



**XVI SNPTEE**  
Seminário Nacional de Produção e  
Transmissão de Energia Elétrica

GRUPO IX

GRUPO DE ESTUDOS DE OPERAÇÕES DE SISTEMAS ELÉTRICOS

REDES NEURAIS NEBULOSAS PARA PREVISÃO DE VAZÕES MÉDIAS MENSAIS

Rosângela Ballini  
FEEC/ UNICAMP

Secundino Soares  
FEEC/UNICAMP\*

Marinho Gomes de Andrade  
ICMC/USP

## RESUMO

Este artigo apresenta uma aplicação de previsão de vazões mensais utilizando uma rede neural nebulosa. Esta metodologia une os benefícios das redes neurais e da teoria de conjuntos nebulosos, combinando-os em um sistema integrado. Os parâmetros que definem a estrutura da rede neural nebulosa são obtidos através de um método de aprendizado construtivo. Para analisar o desempenho destas metodologias foram utilizados dados de diferentes postos de aproveitamento, localizados em diferentes regiões do Brasil. Os resultados foram comparados com o sistema PREVAZ e com redes neurais, mostrando que a rede neural nebulosa apresentou um melhor desempenho que o sistema PREVAZ.

**PALAVRAS-CHAVE:** Previsão de Vazões Mensais, Redes Neurais Nebulosas, Redes Neurais, Sistema PREVAZ.

## 1.0 INTRODUÇÃO

O planejamento da operação de sistemas de produção de energia elétrica visa determinar uma política de operação para usinas hidroelétricas e termoelétricas do sistema que atenda a demanda de energia elétrica de forma econômica e confiável. Em linhas gerais, o objetivo é usar da forma mais eficiente possível a geração de base hidráulica para substituir ao máximo a geração térmica, cujo custo do combustível é elevado e crescente com a geração. As usinas hidroelétricas possuem características de produção não-linear e suas vazões afluentes são variáveis aleatórias, sendo assim um problema estocástico e não-linear. Devido a complexidade do problema, é comum sua

decomposição em uma cadeia de planejamento que inclui as etapas de longo, médio e curto prazos (1).

O parque gerador de energia elétrica no Brasil é predominantemente hidráulico, sendo o setor elétrico responsável pelo gerenciamento da água nos grandes reservatórios de acumulação existentes no país. Estes reservatórios, que até pouco tempo, destinava-se exclusivamente a geração de energia, hoje são alvos de interesses diversos e conflitantes. Neste contexto, cresce a importância na área de planejamento e controle de sistemas de recursos hídricos.

Os modelos de simulação e/ou otimização empregados para o planejamento e operação de sistemas de produção de energia elétrica utilizam usualmente séries de vazões com intervalos de discretização mensal/semanal.

Atualmente, os modelos empregados pelo setor elétrico brasileiro têm como base os modelos estocásticos, baseados na metodologia mista de Yejevich – Box & Jenkins (2), para todos os aproveitamentos considerados no programa do Grupo Coordenador para a Operação Interligada (3), (4). Esta metodologia é conhecida como sistema PREVAZ.

Redes neurais artificiais, especialmente redes neurais multi-camadas com algoritmo *back-propagation* (5) vêm sendo sugeridas para análise de séries temporais devido a sua capacidade para tratar com relações de entrada-saída de dados não-lineares, destacando sua habilidade de aprendizado e capacidade de generalização, associação e busca paralela. Estas qualidades as tornam capazes de identificar e assimilar as características mais marcantes

\* UNICAMP/DENSIS/FEEC – P. O. 6101  
CEP: 13083-970, Campinas, SP, Brasil.  
Tel: (0xx19) 3788-3705 Fax: (0xx19) 3289-1395  
Email: dino@densis.fee.unicamp.br.

das séries, tais como sazonalidade, periodicidade, tendência, entre outras, muitas vezes camufladas por ruídos (6). A capacidade de mapeamentos complexos das redes neurais cresce com o número de camadas e neurônios, acarretando maior tempo de processamento bem como considerável soma de dados. Entretanto, na prática muitas vezes os parâmetros devem ser ajustados rapidamente e somente uma pequena quantidade de dados é disponível (7).

Freqüentemente, dados do mundo real apresentam ruídos, podendo conter contradições e imperfeições. Tolerância à imprecisão e incertezas são também exigidas para considerar tratabilidade e robustez. Conjuntos nebulosos baseados em modelos de análise de dados vêm sendo empregados sob essas hipóteses. Este trabalho propõe a aplicação de modelos de redes neurais nebulosas que unem os benefícios das redes neurais e da lógica nebulosa, combinando-os em um sistema integrado.

Em (8) e (9) foi utilizada esta estrutura de rede neural nebulosa para previsão de vazões médias mensais um passo à frente, sendo o desempenho do modelo comparado com os modelos ajustados de redes neurais e periódicos auto-regressivos. Os resultados mostraram um melhor desempenho para a rede neural nebulosa, com erros 50% menores que os demais modelos.

A estrutura do modelo de rede neural nebuloso usado neste trabalho apresenta é adaptativa, onde os parâmetros que definem a estrutura da rede são obtidos através de um método de aprendizagem construtivo. Este modelo foi desenvolvido por (10) e será descrito a seguir juntamente com o algoritmo de aprendizagem para previsão de vazões médias mensais.

Neste trabalho, também são realizadas previsões de vazões médias mensais usando os modelos PREVAZ e redes neurais multi-camadas com algoritmo *back-propagation*. Para as três metodologias serão realizadas previsões um passo à frente e vários passos à frente para os postos de aproveitamentos de Furnas, Emborcação e Sobradinho, localizadas nos rios Grande, Paranaíba e São Francisco, respectivamente. O desempenho dos modelos foi comparado e os resultados mostraram que a rede neural nebulosa apresentou melhor desempenho que o modelo PREVAZ e a rede neural multi-camadas com algoritmo *back-propagation* tanto para previsão um passo à frente como para previsão com vários passos à frente, com erros significativamente menores.

## 2.0 REDE NEURAL NEBULOSA

A estrutura da Rede Neural Nebulosa (RNN), proposta em (10), apresenta as seguintes principais características: (a) fácil inserção e extração de conhecimento na forma regras lingüísticas nebulosas; (b) o processamento neural é semelhante ao mecanismo de raciocínio nebuloso; (c) regras são geradas automaticamente, sem qualquer proce-

dimento adicional; (d) a partição do espaço de entradas garante que as regras cobrem todo o domínio de operação do modelo; (e) A RNN é um aproximador universal. As características (b) e (c) são condições necessárias para garantir que o sistema proposto tenha uma natureza dual, ou seja, o sistema pode ser visto ora como um sistema baseado em regras nebulosas, ora como uma rede neural nebulosa (11).

A rede é baseada no mecanismo de inferência nebulosa, codificando uma base de regras na forma de “Se um conjunto de condições é satisfeito Então um conjunto de consequentes é inferido”, o qual pode ser definido da seguinte forma:

Entradas:	$x_1 \text{ é } A_1 \text{ e } \dots x_M \text{ é } A_M$
Regras:	Se $x_1 \text{ é } A_1^1 \text{ e } \dots x_M \text{ é } A_M^1$ Então $y \text{ é } w_1$
	Se $x_1 \text{ é } A_1^i \text{ e } \dots x_M \text{ é } A_M^i$ Então $y \text{ é } w_i$
	Se $x_1 \text{ é } A_1^N \text{ e } \dots x_M \text{ é } A_M^N$ Então $y \text{ é } w_N$
Saída:	$y = y(\mathbf{x})$

onde  $x_j, j=1, \dots, M$ , é uma variável nebulosa e  $M$  o número de entradas;  $A_j$  e  $A_j^i, i=1, \dots, N$ , são conjuntos nebulosos representados por funções de pertinência sendo  $N$  o número de regras nebulosas;  $y$  é um número real definido no espaço de saída. Os valores de  $w_i(\mathbf{x}) = w_i$  são números reais e representam os pesos sinápticos correspondentes aos consequentes das regras nebulosas, sendo que, para cada vetor de entrada  $\mathbf{x} = (x_1, \dots, x_M)'$ , está associado um único peso sináptico  $w_i$ .

Para efeito de cálculo e representação de conhecimento na RNN, todas as funções de pertinência são discretizadas. Desta forma, define-se  $a_{jk}$  como sendo o valor da função de pertinência que representa o conjunto nebuloso  $A_j$ , para toda variável de entrada  $x_j$  pertencente ao  $k$ -ésimo intervalo de discretização, ou seja,  $A_j(x_j) = a_{jk}$ . Da mesma maneira, define-se o valor de  $a_{jk}^i$  como sendo o valor da função de pertinência do conjunto nebuloso  $A_j^i$ , isto é,  $A_j^i(x_j) = a_{jk}^i$ .

O valor numérico de  $y$  é determinado através de uma seqüência de três estágios de processamento:

(a) *Cálculo dos antecedentes*: Para cada regra  $i, i=1, \dots, N$ , e para cada antecedente  $j$ , calcula-se a medida de

possibilidade  $P_j^i$  entre os conjuntos nebulosos  $A_j$  e  $A_j^i$ , da seguinte forma:

$$P_i^j(\mathbf{x}) = S \left[ T(A_j, A_j^i) \right] \quad (1)$$

onde  $S$  e  $T$  são operadores lógicos, chamados de *s-norma* e *t-norma*, respectivamente.

(b) *Agregação dos antecedentes*: Para cada regra  $i$ ,  $i=1, \dots, N$ , agregam-se os valores de cada um dos antecedentes  $j$ ,  $j=1, \dots, M$ , através de uma *t-norma*. O resultado desta agregação é chamado de nível de ativação  $H^i$ , definido por:

$$H^i(\mathbf{x}) = T_j \{ P_j^i \} \quad (2)$$

(c) *Agregação das regras*: A saída do sistema de inferência, ou seja, a defuzzificação dos dados, é realizada através de uma média ponderada entre os consequentes e o nível de ativação calculados na equação (2) para cada regra, dada por:

$$y(\mathbf{x}) = \frac{\sum_{i=1}^N H^i(\mathbf{x}) w_i}{\sum_{i=1}^N H^i(\mathbf{x})} \quad (3)$$

A RNN é constituída por unidades de processamento, conhecidas como neurônios nebulosos. Um modelo geral do neurônio nebuloso é apresentado na figura 1. Matematicamente, este neurônio pode ser representado como:

$$y(\mathbf{x}) = \gamma(\phi(\Psi(\mathbf{x}))) = \gamma(\phi(\Psi_1(x_1), \dots, \Psi_M(x_M)))$$

onde  $\Psi: \mathfrak{R}^M \rightarrow \mathfrak{R}^M$  é o operador sináptico,  $\phi: \mathfrak{R}^M \rightarrow \mathfrak{R}$  é o operador de agregação e  $\gamma: \mathfrak{R} \rightarrow \mathfrak{R}$  é a função de ativação.




Figura 1: Modelo Geral do Neurônio Nebuloso.

O modelo da RNN apresenta uma arquitetura estática, ou seja, não recorrente com 5 camadas, como mostra a figura 2. Pode-se verificar que o mecanismo de inferência descrito através dos procedimentos de comparação, agregação dos antecedentes e agregação das regras é isomórfico à estrutura da rede.

A primeira camada é dividida em  $M$  grupos de neurônios, cada um associado a uma variável de entrada. Cada neurônio nesta camada representa um intervalo de discretização  $I_{jk}$ , correspondente ao espaço de entrada.

Ou seja, há tantos neurônios nesta camada quantos forem os intervalos de discretização. Cada grupo de neurônios é responsável por transformar as entradas não nebulosas para que as camadas seguintes possam tratar a informação adequadamente. Estes grupos geram os valores

$a_{jk}$  referentes à função de pertinência que representa o conjunto nebuloso  $A_j$ . Assim, um neurônio recebe um sinal simples, decodifica e o transmite para a segunda camada. O sinal  $a_{jk}$  é transmitido pelo  $k$ -ésimo neurônio localizado no  $j$ -ésimo grupo.




Figura 2: Rede Neural Nebulosa.

Definindo-se  $\psi$  e  $\phi$  como funções identidade, a saída  $a_{jk} \in \{0, 1\}$  é dada por  $a_{jk} = \gamma(x_j)$ . Para um intervalo  $I_{jk} = (x_{jk_l}, x_{jk_F}]$ , a função decodificada  $\gamma(\cdot)$  para este neurônio, através do  $k$ -ésimo intervalo é dada por:

$$a_{jk} = \gamma(x_j) = \begin{cases} 1, & \text{se } x_j \in (x_{jk_l}, x_{jk_F}] \\ 0, & \text{caso contrário} \end{cases}$$

A segunda camada contém  $N$  grupos (número de regras pré-definido), cada qual contendo  $M$  neurônios (número de antecedentes de cada regra). Esta camada representa o primeiro estágio de inferência, chamado de comparação. O  $j$ -ésimo neurônio do  $i$ -ésimo grupo representa, através dos pesos sinápticos  $a_{jk}^i$ , a função de pertinência do conjunto nebuloso  $A_j^i$ . Portanto, o  $i$ -ésimo grupo é composto por neurônios que representam as funções de pertinência de todos os conjuntos nebulosos correspondentes aos antecedentes da  $i$ -ésima regra. Considerando-se que a função  $\psi = t$ -norma,  $\phi = s$ -norma e  $\gamma$  é a função identidade, a saída do  $j$ -ésimo neurônio é a medida de possibilidade  $P_j^i$  dada pela equação (1).

A terceira camada contém  $N$  neurônios, cada um com  $M$  entradas. Para cada grupo  $i$  da segunda camada, um neurônio na terceira camada realiza agregação dos antecedentes (segundo estágio de inferência). Todas as conexões possuem peso sináptico unitário. A saída desta camada é dada pela equação (3), assumindo-se que  $\psi =$  função identidade,  $\phi = t$ -norma e  $\gamma =$  função identidade.

A quarta camada possui dois neurônios, ambos com  $N$  entradas. Ou seja, cada neurônio  $i$  da terceira camada está conectado com os dois neurônios da quarta camada. O operador de agregação associado com estes neurônios é a

soma algébrica. Um dos neurônios conecta-se com o  $i$ -ésimo neurônio da camada anterior através das sinapses, com pesos  $w_i$ . Os operadores  $\psi$  e  $\phi$  são, respectivamente, o operador algébrico e a soma algébrica, e  $\gamma$  é a função identidade. As saídas são constituídas pelo numerador da equação (3).

O outro neurônio também é conectado com todos os neurônios da camada anterior com pesos sinápticos unitários. Considerando-se  $\psi$  = função identidade,  $\phi$  = soma algébrica e  $\varphi$  = função identidade, a saída equivale ao denominador da inferência nebulosa definida em (3).

Finalmente, a última camada consiste de um único neurônio para calcular o quociente dos sinais de entrada, ou seja, para calcular  $y = y(\mathbf{x})$  (equação (3)). Portanto, as conexões possuem pesos unitários e os operadores  $\psi$ ,  $\phi$  e  $\varphi$  são funções identidade, operador de divisão e a função identidade, respectivamente.

Cada uma das camadas da RNN possui uma associação com os diversos estágios da inferência nebulosa, descrita através das equações de (1) a (3). Além disso, os pesos sinápticos representam as funções de pertinência dos antecedentes e conseqüentes das regras nebulosas. Assim, a RNN codifica um conjunto de  $N$  regras em sua estrutura, processa as informações através de neuro-computação, executando raciocínio nebuloso.

Esta estrutura apresenta um método de aprendizagem construtivo, o qual capacita a rede compensar degradações de desempenho provocadas por variações dos parâmetros do modelo ou outras perturbações devido a mudanças provocadas no sistema real. Na próxima seção é apresentado o método de aprendizagem utilizado para a previsão de vazões médias mensais.

#### 4.0 MÉTODO DE APRENDIZAGEM

O modelo proposto por (10) apresenta um método de aprendizagem construtivo, onde regras nebulosas são adicionadas à estrutura da rede quando o desempenho desta não é satisfatório.

A estratégia de aprendizagem da RNN se divide em duas fases. A primeira fase corresponde à aprendizagem não supervisionada, ou seja, a aprendizagem se processa sem que as saídas sejam fornecidas, envolvendo somente uma parte da arquitetura, mais especificamente a segunda camada. Nesta fase, a rede aprende as funções de pertinência dos antecedentes das regras nebulosas enquanto ajusta os pesos sinápticos associados a esta camada. O método utilizado durante esta etapa é do tipo competitivo, baseado nas redes do tipo Kohonen. A segunda fase adota um método supervisionado, baseado no método do gradiente para aprendizagem dos

conseqüentes das regras e envolve apenas o ajuste dos pesos da quarta camada. Assim, a RNN deve aprender os pesos sinápticos  $a_{jk}^i$  relacionados aos neurônios da segunda camada, bem como os pesos sinápticos  $w_i$  da quarta camada.

O algoritmo de aprendizagem consiste na apresentação dos pares de entrada/saída desejada à rede, sendo o  $t$ -ésimo par dado por  $(\mathbf{x}(t), y_d(t))$ , onde  $\mathbf{x}(t)$  é o vetor de entrada com  $M$  componentes e  $y_d(t)$  é a saída desejada.

Considera-se que os conjuntos nebulosos  $A_j^i(\cdot)$ , são representados por funções de pertinência do mesmo tipo, simétricas e complementares definidas através dos valores modais  $c_j^i(t)$  e de dispersão  $\rho^i$ . Assim, determinando-se o valor modal e de dispersão de cada função de pertinência  $F_j^i(\cdot)$  e definidos os intervalos de discretização  $I_{jk}$ , é possível determinar os pesos sinápticos  $a_{jk}^i$  na forma:

$$a_{jk}^i = F_j^i(x_j), \text{ tal que } x_j \in I_{jk} = (x_{jk_f}, x_{jk_F}]$$

Os valores modal e de dispersão de cada função  $F_j^i(\cdot)$  devem ser aprendidos durante o treinamento, segundo o método de aprendizado competitivo, para determinar os pesos sinápticos  $a_{jk}^i$  da segunda camada.

A função erro que determina o índice de desempenho do modelo, necessária a aplicação do método baseado no gradiente descendente, é definida por:

$$E(\mathbf{x}(t)) = \frac{1}{2} (y_d(t) - y(t))^2 \quad (4)$$

onde  $y(t)$  é a saída da rede em relação à entrada  $\mathbf{x}(t)$ , dada pela equação (3).

O objetivo do processo de treinamento é ajustar os parâmetros (valor modal, dispersão e pesos) da rede, tal que minimize  $E(\mathbf{x}(t))$ . Desta forma, o ajuste dos pesos sinápticos  $w_i$  é proporcional à direção oposta ao gradiente  $\partial E(\mathbf{x}(t)) / \partial w_i(t)$ , sendo dado da seguinte forma:

$$w_i(t+1) = w_i(t) + \eta \left( \frac{(y_d(t) - y(t)) H^i(\mathbf{x}(t))}{\sum_{h=1}^n H^h(\mathbf{x}(t))} \right) \quad (5)$$

A equação (5) é utilizada no método do aprendizado utilizado para previsão de vazões médias mensais (9). Este método de aprendizagem capacita a rede a adquirir novos conhecimentos codificando novas regras nebulosas em sua estrutura, alterando a arquitetura da rede. Portanto o número de regras nebulosas codificadas pela rede, correspondente ao número de grupos de neurônios na segunda camada, não é constante, ou seja,  $N=N(t)$ .

A estrutura da rede é alterada basicamente devido a dois motivos: o desempenho desejado não é satisfeito pela rede ou todos os grupos neurais da segunda camada são tais que o nível de ativação é igual a zero. Nestes casos, a rede acrescenta novos elementos à sua estrutura de maneira a codificar uma nova regra nebulosa. Portanto, os grupos de neurônios da segunda camada competem entre si sempre que a rede recebe uma nova entrada  $\mathbf{x}(t)$ . O grupo vencedor guia o procedimento de ajuste dos pesos sinápticos.

A próxima seção apresenta a aplicação desta metodologia ao problema de previsão e os resultados são comparados com os resultados obtidos pelo modelo de PREVAZ.

### 5.0 PREVISÃO DE VAZÕES MENSAS

Nesta seção, são apresentados os resultados do ajuste dos modelos PREVAZ, RNA e RNN e uma análise comparativa dos erros de previsão é realizada.

Para este estudo foram utilizados dados que consistem em séries históricas de vazões naturais afluentes médias mensais que abrangem o período de 1931 a 1990, medidas em postos de medições de vazões onde existe aproveitamento hidroelétrico. Esses conjuntos de dados compõem um banco de vazões históricas mantido pela Eletrobrás. Estes dados correspondem aos postos de Furnas e Emborcação, localizados na bacia do rio Paraná e pertencentes ao sistema Sudeste brasileiro.

Os modelos foram ajustados sob o período de 1931 a 1971 e foram testados para o período de 1972 a 1976. Previsões 1, 3, 6 e 12 passos à frente foram realizadas para o período de teste, para a avaliação do desempenho das metodologias.

O sistema PREVAZ consiste em modelos de previsão de vazões médias mensais utilizados rotineiramente para a elaboração do programa mensal de operação do sistema interligado para todos os aproveitamentos considerados pelo setor elétrico brasileiro (3). O processo de seleção dos modelos de previsão é baseado na metodologia de Yevjevich - Box & Jenkins (4).

Tanto para a RNA como para a RNN o vetor de entrada  $\mathbf{x}(t)$  contém 6 componentes representadas pelos dados de vazões  $t-1$ ,  $t-2$ ,  $t-11$ ,  $t-12$ ,  $t-13$ . A escolha dessas entradas foi devido ao fato de fornecer ao modelo a tendência e informações sobre a sazonalidade da série.

Uma RNA com uma camada intermediária foi utilizada para a seleção dos parâmetros livres (peso, taxa de aprendizado) da rede foi utilizado um conjunto de arquiteturas candidatas e através da técnica de validação cruzada os parâmetros foram estimados, verificando o desempenho dos modelos sob o conjunto de validação, sendo escolhido o modelo que apresentou melhor desempenho em relação ao erro quadrático médio. Assim, o número de neurônios na camada intermediária foi

variável em relação ao mês a ser previsto, ou seja, para cada mês foi escolhido um determinado número de neurônios, variando de 3 a 5 neurônios para os dois postos.

Para a RNN, primeiramente os dados foram padronizados para o intervalo [0, 1]. Esta padronização é realizada para simplificar a entrada na rede, pois, desta forma, pode-se considerar que a primeira camada da RNN contém  $M$  grupos e cada grupo contém 1 neurônio.

O número de regras inicial foi  $N(0)=1$  para os três conjuntos de dados de vazões. Novas regras foram adicionadas a estrutura da rede sempre que o desempenho foi maior que 0,09. No final do treinamento, o número de regras foi igual a 39, 32 e 37 para os postos de Furnas, Emborcação e Sobradinho.

Para avaliar o desempenho dos modelos RNN e PREVAZ foram analisados o erro quadrático médio (EQM), erro absoluto médio (EAM), erro relativo percentual médio (EPM) e erro relativo percentual máximo ( $EP_{Max}$ ). As tabelas 1 e 2 mostram os erros obtidos para os três modelos ajustados, para o posto de Furnas e Emborcação, respectivamente, e para as previsões 1, 3, 6 e 12 passos à frente.

Tabela 1: Estatísticas para o posto de Furnas.

Modelos	Passos	EQM( $\times 10^5$ )	EAM	EPM	EP <sub>Max</sub>
PREVAZ	1	0.67	181.7	21.5	83.1
	3	0.97	231.8	30.0	190.3
	6	0.83	218.9	28.6	92.4
	12	0.87	223.9	30.2	100.5
RNA	1	0.63	187.6	21.8	63.6
	3	1.26	256.8	25.5	93.8
	6	1.06	247.0	26.9	73.9
	12	1.44	281.0	30.1	83.2
RNN	1	0.12	83.6	10.9	55.4
	3	0.42	91.7	14.6	58.8
	6	0.53	121.1	16.5	64.5
	12	0.58	124.1	18.5	66.9

Tabela 2: Estatísticas para o posto de Emborcação.

Modelos	Passos	EQM( $\times 10^4$ )	EAM	EPM	EP <sub>Max</sub>
PREVAZ	1	3.51	118.8	25.9	105.9
	3	5.73	169.9	38.4	174.9
	6	4.47	150.8	38.3	126.1
	12	5.71	143.9	30.2	100.5
RNA	1	3.49	114.9	28.5	121.9
	3	4.55	149.1	32.0	116.6
	6	4.79	149.7	33.0	116.6
	12	4.69	149.5	32.9	116.6
RNN	1	2.06	93.6	12.6	71.3
	3	1.19	87.5	14.2	78.8
	6	1.44	89.9	24.8	83.3
	12	3.65	104.1	25.6	87.3

Analisando as tabelas acima se pode notar que o modelo RNN apresentou melhor desempenho tanto para previsão 1 passo à frente como para previsão vários passos à

frente. Para a previsão 1 passo à frente o nota-se que a RNN apresenta erros 50% menores que os demais modelos.

Estes resultados indicam que o modelo RNN apresenta como uma das principais características de sua estrutura uma fácil adaptabilidade às mudanças ocorridas durante o período usado para teste.

As figuras 3 e 4 mostram os erros *EPM* para os três modelos ajustados e para os vários passos à frente, onde se pode observar a variação do erro quando o horizonte de previsão aumenta.




Figura 3: Erro Percentual Médio – Posto de Furnas.




Figura 4: Erro Percentual Médio – Posto de Emborcação.

## 6.0 CONCLUSÕES

Este trabalho apresentou uma classe de rede neural nebulosa para previsão de vazões naturais médias mensais. A estrutura do modelo utilizado é adaptativa e um algoritmo de treinamento baseado no paradigma de aprendizado competitivo foi utilizado, onde grupos de neurônios são adicionados à estrutura da rede sempre que novos conhecimentos são necessários ou quando o desempenho não for satisfatório.

Foram realizadas previsões 1, 3, 6 e 12 passos à frente para os postos de aproveitamento de Furnas e Emborcação. Os resultados da aplicação do modelo de rede neural nebulosa foram comparados com os resultados obtidos pelos modelos de redes neurais artificiais multicamadas com algoritmo *back-propagation* e o sistema PREVAZ. O desempenho dos modelos foi avaliado por diferentes estatísticas, mostrando que a rede neural nebulosa apresentou um desempenho superior em relação aos demais modelos, com erros até 50% menores.

## BIBLIOGRAFIA

- SOARES, S.. Planejamento da Operação de Sistemas Hidrotérmicos, Controle e Automação – Revista Brasileira de Automática, 1 (2), pp. 122-123, 1987.
- (2) BOX, G. E. P., JENKINS, G. M.. Time Series Analysis: Forecasting and Control, Holden Day, San Francisco, 1976.
- (3) GCOI. Grupo Coordenador da Operação Interligada. Manual do Sistema PREVAZ, Eletrobrás, 1983.
- (4) SALES, P. R. H. , VIEIRA, A. M.. Modelagem de vazões médias mensais tendo em vista a obtenção de previsão segundo a metodologia de Yevjevich/Box & Jenkins, Seminário Internacional de Hidrologia e Hidráulica, Assunção-Paraguai, 1984.
- (5) RUMELHART, D., HINTON, G., WILLIAMS, R.. Learning representations by back-propagation errors. Nature (London), vol. 323, pp. 533-536, 1986.
- (6) MAIER, H. R., DANDY, G.C.. Neural Networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. Environmental Modelling & Software, vol. 5, pp. 101-124, 2000.
- (7) LACHTERMACHER, G., FULLER, J.D.. Backpropagation in time series forecasting. Journal of Forecasting, vol. 14, no. 4, pp. 381-393, 1995.
- (8) BALLINI, R., FIGUEIREDO, M., SOARES, S., ANDRADE, M., GOMIDE, F.. A seasonal streamflow forecasting model using neurofuzzy network. Information, Uncertainty and Fusion. Kluwer Academic Publishers, B. Bouchon-Meunier, R. R. Yager e L. Zadeh, eds, pp. 257-276, 2000.
- (9) BALLINI, R.. Análise e Previsão de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais Artificiais e Redes Neurais Nebulosas. Tese de Doutorado, Faculdade de Engenharia Elétrica e de Computação, UNICAMP, 2000.
- (10) FIGUEIREDO, M., GOMIDE, F.. Fuzzy system design using neurofuzzy networks. Proc. of the 7<sup>th</sup> Information Processing and Management of Uncertainty on Knowledge – Based Systems – IPMU'96, vol.2, pp. 1416-1422, 1998.
- (11) PEDRYCZ, W., GOMIDE, F.. An Introduction to Fuzzy Sets: Analysis and Design. MIT Press, Cambridge, MA, 1998.