em relação às partições  $\mu_{k_i}$  e  $\mu_{k_i+1}$  o grau de pertinência de  $x_i$  poderá ser diferente de zero ( $\mu_j = \mu_j(x_i) \neq 0$ ).

Assim, utilizando-se o processo de inferência “max-min” e o “centro de gravidade” para a desnebulização, as sinapses  $\hat{y}_i = f_i(x_i)$  estarão determinadas pela seguinte equação:

$$f_i(x_i) = \mu_{ik_i}(x_i) \cdot w_{ik_i} + \mu_{ik_i+1}(x_i) \cdot w_{ik_i+1} \quad (1)$$

E a saída  $\hat{y}$  é calculada pela soma de todas as sinapses, ou seja:

$$\hat{y} = \sum_{i=1}^n f_i(x_i) \quad (2)$$

A figura 3 mostra o processo de nebulização e desnebulização do NFN.

### Treinamento do NFN

O processo de treinamento do NFN consiste no ajuste dos pesos,  $w_{ij}$ . Portanto, a cada apresentação dos padrões de entrada  $X_t$ , os pesos vão sendo ajustados para que a saída  $\hat{y}_t$  do NFN aproxime-se cada vez mais do valor desejado  $y_t$ , onde  $t$  é o índice

do padrão apresentado, sendo  $t = 1, 2, \dots, t_{\max}$ , e  $t_{\max}$  é o número de padrões a serem apresentados.

Portanto, o ajuste dos pesos está associado com o erro  $E_t$  entre o valor desejado e o valor estimado pela rede.

De posse dos valores  $\hat{y}_t$  e  $y_t$  pode-se calcular o erro quadrático pela equação 3:

$$E_t = \frac{1}{2}(\hat{y}_t - y_t)^2 = E_t(w_{ij}) \quad (3)$$

Os ajuste dos pesos a cada iteração, ou seja, o peso da próxima iteração, é calculado através da equação 4.

$$w_{ik_i}^{j+1} = w_{ik_i}^j - \alpha^j \cdot (\hat{y}_t - y_t) \cdot \mu_{ik_i}(x_{t_i}) \quad (4)$$

Sendo  $\alpha$  a taxa de aprendizado, que pode ser fixa ou variável durante o processo e pode ser determinada empiricamente ou utilizando-se métodos de busca unidirecional indireto ou direto.

A utilização de uma taxa de aprendizado ótima (Caminhas, 1997) leva em consideração o fato de ser quadrática a função objetivo a ser minimizada: o erro quadrático, apresentado na equação 3.

Sendo assim, a taxa de aprendizado ótima é equacionada por:

$$\alpha = \frac{1}{\sum_{i=1}^n \mu_{ik_i}^2(x_{t_i}) + \mu_{ik_{i+1}}^2(x_{t_i})} \quad (5)$$

### Estruturação do Algoritmo de Treinamento

Utilizando a teoria recém explicada, segue-se a estrutura básica do algoritmo da rede NFN utilizada no processo de treinamento:

1. Construção das funções de pertinência das partições (triangulares igualmente espaçadas);
2. Determinação das distâncias entre as partições;
3. Determinação dos centros das partições
4. Determinação das partições ativas referentes a cada entrada;
5. Determinação do grau de pertinência de cada entrada em relação às suas duas partições ativas;

6. Cálculo da sinapse referente a cada entrada (equação 1);
7. Cálculo do valor estimado (equação 2);
8. Ajuste dos pesos;
  - 8.1) Cálculo da taxa de aprendizagem (se for o caso);
  - 8.2) Atualização dos pesos (equação 4);
- 9) Volta ao passo 2 até todos os pontos desejados da série serem apresentados.

O primeiro passo é a obtenção das funções de pertinência. Estas sendo triangulares e igualmente espaçadas, podem ser implementadas a partir do número de partições utilizando-se apenas a distância entre os centros das partições e a sua posição no vetor de entrada associado. Neste caso todas as entradas são da mesma natureza, o que implica em um mesmo conjunto de partições para todas.

A figura 4 mostra funções triangulares igualmente espaçadas correspondentes a 6 partições  $\{k \in N, 0 \leq k \leq 5\}$ . Aqui, a primeira partição ativa de  $x_i$  será rotulada por  $k_{1i}$ , e a segunda, por  $k_{2i}$ .

Conhecendo-se as variáveis, já definidas, podem-se obter os valores das funções de pertinência segundo interpolação linear, representada na equação 6.

$$\mu_{k_1}(x_i) = k_2(x_i) + \frac{x_{\min} - x_i}{\text{dist}} \quad (6)$$

### REDES NFN APLICADAS À MODELAGEM DE SÉRIES TEMPORAIS

A grande maioria dos trabalhos aplicados à predição de séries temporais utilizando representações não-lineares baseadas em RNA utilizam modelos puramente auto-regressivos (AR) (Diniz e Andrade, 1998 e Coulibaly et al., 2000). No que diz respeito à utilização de redes NFN, também não é diferente, (Caminhas et al., 1998 e Alvim Filho et al., 2000). Nesta seção, será introduzida a utilização dos resíduos no conjunto de entradas, agregando uma parte de médias móveis (MA) ao AR original.

Assim sendo, para melhor identificação dos modelos, estes serão definidos por 3 parâmetros:  $p$  (número de atrasos utilizados como entrada),  $q$  (número de resíduos utilizados como entrada) e  $np$  (número de partições). A seguir são definidas as opções de modelo estudadas, com base nas equações 1 e 2:

NFNAR(p,np) (Neo Fuzzy Neuron Auto-regressivo):

$$y_t = f(y_{t-1}) + f(y_{t-2}) + f(y_{t-3}) \dots + f(y_{t-p}) + a_t \quad \therefore$$

$$\therefore \begin{cases} f(y_{t-i}) = \mu_{iki}(y_{t-i}) \cdot w_{iki} + \mu_{iki+1}(y_{t-i}) \cdot w_{iki+1} \\ a_t = y_t - \hat{y}_t \end{cases} \quad (7.a)$$

ou:

$$y_t = \sum_{i=1}^p f_i(y_{t-i}) + a_t \quad (7.b)$$

NFNMA(q,np) (Neo Fuzzy Neuron de Médias Móveis):

$$y_t = f(a_{t-1}) + f(a_{t-2}) + f(a_{t-3}) \dots + f(a_{t-q}) + a_t \quad \therefore$$

$$\therefore \begin{cases} f(a_{t-i}) = \mu_{iki}(a_{t-i}) \cdot w_{iki} + \mu_{iki+1}(a_{t-i}) \cdot w_{iki+1} \\ a_{t-i} = y_{t-i} - \hat{y}_{t-i} \end{cases} \quad (8.a)$$

ou:

$$y_t = \sum_{i=1}^q f_i(a_{t-i}) + a_t \quad (8.b)$$

NFNARMA(p,q,np) (Neo Fuzzy Neuron Auto-regressivo de Médias Móveis):

$$y_t = a_t + f(a_{t-1}) + f(a_{t-2}) + f(a_{t-3}) \dots + f(a_{t-q}) +$$

$$+ f(y_{t-1}) + f(y_{t-2}) + f(y_{t-3}) \dots + f(y_{t-p}) \quad (9.a)$$

Ou, simplesmente:

$$y_t = \sum_{i=1}^p f_i(y_{t-i}) + \sum_{i=1}^q f_i(a_{t-i}) + a_t \quad (9.b)$$

### Critérios de Validação

Neste trabalho, os critérios de validação são classificados em dois grupos: avaliação dos erros de predição e análise dos resíduos. A diferença básica entre os dois grupos é que, enquanto o primeiro leva em consideração a intensidade do erro, o segundo leva em consideração o seu comportamento enquanto ruído.

Assim sendo, são utilizados os seguintes critérios: erro percentual médio (EPM) de predição um passo à frente, o erro percentual médio na predição dos picos de vazão (EPPM), o RMSE ("root mean square error"), a distribuição da frequência de permanência relativa dos erros percentuais individuais (FPR<sub>ep</sub>) e o coeficiente de determinação R<sup>2</sup> (todos classificados como avaliação dos erros). Também é verificada a análise dos resíduos, tanto pela função de autocorrelação (FAC) quanto pelo periodograma acumulado normalizado (PAN).

### Critérios baseados na avaliação dos erros de predição

O EPM pode ser equacionado da seguinte forma:

$$EPM = 100 \cdot \frac{\sum_{t=1}^N |y_t - \hat{y}_t|}{N} \quad (10)$$

onde N é o número de dados do conjunto de validação.

Além do erro médio para todo o conjunto de validação, propõe-se a utilização do EPPM para avaliar a predição dos picos de vazão, devido à sua importância, já que estão associados às inundações.

$$EPPM = 100 \cdot \frac{\sum_{p=1}^{N_p} |y_p - \hat{y}_p|}{N_p} \quad (11)$$

sendo N<sub>p</sub> o número de dados associados aos picos de vazão no conjunto de validação, e y<sub>p</sub> o p-ésimo pico de vazão observado.

O RMSE é assim equacionado:

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{N}} \quad (12)$$

A FPR<sub>ep</sub>(X), sendo X um valor percentual qualquer, é assim calculada:

$$FPR_{ep}(X) = \frac{N(EP > X)}{N} \quad (13)$$

sendo,  $N(EP>X)$  a quantidade de erros percentuais maiores que  $X$  (%), e  $N$  a quantidade de pontos do conjunto de validação.

Também será utilizado como critério de validação o coeficiente de determinação  $R^2$ , que pode ser assim obtido:

$$R^2 = 1 - \frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{\sum_{t=1}^N (y_t - \bar{y})^2} \quad (14)$$

O coeficiente de determinação  $R^2$  compara o modelo utilizado com a utilização da média como preditor trivial. Assim, quanto mais distante estiver  $R^2$  de zero, melhor é o modelo em relação à média. De fato, sobre este aspecto, considera-se o modelo satisfatório se  $R^2 > 0,7$  (Coulibaly et al., 2000), considerando-se o modelo perfeito se  $R^2 = 1$ .

### Análise dos Resíduos

A FAC de um resíduo branco é uma função impulso, com valor unitário para o atraso zero e nulo para os demais atrasos. A autocorrelação estimada para o  $k$ -ésimo atraso  $r_k$  é obtida pela equação 15 (Box et al., 1994):

$$r_k = \frac{c_k}{c_0} \quad (15)$$

Onde  $c_k$  é a autocovariância estimada para o  $k$ -ésimo atraso, e  $c_0$  é a autocovariância para o atraso zero.

Através da análise dos resíduos, pode-se saber o quanto de informação o modelo conseguiu retirar da série estudada. Se os resíduos forem considerados brancos (FAC estatisticamente nula), considera-se que o modelo conseguiu retirar toda a informação possível do sistema, e o que sobrou, o resíduo, é um sinal aleatório, não podendo, portanto, ser explicado. A análise dos resíduos será feita através da FAC linear e do periodograma acumulado normalizado.

### Periodograma Acumulado Normalizado

Segundo Box & Jenkins (1994), mesmo que a FAC do conjunto de resíduos caracterize-o como aleatório, pode ser que a periodicidade esteja mascarada. Isto pode acontecer porque a periodicidade tende a se diluir entre várias autocorrelações. Uma

das ferramentas mais utilizadas para detecção de periodicidade em um sinal  $a_t$  ( $t=1,2,\dots,N$ ) é o periodograma:

$$I(f_i) = \frac{2}{N} \left[ \left( \sum_{t=1}^N a_t \cdot \cos(2 \cdot \pi \cdot f_i \cdot t) \right)^2 + \left( \sum_{t=1}^N a_t \cdot \sin(2 \cdot \pi \cdot f_i \cdot t) \right)^2 \right]; \quad i=1,2,\dots,q \quad (16)$$

Sendo  $f_i = \frac{i}{N}$  a frequência, e  $q = \frac{N}{2}$ , se  $N$  é par, ou  $q = \frac{(N-1)}{2}$ , se  $N$  é ímpar.  $I(f_i)$  é denominada intensidade na frequência  $f_i$ .

Uma maneira mais explícita de se verificar a presença de um padrão periódico significativo nos resíduos é utilizando-se o periodograma acumulado normalizado (PAN):

$$C(f_i) = \frac{\sum_{i=1}^q I(f_i)}{N \cdot s^2} \quad (17)$$

Sendo  $s^2$  a variância estimada, e  $f_i$  a frequência, que estará variando entre 0 e 0,5 ciclo.

Para um ruído branco, o gráfico de  $C(f_i)$  contra  $f_i$  é uma linha reta passando pelos pontos (0;0) e (0,5;1). Um sinal pode ser considerado ruído branco com um determinado nível de confiança caso satisfaça o teste de Kolmogorov-Smirnov, ou teste K-S (Box & Jenkins, 1994).

Este teste consiste em construir 2 linhas retas simétricas em relação à reta para ruído branco, sendo que seu afastamento desta é igual a  $\pm \frac{K_\epsilon}{\sqrt{q}}$ ,

sendo:  $q=(N-2)/2$ , se  $N$  for par, ou  $q=(N-1)/2$ , se  $N$  for ímpar, e  $K_\epsilon$  depende do intervalo de confiança  $\epsilon$  desejado, sendo obtido da tabela 1 abaixo.

**Tabela 1 – Coeficientes para o teste K-S**

$\epsilon$	0,01	0,05	0,10	0,25
$K_\epsilon$	1,63	1,36	1,22	1,02

Caso  $C(f_i)$  mantenha-se, para qualquer que seja  $f$  entre 0 e 0,5 ciclo, dentro da faixa delimitada pelas duas retas do teste K-S, considera-se que não há periodicidade na série. E, caso  $C(f_i)$  dê um salto em um determinado valor de  $f$ , significa que há um componente periódico significativo nesta frequência.

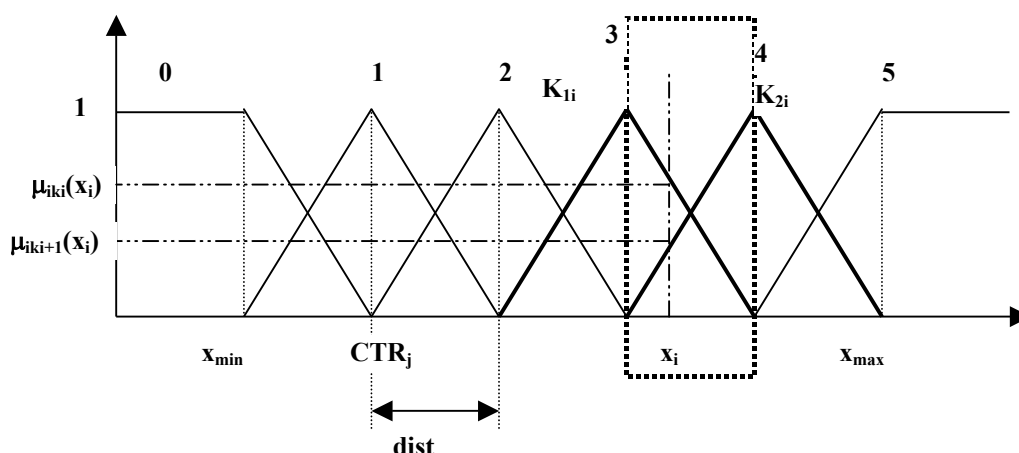


Figura 4 - Funções triangulares igualmente espaçadas

Tabela 2 – Características das estações estudadas

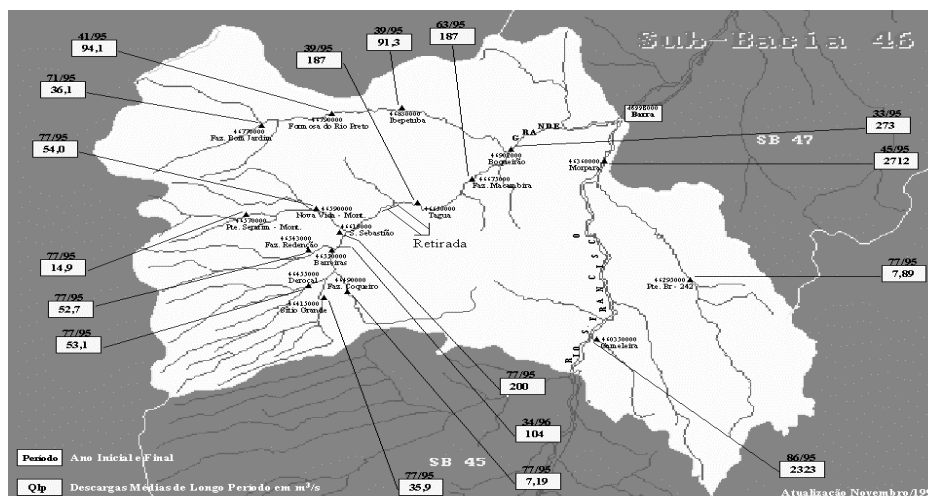
Código	Nome	Latitude	Longitude	Altitude (m)	Área de Drenagem (km <sup>2</sup> )	Classe de Vazão	Curso d'água
46295000	Ponte Br-242	-12°14'55"	-42°45'48"	431	13700	Observada	Paramirim
46360000	Morpara	-12°33'30"	-43°16'57"	399	348074	Observada	S.Francisco
46415000	Sítio Grande	-12°25'50"	-45°05'08"	512	4890	Observada	Grande
46455000	Derocal	-12°37'45"	-45°07'29"	510	6231	Observada	Femeas
46490000	Fazenda Coqueiro	-12°24'04"	-44°57'14"	497	4300	Observada	S.Desidério
46543000	Fazenda Redencao	-12°08'11"	-45°06'16"	474	5400	Observada	Ondas
46550000	Barreiras	-12°09'16"	-45°00'33"	437	18560	Observada	Grande
46570000	Ponte Serafim-Montante	-12°53'45"	-45°45'48"	711	2545	Observada	Janeiro
46590000	Nova Vida-Montante	-12°51'09"	-45°07'20"	456	7155	Observada	Branco
46610000	Sao Sebastiao	-12°58'46"	-44°52'38"	424	32586	Observada	Grande
46650000	Tagua	-12°43'20"	-44°30'11"	459	35564	Observada	Grande
46770000	Fazenda Bom Jardim	-12°59'33"	-45°31'36"	499	5925	Observada	Sapão
46790000	Formosa do Rio Preto	-12°02'51"	-45°11'26"	479	14210	Observada	Preto
46830000	Ibipetuba	-12°00'22"	-44°31'32"	432	18200	Observada	Preto
46902000	Boqueirao	-12°20'38"	-43°49'42"	401	68540	Observada	Grande

## DETERMINAÇÃO DA ESTRUTURA

Geralmente, a escolha da estrutura dos modelos não-lineares baseados em RNA é efetuada por tentativa e erro, ainda que, algumas vezes, possa ser utilizado um conhecimento mínimo do processo para minimizar o espaço de busca. Neste contexto, podem ser úteis as informações fornecidas pela FAC (Valença & Lurdermir, 1998), utilizando-se entradas exclusivamente endógenas, e/ou pela função de correlação cruzada FCC (Diniz e Andrade., 1998), se são utilizadas entradas exógenas.

Há, ainda, uma infinidade de algoritmos, métodos de "poda", que automatizam o processo de tentativa e erro, identificando estruturas através de critérios preestabelecidos (Reed., 1993).

Estes algoritmos partem de uma estrutura excessivamente grande, sendo, no decorrer do processo, eliminados os elementos considerados não significativos. Grande parte dos algoritmos efetuam a eliminação dos elementos não significativos de duas maneiras: analisando a sensibilidade dos resíduos a determinadas conexões, eliminando-as se insignificantes à variância dos resíduos (métodos de cálculo de sensibilidade), ou anulando pesos desne-



**Figura 5 – Mapa da sub-bacia 46 com posicionamento das estações fluviométricas**

cessários ao modificar a função custo (métodos de penalidade de termos).

No que diz respeito à redes NFN, ainda que as entradas auto-regressivas possam ser escolhidas com auxílio da FAC e/ou FCC, o número de partições vem sendo escolhido exclusivamente de modo empírico.

## CARACTERIZAÇÃO E PREPARAÇÃO DA SÉRIE DE VAZÕES ESTUDADA

### Caracterização da Série

As séries estudadas pertencem à sub-bacia 46, subdivisão da bacia 4 (Figura 5). Os dados de vazão das todas as séries históricas utilizadas estão em  $\text{m}^3/\text{s}$ . Todos estão consistidos e correspondem a séries diárias reais. Das estações disponibilizadas pela Aneel, na sub-bacia 46, não foram aproveitados os dados de Gameleira (46035000), Barra (46995000) e Fazenda Macambira (46675000), devido à grande quantidade de dias sem coleta (ver próximo item para maiores detalhes), chegando a haver vazios de quase 11 meses seguidos (4015 dias, aproximadamente). A Tabela 2 traz as principais características das estações estudadas.

## METODOLOGIA

### Escolha e Caracterização da Estação de Referência

Sendo um dos objetivos do trabalho a obtenção de um modelo que satisfaça a toda a sub-bacia 46, foi escolhida, então, uma estação de refe-

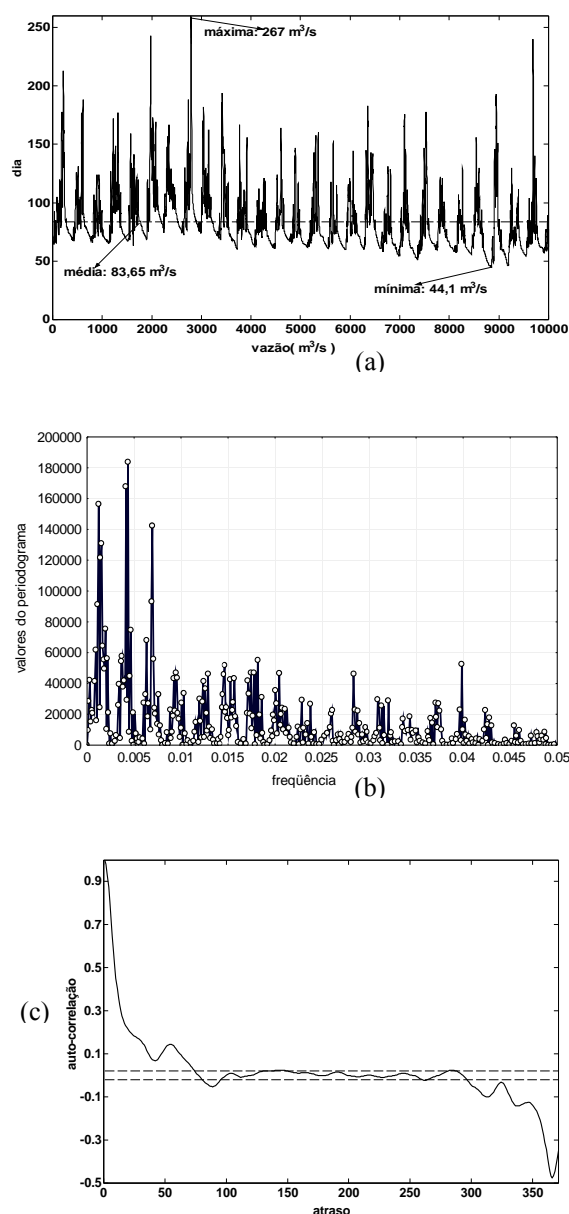
rência, cujo modelo foi testado nas outras estações pertencentes ao conjunto amostral escolhido.

A estação escolhida como referência é a de Ibepetuba (46830000), por possuir o terceiro período de coleta mais abrangente (de 01/1939 a 12/1995) sem, ao contrário das demais, apresentar ausência de dados, o que corresponde a um total de 20819 dados diários de vazão. Foram escolhidos, então, 10000 pontos para treinamento e 2000 pontos para validação, sendo que o ponto inicial para treinamento foi o quinquagésimo. Ou seja, o conjunto utilizado para treinamento encontra-se no intervalo  $y_{50} \leq y_t \leq y_{10049}$ , e o utilizado para validação, no intervalo  $y_{10050} \leq y_t \leq y_{12049}$ . Assim sendo, dispõe-se do intervalo  $y_1 \leq y_t \leq y_{49}$  para compor o padrão inicial de entradas auto-regressivas (AR).

A Figura 6, mostra as seguintes características da série representativa do conjunto utilizado para treinamento: (a) a série temporal, com indicações dos valores mínimo, médio e máximo; (b) o periodograma, mostrando a faixa de frequência mais importante, e (c) a função de autocorrelação (FAC). Os dois últimos gráficos relacionam-se com a série já diferenciada em relação ao 365° atraso. A diferenciação em relação ao atraso associado ao principal componente sazonal (para dados diários, período igual a 365) deve-se ao fato de que este pode mascarar tanto outros componentes importantes, como também a interdependência em relação aos atrasos na FAC (Box & Jenkins, 1994).

A Figura 6b mostra que, mesmo após retirada a principal componente sazonal, a série ainda apresenta componentes importantes em baixa frequência, destacando-se o associado a períodos de 230 dias.





**Figura 6 – Caracterização da série: (a) série temporal, (b) periodograma (série diferenciada:  $d=365$ ), (c) função de autocorrelação (série diferenciada:  $d=365$ ).**

Já a figura 6c mostra que a auto-correlação é estatisticamente significativa até o 73º atraso, ainda que para valores abaixo de 30%. Esta figura mostra, também, que a FAC continua com um pico no 365º atraso. Contudo, a FAC da série diferenciada apresenta um amortecimento muito maior que a FAC da série original, tendo esta um comportamento periódico ( $T=365$  dias) muito mais forte, evidenciado pela sazonalidade, como mostra a figura 7(a) e 7(b).

## ESCOLHA DO MODELO NFNARMA(P,Q,NP)

Inicialmente, optou-se por se utilizarem somente entradas auto-regressivas. Assim sendo, foram realizadas 50 épocas ( iterações ) de treinamento, visando uma validação com o menor EPM possível, e com resíduos que pudessem ser caracterizados como ruído branco

Os testes são iniciados com a estrutura mais simples, 1 entrada e 1 partição. A partir de então, o número de partições é aumentado segundo o conjunto  $np = \{1,3,5,10,15\}$ .

Depois, é aumentada a quantidade de entradas auto-regressivas segundo o conjunto  $P = \{1,2,3,4,5\}$ , sendo que, para cada quantidade de entradas, repete-se a simulação com todas as quantidades de partições pertencentes ao conjunto  $np$ , perfazendo, assim, 25 combinações. Em todas as estruturas testadas, a taxa de aprendizagem  $\alpha$  utilizada é igual a 0,01. Os testes são interrompidos com a estrutura NFNARMA(5,0,15).

Os dados reais e estimados da série são mostrados na Figura 8. As avaliações dos erros de validação se encontram Tabela 3 (EPM, EPMP, RMSE) e na figura 9(a) a ( $FPR_{cp}$ ). Já as análises dos resíduos são mostradas na figura 9(b) (PAN) e 9(c) (FAC), sendo os dois últimos utilizando 95% de confiança.

**Tabela 3 – Avaliação dos erros de validação**

EPM (%)	1,78
EPMP (%)	2,28
RMSE (média) ( $m^3/s$ )	2,98 (83,38)
$R^2$ (adimensional)	0,98

Como se pode perceber, tanto a FAC quanto o PAN mostram que a adição da parte MA ao modelo conseguiu produzir resíduos que podem ser considerados ruído branco, com uma confiança de 95%. Além disto, os resultados também melhoraram no que diz respeito aos critérios baseados na avaliação dos erros (Tabela 4). Ainda quanto à avaliação dos erros, as Figuras 10(a) e 10(b) mostram que os erros percentuais são muito pequenos, sendo verificado um erro máximo de, aproximadamente, 13%.

**Tabela 4 – Avaliação dos erros de validação**

EPM (%)	1,65
EPMP (%)	1,16
RMSE (média) ( $m^3/s$ )	2,73 (83,38)
$R^2$ (adimensional)	0,99




Figura 7 – Função de auto-correlação da série diferenciada (a) e original(b), apresentando até o 800º atraso.




Figura 8 – Dados reais e estimados do conjunto de validação

## VERIFICAÇÃO DA VALIDADE DE UM MODELO ÚNICO PARA A SUB-BACIA 46

Obtida a estrutura para a estação de referência, pretende-se verificar a possibilidade de que esta estrutura também seja eficiente na predição do conjunto de dados das demais estações pertencentes à sub-bacia 46. Para tanto, a estrutura de referência,  $NFNARMA(5,3,15)$ , foi testada para o conjunto de dados diários de vazão.

Como em grande parte destas estações os dados correspondem ao período entre 01/01/1977 e 31/12/1995 (6939 dados), escolheu-se, para todas as estações a serem avaliadas, este intervalo como o correspondente à amostra a ser estudada. Assim, os dados inseridos no intervalo [01/01/1977; 31/01/1977] foram disponibilizados para o conjunto inicial de entradas. Já o intervalo [01/02/1977; 31/12/1990] (5082 dados) foi utilizado para treinamento, enquanto que o intervalo [01/01/1991; 31/12/1995] (1826 dados) foi utilizado para validação. Foram realizadas, em

todos os casos, 50 épocas ( iterações ) de treinamento.

## RESULTADOS OBTIDOS E DISCUSSÃO

Os resultados mostrados a seguir correspondem à utilização da estrutura  $NFNARMA(5,3,15)$  para predição de vazões diárias de 15 estações pertencentes à sub-bacia 46.

### Avaliação dos resultados de predição

Primeiramente são avaliados os erros de predição segundo o EPM, EPPM, RMSE,  $R^2$  (Tabela 5) e a  $FPR_{ep}$ .

A Avaliação dos erros de predição retorna resultados satisfatórios no que diz respeito a todos os critérios, sendo que todas as séries analisadas apresentam erros menores que 10%, como apresentado pela Figura 11.a. Entretanto, as séries associadas às estações 46295000 (Figura 11.b) e 46490000, o EPPM está abaixo de 20%.

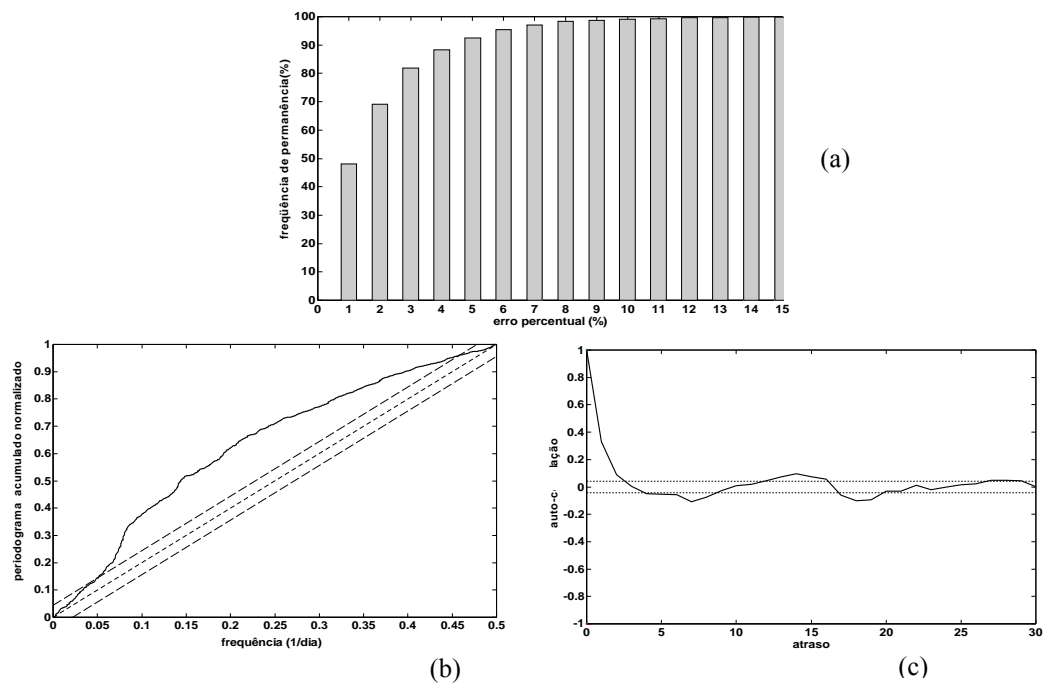


Figura 9– Eficiência da validação: (a)  $FPR_{en}$ , (b) PAN (5%); (c) FAC(5%)




Figura 10 – Avaliação da validação: (a) erro (b)  $FPR_{cp}$ , (c) PAN (5%); (d) FAC(5%)


A fim de ratificar o excelente resultado obtido das avaliações dos erros, a  $FPR_{ep}$  (10%)  $\cong$  90 (Figura 11.a) para todas as estações analisadas, excetuando-se, novamente, as estações 46295000 (Figura 11.b) e 46490000; ou seja, 90% dos erros de predição são menores que 10%. E mesmo para as estações 46295000 e 46490000, os valores retornados pela  $FPR_{ep}$  são satisfatórios, já que mesmo o pior resultado, apresentado pela 46295000, indica que 70% dos erros são menores que 10%.

**Tabela 5 – Avaliação dos erros de predição**


Estação (Código)	EPM (%)	EPPM (%)	RMSE (m <sup>3</sup> /s)	Média (m <sup>3</sup> /s)	R <sup>2</sup>
46295000	9,96	38,26	5,18	5,81	0,95
46360000	2,08	1,68	88,26	2566,0	0,99
46415000	1,64	8,01	1,39	35,21	0,98
46455000	1,63	7,05	5,45	55,16	0,90
46490000	4,47	41,23	1,75	5,82	0,77
46543000	2,53	8,05	4,31	51,44	0,92
46550000	2,21	19,86	6,00	92,24	0,95
46570000	3,14	11,46	0,89	13,70	0,97
46590000	2,56	22,06	3,88	51,50	0,92
46610000	1,18	2,31	4,60	194,71	0,99
46650000	1,21	1,46	4,77	191,56	0,99
46770000	1,71	2,30	1,01	33,27	0,98
46790000	1,63	1,42	3,03	97,42	0,99
46830000	1,29	1,88	2,61	96,55	0,99
46902000	0,83	0,81	3,67	281,72	0,99

De fato, os piores resultados foram apresentados pelos processos associados às séries que apresentaram as menores médias, sendo que o pior resultado é apresentado pela única série, dentre as estudadas, que apresenta régua seca, ou seja, vazão nula durante o período seco. Isto implica em uma diferença significativa em relação à característica da série de referência (46830000), como pode ser observado na Figura 12.

Pode-se observar que, mesmo as estações estando posicionadas em rios diferentes, e distantes uma da outra (Figura 5), as características (Figura 12.a) das séries 46830000 e 46610000 são bastante semelhantes, o que não acontece entre a 46830000 e a 46295000, ou entre aquela e a 46490000. Este fato é melhor visualizado na figura 12(b), que mostra a dinâmica através da variação percentual. Pode-se perceber claramente que as variações na 46830000 e na 48610000 são significativamente menores que as apresentadas pela 46295000 e pela 46490000, sendo que nesta a variação é menos intensa que na 46295000.



46360000 (a)




46295000 (b)

**Figura 11 – Curva de Frequência de Permanência Relativa dos erros percentuais de predição para as estações 46360000 e 46295000.**


### Análise dos Resíduos

As figuras 13, 14, 15 e 16 mostram a FAC e o PAN para as séries modeladas utilizando-se a estrutura da estação de referência

Ao contrário do resultado retornado pela avaliação dos erros de predição, a análise dos resíduos mostra que o modelo da estação de referência não conseguiu explicar totalmente, do ponto de vista estatístico, a grande maioria das séries estudadas. De fato, as únicas séries que apresentaram resultados realmente satisfatórios, foram a 46570000, 46610000, 46770000, e é interessante observar que dentre estas, somente a 46770000 pertence ao mesmo curso d'água da estação de referência. O modelo, para algumas dentre as demais séries, pode até ter conseguido retirar a sazonalidade, caracterizando, pelo PAN, o ruído como branco. Porém, a FAC apresenta ainda autocorrelações significativas.



**Figura 12.a - Característica referente ao conjunto de validação das séries 46830000, 46610000, 46295000 e 46490000.**



**Figura 12.b –Variação percentual referente ao conjunto de validação das séries 46830000, 46610000, 46295000 e 46490000.**

Apesar disto, é fato que se conseguiu retirar grande parte da informação na maioria das séries estudadas. Das 14 séries estudadas, em apenas 5 os resultados foram considerados críticos, apresentando picos de autocorrelação acima de 15% e/ou periodogramas acumulados normalizados acima de 10% do valor determinado pelo teste K-S como o

esperado para ruído branco. São elas: 46360000, 46455000, 46543000, 46650000, 46902000. É interessante notar que este fato não tem relação alguma com a semelhança entre as séries com a referência, como mostrada na avaliação dos erros. Isto pode ser explicado pelo fato de que o modelo é orientado para diminuir o erro de predição; portanto, espera-

se que séries semelhantes realmente apresentem resultados semelhantes no que diz respeito à avaliação dos erros.




Figura 13 – FAC (a) e PAN (b) dos resíduos de predição para as estações 46295000

Já o resultado apresentado pela análise dos resíduos indica que o modelo utilizado não foi suficiente para explicar a série. Isto pode ser devido ou à ausência no conjunto de entradas de variáveis exógenas fortemente correlacionadas com a série em estudo (como, por exemplo, dados pluviométricos), ou à simplicidade da estrutura utilizada. Quanto a este último fator, aumentando-se a quantidade de entradas MA de 3 para 20 (modelo *NFNARMA(5,20,15)*), foram melhoradas, significativamente, as respostas tanto da FAC quanto do PAN para, por exemplo, a série 46650000 (Figura 17).

Tabela 6 – Avaliação dos erros de validação para a série 46650000, utilizando-se um modelo *NFNARMA(5,20,15)*.

EPM (%)	1,06
EPMP (%)	1,41
RMSE (média) (m³/s)	4,08 (191,56)
R²	0,99

Pode-se perceber que se conseguiu uma redução do valor da autocorrelação máxima de 0,569 (4º atraso) para 0,149 (18º atraso), além de tratar quase que completamente a sazonalidade presente nos resíduos. A Tabela 6 mostra que a utilização do modelo *NFNARMA(5,20,15)* também melhorou as respostas da avaliação dos erros de predição.

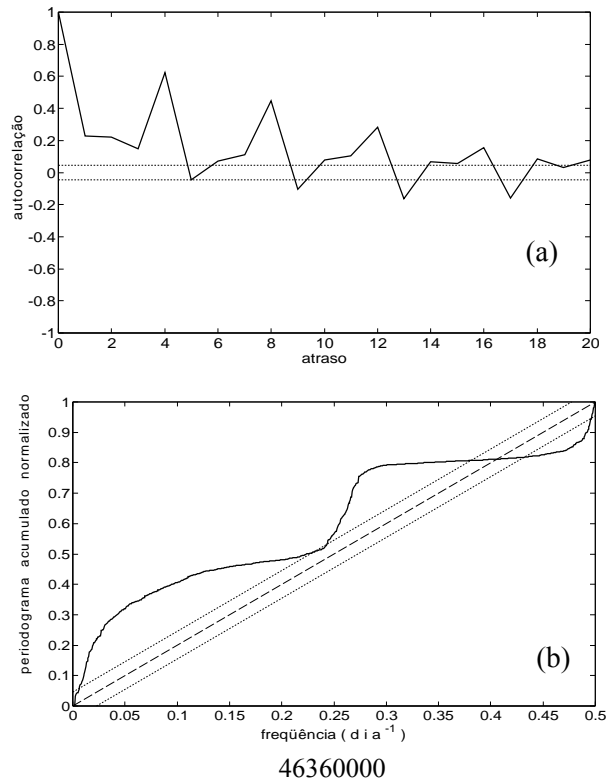


Figura 14 – FAC (a) e PAN (b) dos resíduos de predição para as estações 46360000

CONCLUSÃO

Foram utilizados, como estudo de caso, os dados diários de vazão de 15 estações da sub-bacia 46, sendo escolhida como estação de referência a estação 46830000, para modelagem dos dados das demais estações, pois oferece o maior histórico de vazões sem ausência de dados.

As redes NFN apresentam excelentes resultados na predição de vazões para as estações estudadas, principalmente no que diz respeito à avaliação dos erros de predição, que, de fato, é a principal preocupação mostrada na literatura. Já a agregação de entradas MA melhorou significativamente os resultados apresentados pelos modelos puramente

auto-regressivos, principalmente no que diz respeito à explicação dos dados de validação. Pode-se concluir, também, que é possível obter-se uma estrutura  $NFNARMA(p,q,np)$  única para modelagem de toda uma sub-bacia.




Figura 15 – FAC (a) e PAN (b) dos resíduos de predição para as estações 46590000

No que diz respeito à utilização de redes NFN para a predição de vazões, a predição para a estação de referência já foi considerada muito eficiente, mesmo sendo utilizado um modelo puramente auto-regressivo ( $NFNARMA(5,0,15)$ ), já apresentando os seguintes resultados no que diz respeito à avaliação dos erros de predição: EPM= 1,78%; EPMP= 2,28%, RMSE= 2,98 m<sup>3</sup>/s (média = 83,38 m<sup>3</sup>/s), R<sup>2</sup>= 0,99, FRP<sub>cp</sub> (1)= 47%, e FRP<sub>cp</sub>(12)= 100%. Ou seja, segundo a FRP<sub>cp</sub> obtida, 40% dos erros são menores que 1%, e 100% menores que 12%. Contudo, os resíduos obtidos não se comportam como ruído branco, apresentando sazonalidades significativas no intervalo entre 0,06 dia<sup>-1</sup> e 0,45 dia<sup>-1</sup>, e também autocorrelações significativas a partir do 7º atraso.

A fim de tentar caracterizar o resíduo obtido da predição do modelo como ruído branco, buscando, portanto, retirar toda a informação possível (do ponto de vista estatístico) do conjunto de validação, este trabalho propôs a utilização dos resíduos

como parte do conjunto de entradas, agregando, portanto, uma parcela MA ao modelo AR original, que, a partir de então, foi denominado modelo *neo fuzzy neuron auto-regressivo de médias móveis* ( $NFNARMA(p,q,np)$ ).

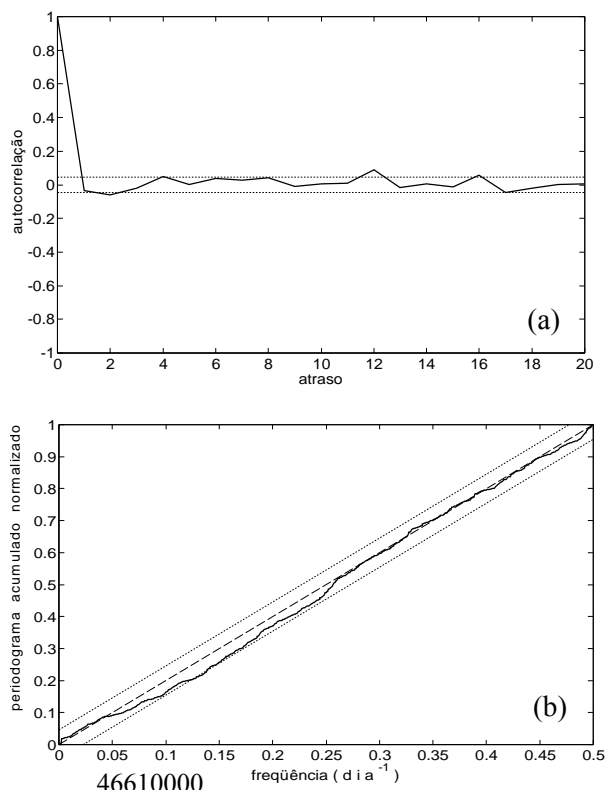



Figura 16 – FAC (a) e PAN (b) dos resíduos de predição para as estações 46610000

Assim sendo, utilizando-se um modelo  $NFNARMA(5,3,15)$ , conseguiu-se não somente caracterizar os resíduos obtidos da predição como ruído branco, como também diminuir os valores retornados pelos critérios baseados na avaliação dos erros: EPM= 1,65%; EPMP= 1,16%, RMSE= 2,73 m<sup>3</sup>/s, R<sup>2</sup>= 0,99, FRP<sub>cp</sub> (1)= 50%, e FRP<sub>cp</sub>(10)= 100%.

Já quanto à utilização da estrutura  $NFNARMA(5,3,15)$  para predição nas demais estações, os resultados retornados pela avaliação dos erros de predição foram considerados muito bons, sendo os piores resultados obtidos nos processos das estações 46295000 (EPM= 9,96%; EPMP= 38,26%, RMSE= 5,18 m<sup>3</sup>/s, R<sup>2</sup>= 0,95, FRP<sub>cp</sub> (1)= 45%, e FRP<sub>cp</sub>(10)= 70%), e 46490000 (EPM= 4,47%; EPMP= 41,23%, RMSE= 1,75 m<sup>3</sup>/s, R<sup>2</sup>= 0,77, FRP<sub>cp</sub> (1)= 32%, e FRP<sub>cp</sub>(10)=70%). Estas são as estações, dentre as estudadas, que apresentam diferenças significativas em relação à referência, tanto no que diz respeito à

característica da série, quanto no que diz respeito à sua dinâmica.



**Figura 17– FAC e PAN dos resíduos de predição para a série 46650000, utilizando-se um modelo  $NFNARMA(5,20,15)$ .**

Já os resultados da análise dos resíduos só foram satisfatórios para as estações 46570000, 46610000 e 46770000. Apesar disto, apenas para 5 estações (46360000, 46455000, 46543000, 46650000 e 46902000) os resultados foram considerados críticos, apresentando picos de autocorrelação acima de 15% e/ou periodogramas cumulativos normalizados acima de 10% do valor determinado pelo teste K-S como o esperado para ruído branco. Acredita-se que podem-se melhorar estes resultados aumentando-se a estrutura utilizada, ou agregando entradas exógenas que tenham correlação com os dados de vazão, como, por exemplo, dados pluviométricos.

Como exemplo, foi utilizado um modelo  $NFNARMA(5,20,15)$  (agregando-se 18 entradas MA à estrutura de referência) para predição de vazões na estação 46650000. Com isto, conseguiu-se diminuir a autocorrelação máxima de 0,569 (4º atraso) para 0,149 (18º atraso) e tratar quase que completamente a sazonalidade presente nos resíduos.

## REFERÊNCIAS

- AGUIRRE, A. 2000. *Introdução à identificação de sistemas: técnicas lineares e não lineares aplicadas à sistemas reais*. Editora UFMG, Belo Horizonte, 554 p.
- AGUIRRE, A., AGUIRRE, L.A. 2000. Time series analysis of monthly beef cattle prices with non-linear autoregressive models. *Journal of Applied Economics*, 32: 265-275.
- ALVIM FILHO, A. DE C.; SILVA, S.R.; MARTINEZ, C.B., CAMINHAS, W.M. 2000. Predição de vazões utilizando rede "Neo Fuzzy Neuron". *Anais do II Simpósio sobre Pequenas e Médias Centrais Hidrelétricas*, Canela-RS
- BOX, G.E.P., JENKINS, G.M. 1976. *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco, CA, USA.
- BOX, G.E.P., JENKINS, G.M., REINSEL, G.C. 1994. *Time Series Analysis: Forecasting and Control*. Prentice Hall, Englewood Cliffs, New Jersey. 598 p.
- CAMINHAS, W.M. 1997. Estratégias de detecção e diagnóstico de falhas em sistemas dinâmicos. *Tese de Doutorado*. FCEE, Unicamp, Campinas, SP. 160 p.
- CAMINHAS, W.M., PEREIRA, G. A.S., TAVARES, H.M.F., GOMIDE, F.A.C. 1998. Identificação de sistemas dinâmicos: Abordagem baseada em neurônio nebuloso. *Anais do V Simpósio Brasileiro de Redes Neurais*, p. 105-110. Belo Horizonte, MG.
- COULIBALY, P., ANCTIL, F., BOBÉE, B. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, 230: 244–257.
- CRAWFORD, N.H., LINSLEY JR., R.K. 1966. *Digital simulation in watershed hydrology: Stanford watershed model IV*. Stanford University, Dept. Civ. Eng. Tech. Rep. 39.
- DINIZ, H., ANDRADE, L.C.M. DE. 1998. Previsão de Séries Temporais utilizando redes neurais artificiais e modelos de Box & Jenkins. *Anais do V Simpósio Brasileiro de Redes Neurais*, p. 173-178, Belo Horizonte, MG.
- IVAKHNENKO, A.G., MULLER, J.A. 1995. Self-organization of nets of active neurons. *System Analysis Modeling Simulation*, 20: 93-106.
- KARNIK, N.N., MENDEL, J.M. 1999. Applications of type-2 fuzzy logic systems to forecasting of time-series. *Information Sciences*, 120: 89-111.
- KUO, R.J., CHUE, K.C. 1999. Fuzzy neural networks with application to sales forecasting. *Fuzzy Sets and Systems*, 108: 123-143.
- LINSLEY JR., R.K., KOHLER, M.A., PAULHUS, J.L.H. 1988. *Hydrology for engineers*. McGraw-Hill, London. 492 p.



- MENEZES, L.M. DE, BUNN, D.W., TAYLOR, J.V. 2000. Review of guidelines for the use of combined forecasts. *European Journal of Operational Research*, 120: 190-204. periodic trends. *Electrical Power and Energy Systems*, 23: 63–68.
- REED, R. 1993. Pruning algorithms-A survey. *IEEE Transaction on Neural Networks*, 5: 740-747.
- ROSA, P.C., MARTINEZ, C.B. 2000. Gerenciamento econômico del despacho de carga por redes neuronales. *CIT* (in press).
- TSENG, F.-M, TZENG, G.-H., YU, H.-C., YUAN, B.J.C. 2001. Fuzzy ARIMA model for forecasting the foreign exchange market. *Fuzzy Sets and Systems*, 118: 9-19.
- VALENÇA, M.J.S., LURDERMIR, T.B. 1998. Self-organizing modeling in forecasting daily river flows. *Annals of V Brazilian Symposium on neural networks-Brazilian Computer Society, IEEE*, 1: 210-214. Belo Horizonte-MG.
- YAMAKAWA, T; UCHINO, E; MIKI, T; KUSANAGI. 1992. A Neo Fuzzy Neuron and its Applications to System Identification and Predictions to System Behaviour. *Proc. Of 2° IZUKA*, p. 477-483. Ilizuka, Japan.

**Keywords:** *outflow prediction, artificial neuron networks, neuron-nebulous models*

### ***The application of Neo-Fuzzy-Neuron networks to flow prediction***

#### **ABSTRACT**

*The prediction and modeling of a river's outflow series is important not only for energy production, but also for the safety of population living near its banks. Progress in system identification has contributed significantly to the consistency and reliability of outflow modeling. Over the last decade there has been much research in the use of models based on artificial neuron networks (RNA). A major contribution to this area has been the integration of fuzzy logic with RNAs, leading to neuron-fuzzy models. Among these, Neo-Fuzzy-Neuron networks have been successful in mapping non-linear systems. In this paper, NFN networks are applied to predict daily outflows, through an assessment of the viability of using a single NFN structure for modeling tributary outflows at all stations within a sub-catchment. To apply the methodology, case studies were used with the daily flow data from 15 stations belonging to sub-catchment 46 ( São Francisco river ). One of these stations, the most comprehensive and complete, was chosen as a reference for modeling the data of the others. The NFN networks gave excellent outflow prediction results for the stations studied. In addition, the inclusion of moving-average (MA) inputs considerably improved the results obtained using only models with auto-regressive terms, particularly with regard to validation. The viability of obtaining a single NFNARMA (p,q,np) structure for modeling the entire sub-catchment 46 has been established.*