

Previsão de Vazões Semanais Utilizando Redes Neurais Nebulosas

Rosângela Ballini Luiz Guilherme Ferreira Guilhon e Secundino Soares Fernando Gomide

Resumo—Este artigo apresenta uma aplicação de previsão de vazões semanais 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. Uma comparação com o sistema PREVIVAZ é realizada. Este sistema vem sendo empregado pelo Operador Nacional do Sistema Elétrico (ONS) para realizar as previsões de vazões semanais. Para analisar o desempenho destas metodologias foram utilizados dados de diferentes postos de aproveitamento, localizados em diferentes regiões do Brasil. Os resultados mostram que a rede neural nebulosa apresenta um melhor desempenho que o sistema PREVIVAZ.

Index Terms—Redes Neurais Nebulosas, Previsão de Vazões Semanais, Modelos de Séries Temporais, Sistema PREVIVAZ.

I. INTRODUÇÃO

O Programa Mensal de Operação Energética do Setor Elétrico, coordenado pelo Operador Nacional do Sistema Elétrico (ONS) com o objetivo de otimizar o despacho centralizado das usinas, é realizado de forma mensal, ocorrendo também revisões semanais necessárias aos ajustes devido às variabilidades das afluições, das demandas e das indisponibilidades não previstas nos equipamentos. Para efetuar a programação mensal da operação e suas revisões é necessário realizar previsão de afluições para os reservatórios despachados centralizadamente, o qual vem sendo realizado pelo ONS, utilizando o sistema PREVIVAZ, desenvolvido pelo Centro de Pesquisas em Energia Elétrica - CEPEL [1]. Este sistema seleciona o melhor modelo dentre 94 combinações de modelos de séries temporais, com diferentes métodos de estimação de parâmetros, e começou a ser utilizado no início de 1999. Mesmo sendo um modelo de pouco tempo de utilização já se mostrou mais eficiente que seu antecessor no Setor Elétrico, o sistema PREVAZ, substituindo-o no Programa Mensal de Operação.

O modelo PREVIVAZ, assim como seu antecessor, possui um desempenho satisfatoriamente razoável no período seco que compreende os meses de maio a outubro, estando sua previsão bastante aderente aos valores verificados. Entretanto, para os meses de novembro a abril, que abrangem o período úmido, os erros verificados por esses modelos se mostraram consideravelmente maiores.

No sentido de obter previsões mais eficientes, especialmente nos períodos úmidos dos anos, foram desenvolvidos modelos de redes neurais artificiais e de redes neurais nebulosas. Redes neu-

rais artificiais, principalmente redes neurais multi-camadas com algoritmo de retro-propagação do erro [2], tornaram-se extremamente conhecidas para previsão em diversas áreas, incluindo finanças [3], carga elétrica [4] e recursos hídricos [5]. Estes modelos apresentam habilidade de aprendizado e capacidade de generalização, destacando a sua capacidade para tratar relações não-lineares de entradas-saídas.

A comparação de redes neurais com abordagens tradicionais na previsão de séries temporais ainda não é conclusiva. As explicações podem estar relacionadas a diferentes fatores, tais como a estrutura da rede neural, o tipo de série (estacionária, não-estacionária) analisada e a relação do tamanho da rede e o número de entradas das séries temporais. Além disso, 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 para treinamento [6].

As redes neurais nebulosas são sistemas capazes de processar o conhecimento de forma compreensível e de manipular incertezas visando solucionar problemas reais complexos. Estes modelos tratam as incertezas e imprecisões, geralmente presentes nos dados reais, e apresentam fácil adaptabilidade a novos dados, sem a necessidade de laboriosas formulações estatísticas. Estes modelos apresentam estas características pois, diferentemente das outras abordagens, abstraem o conhecimento físico dos sistemas a serem modelados, já que o modelo pode ser gerado a partir dos dados de entrada e saída e, ao se manter ativo o processo de geração do modelo, cria-se condições para eliminar deficiências causadas por variações dos parâmetros [7].

Este trabalho propõe a aplicação de um modelo de rede neural nebulosa com estrutura adaptativa, proposta em [8]. Este modelo apresenta um método de aprendizagem construtivo, onde regras nebulosas são adicionadas à estrutura da rede quando o desempenho não é satisfatório. Este modelo foi aplicado para previsão de vazões afluentes médias mensais e comparado com os modelos de redes neurais e modelos de séries temporais, apresentando erros significativamente menores [9], [10].

Neste trabalho, que relata a aplicação em previsão de vazões afluentes semanais, foram selecionados os aproveitamentos de Furnas, Itumbiara, Tucuruí e Foz do Areia, sendo representativos das bacias dos rios Grande, Paranaíba, Tocantins e Iguaçu. Também foi selecionado um posto relativo à vazão incremental entre Três Marias e Sobradinho, fundamental para a determinação da operação da bacia do rio São Francisco. Foram comparadas as previsões da semana 45 (primeira de novembro) do ano de 1999 até a semana 17 (última de abril) do ano 2000, isto é, da semana que vai de 30.10.1999 (sábado) à 05.11.1999 (sexta-feira), até a semana que vai de 22.04.2000 (sábado) à 28.04.2000 (sexta-feira). Para tal, o treinamento das redes neurais, bem como a alimentação do modelo PREVIVAZ, foram feitos considerando o histórico de dados até a semana anterior à

R. Ballini, Departamento de Teoria Econômica - DTE, Instituto de Economia - IE, Universidade Estadual de Campinas, Campinas, e-mail: ballini@eco.unicamp.br

L. G. F. Guilhon, Operador Nacional de Sistema de Elétrico - ONS/Hidrologia

S. Soares, Departamento de Engenharia de Sistemas, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, e-mail: dino@densis.fee.unicamp.br

F. Gomide, Departamento de Computação e Automação Industrial, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, e-mail: gomide@dca.fee.unicamp.br

previsão.

A comparação entre os modelos foi realizada com o objetivo de avaliar o desempenho das diferentes abordagens, utilizando distintas estatísticas, tais como os erros quadráticos médios, absolutos médios, relativos percentuais médios e relativos percentual máximo.

II. O SISTEMA PREVIVAZ

O modelo estocástico de previsão de vazões semanais, PREVIVAZ, foi desenvolvido entre o segundo semestre de 1994 e julho de 1996, a partir de recomendação do "I Encontro Técnico Sobre Previsões de Séries Temporais", realizado em maio de 1993, de substituição da então metodologia de previsão de vazões semanais, obtida a partir da desagregação dos valores previstos em base mensal, com a utilização do modelo PREVIVAZ.

Em julho de 1996 finalizou a versão 1.0 do programa juntamente com o relatório sobre a primeira etapa (pesquisas e escolhas das metodologias a serem desenvolvidas). Em dezembro de 1996 finalizou a versão 1.1 do programa, o manual do usuário e a segunda etapa (elaboração das vazões definitivas). A terceira etapa (testes finais de aceitação) finalizou em março de 1998.

Os modelos estatísticos de previsão de vazões foram classificados em estacionários e periódicos. Dentre os estacionários encontram-se a média anual, a média semanal, os modelos auto-regressivos, AR(p) com $1 \leq p \leq 4$ e os modelos auto-regressivos médias móveis ARMA(p,1), sendo a equação de regressão e a estrutura de correlação de uma semana com as anteriores consideradas constantes ao longo do ano, sendo porém as médias e desvios padrões considerados sazonais. A estimação dos parâmetros foi realizada pelo método dos momentos.

O modelo AR(p) possui a seguinte formulação:

$$z_t = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + a_t \quad (1)$$

sendo,

$z_t = \frac{y_t - \mu_m}{\sigma_m}$: denota a série padronizada;

y_t : série sazonal com 52 períodos, $t = (1, 2, \dots, 52) \times N$, sendo N o número de anos;

μ_m : é a média sazonal do período m ;

σ_m : é o desvio padrão sazonal do período m ;

p : ordem do modelo auto-regressivo;

a_t : : ruídos independentes de média zero e variância σ_a^2 ;

ϕ_p : coeficiente de autocorrelação de ordem p .

No modelo ARMA(p,1) somente deverá acrescentar a parcela de médias móveis ao segundo lado da Equação 1, ou seja:

$$z_t = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + \theta_1 a_{t-1} + a_t \quad (2)$$

sendo θ_1 o coeficiente média móvel de ordem 1.

Os fenômenos semanais apresentam um comportamento periódico, onde cada período apresenta características próprias definidas por sua média, seu desvio padrão e sua estrutura de correlação. Além disso, também pode ser considerada sazonalidade mensal, trimestral ou semestral.

Os modelos PARMA(p,1) são periódicos e, desta forma, a Equação (2) caracteriza-se por apresentar uma equação de regressão para cada período, sendo que para a estimação dos

parâmetros foram utilizados os métodos dos momentos, da regressão com respeito à origem de previsão e da regressão simples. Para os modelos PAR(p), com $1 \leq p \leq 4$, não foi utilizado o método de regressão simples (Equação (1)) para a estimação dos coeficientes.

A formulação destes dois modelos é semelhante àquela apresentada para os modelos AR e ARMA, sendo que se substituem os coeficientes ϕ_p por ϕ_p^m , sendo ϕ_p^m o coeficiente de autocorrelação de ordem p e período m , e também substitui-se ϕ_1 por ϕ_1^m , sendo este último o coeficiente de média móvel de ordem p e período m . O modelo PREVIVAZ modela as vazões semanais utilizando a transformação Box & Cox ou a transformação logarítmica.

Assim, resulta num modelo que possibilita a escolha dentre 94 tipos de modelos diferentes, para cada posto base (aproveitamento hidrelétrico com série histórica e significativo em sua bacia) em cada semana do ano.

O modelo PREVIVAZ separa o histórico em duas metades e processam-se três etapas distintas da previsão, sendo:

Etapas 1 - Utiliza-se a primeira parte da série para estimar os parâmetros e a segunda parte para a verificação dos erros médios quadráticos de previsão.

Etapas 2 - Estimam-se os coeficientes para a segunda metade da série e é feita a verificação para a primeira metade da série.

Etapas 3 - A partir da escolha do modelo que produz o menor erro médio quadrático, realizam-se as previsões de afluições para as 6 (seis) semanas seguintes para todos os postos base, calculando-se em seguida, as previsões para as demais usinas hidrelétricas através de equações de regressão mensais previamente estabelecidas.

A partir de maio de 2000, o ONS, passou a utilizar o mesmo modelo PREVIVAZ também para a previsão de vazões do Programa Mensal de Operação - PMO, em substituição ao modelo PREVIVAZ desagregado.

Atualmente, o modelo PREVIVAZ, calcula as previsões de vazões para 41 locais de usinas hidrelétricas básicas (postos base) e estende para outros locais de aproveitamentos hidrelétricos totalizando 84 usinas ou reservatórios com previsão semanal de vazões.

III. REDE NEURAL NEBULOSA

A estrutura da Rede Neural Nebulosa (RNN), proposta em [8], foi desenvolvida com base em duas características essenciais: o mapeamento das regras nebulosas na estrutura da rede é direto e o processamento neural deve equivaler totalmente a um mecanismo de inferência nebulosa. Essas propriedades 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 [10].

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". Seja x_j uma variável nebulosa; $j = 1, \dots, M$ o índice de entrada; A_j e A_j^i os conjuntos nebulosos no espaço de en-

trada; y uma variável real e g^i uma constante (ambos definidos no espaço de saída); e $i = 1, \dots, N$ o índice da regra nebulosa. Portanto, o sistema de inferência pode ser definido da seguinte forma:

Entrada: $x_1 \text{ é } A_1 \text{ E } \dots \text{ } x_M \text{ é } A_M$

Regras: Se $x_1 \text{ é } A_1^i \text{ E } \dots \text{ } x_M \text{ é } A_M^i$ Então $y \text{ é } g^i$

Saída: $y = g$

Define-se o grau de pertinência de x_k em A_j^i por a_{jk}^i , i.e., $A_j^i(x_k) = a_{jk}^i$, se $x_k \in I_k = (x_I, x_F]$, sendo A_j^i um conjunto nebuloso e x_k um valor do espaço de entrada. O valor da saída y é determinado através de uma seqüência de três estágios de processamento (T e S denotam as t-normas e s-normas, respectivamente) [7], [11]:

(a) *Comparação*: Para cada regra i , e para cada antecedente j , calcula-se a medida de possibilidade P_j^i entre os conjuntos nebulosos A_j e A_j^i .

$$P_j^i(\mathbf{x}) = S\{T(a_{jk}, a_{jk}^i)\} \quad (3)$$

sendo S tomado sob tod k , e $\mathbf{x} = (x_1, \dots, x_j, \dots, x_M)^T$ é o vetor de entrada.

(b) *Agregação dos antecedentes*: Para cada regra i , calcula-se o nível de ativação H^i :

$$H^i(\mathbf{x}) = T\{P_j^i(\mathbf{x})\} \quad (4)$$

(c) *Agregação das regras*: A saída do sistema de inferência é realizada através de uma média ponderada entre os conseqüentes de cada regra da base de regras, tendo como pesos os valores calculados na Equação (4):

$$y(\mathbf{x}) = \frac{\sum_{i=1}^N H^i(\mathbf{x}) g^i}{\sum_{i=1}^N H^i(\mathbf{x})} \quad (5)$$

Pode-se verificar que este sistema de inferência é isomórfico à RNN mostrada na Figura 1. Como toda rede neural, esta rede também é definida a partir da interconexão de unidades simples de processamento, conhecidas como neurônios. O modelo de um neurônio genérico é apresentado na Figura 2. Matematicamente, a saída deste neurônio pode ser representada como:

$$y(\mathbf{x}) = \varphi(\phi(\Psi(\mathbf{x}))) = \varphi(\phi(\psi_1(x_1), \dots, \psi_M(x_M)))$$

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

A primeira camada é dividida em M grupos de neurônios, cada um associado a uma variável nebulosa de entrada. Cada neurônio nesta camada representa um intervalo de discretização




Figura 1. Rede Neural Nebulosa.




Figura 2. Modelo Geral do Neurônio Fuzzy.

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 do conjunto nebuloso A_j . Assim, um neurônio de entrada 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. Nesta camada, ψ e ϕ são definidas como funções identidade e a saída $a_{jk} \in \{0, 1\}$ é dada por $a_{jk} = \varphi(x_j)$.

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 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 nebuloso correspondentes aos antecedentes da i -ésima regra. Além disso, cada neurônio da i -ésima regra calcula a comparação P_j^i entre os conjuntos nebuloso A_j e A_j^i . Assim, o k -ésimo neurônio do j -ésimo grupo da primeira camada, cuja saída é dada por a_{jk} , se conecta com o i -ésimo grupo da segunda camada através de pesos sinápticos a_{jk}^i . Considerando-se que $\psi = t$ -norma, $\phi = s$ -norma e φ é a função identidade, a saída do j -ésimo neurônio é a medida de possibilidade P_j^i dada pela Equação (3).

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 (se-

gundo estágio de inferência). Todas as conexões possuem peso sináptico unitário. A saída desta camada é dada pela Equação (4), assumindo que $\psi =$ função identidade, $\phi = t$ -norma e $\varphi =$ 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 ψ e ϕ são, respectivamente, o operador algébrico e a soma algébrica, e φ é a função identidade. As saídas são constituídas pelo numerador da Equação (5).

O outro neurônio também é conectado com todos os neurônios da camada anterior com pesos sinápticos unitários. Considerando $\psi =$ função identidade, $\phi =$ soma algébrica e $\varphi =$ função identidade, a saída equivale ao denominador da inferência nebulosa definida em (5).

Finalmente, a última camada consiste de um único neurônio para calcular o quociente dos sinais de entrada, ou seja, para calcular $y(\mathbf{x})$ (Equação (5)). Portanto, as conexões possuem pesos unitários e os operadores ψ , ϕ e φ são função 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, descritos de (3) a (5). Além disso, os pesos sinápticos representam tanto o conhecimento da rede neural como também representam as funções de pertinência dos antecedentes e conseqüentes das regras nebulosas. Assim, a RNF codifica um conjunto de N regras em sua estrutura, processa as informações através de neurocomputação, executando raciocínio nebuloso.

A. Método de Ajuste dos Parâmetros

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 fuzzy 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 à rede, o qual o t -ésimo par é dado por $(\mathbf{x}(t), y_d(t))$, sendo $\mathbf{x}(t) = (x_1(t), \dots, x_M(t))'$ o vetor de entrada com M coordenadas e $y_d(t)$ a saída desejada.

Considera-se que os conjuntos fuzzy, $A_j^i(\cdot)$, são representados por funções de pertinência do mesmo tipo, simétricas e completamente definidas pelos valores modais c_j^i e de dispersão ρ^i . Por exemplo, funções do tipo Gaussianas ou funções triangulares.

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:

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

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 à aplicação do método baseado no gradiente descendente, é definida por:

$$E(\mathbf{x}(t)) = \frac{1}{2}(y_d(t) - y(t))^2 \quad (6)$$

sendo $y(t)$ a saída da rede em relação à entrada $\mathbf{x}(t)$, dada pela Equação (5).

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

$$w_i(t+1) = w_i(t) - \eta \frac{\partial E(\mathbf{x}(t))}{\partial w_i(t)} \quad (7)$$

sendo η a taxa de aprendizagem. Derivando a equação (6) em relação a w_i , tem-se:

$$\frac{\partial E(\mathbf{x}(t))}{\partial w_i} = \frac{(y_d(t) - y(t)) H^i(\mathbf{x}(t))}{\sum_{i=1}^n H^i(\mathbf{x}(t))} \quad (8)$$

Substituindo a equação (8) na equação (7), o ajuste dos pesos sinápticos $w_i(t)$ é rescrito da seguinte forma:

$$w_i(t+1) = w_i(t) + \eta \left(\frac{(y_d(t) - y(t)) H^i(\mathbf{x}(t))}{\sum_{h=1}^n H^h(\mathbf{x}(t))} \right) \quad (9)$$

O método de aprendizagem ou algoritmo de aprendizagem capacita a RNF 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 fuzzy. Portanto, os grupos de neurônios da segunda camada competem entre si sempre que a rede recebe uma nova entrada $\mathbf{x}(t)$. O grupo do neurônio vencedor guia os procedimentos de ajuste dos pesos sinápticos. Maiores detalhes ver [9].

IV. PREVISÃO DE VAZÕES SEMANAIS

Nesta seção são analisados os resultados obtidos com a aplicação dos modelos PREVIVAZ e RNN para previsão de vazões semanais.

Para efeito de estudo de casos, foram utilizados os dados de vazões semanais de Furnas, Itumbiara, Foz do Areia, pertencentes as bacias dos rios Grande, Paranaíba, e Iguaçu, respectivamente. Também foram selecionados um posto relativo à vazão incremental entre Três Marias e Sobradinho, pertencente a bacia do rio São Francisco.

O sistema PREVIVAZ consiste no ajuste de 94 modelos com diferentes combinações de séries temporais, estrutura estacionária ou periódica, métodos de estimação de parâmetros e diferentes transformações, selecionando o melhor modelo dentre os 94 para realizar a previsão de vazões semanais.

Para a RNN, para as entradas da rede foram utilizados dados de vazões semanais anteriores para realizar as previsões. Para cada posto de aproveitamento foram selecionados diferentes números de entradas, sendo este número fixo para a previsão das semanas. O número de variáveis de entrada foi igual a 8, 8, 6, 2 para os postos de aproveitamento de Furnas, Itumbiara, Foz do Areia e incremental de Três Marias e Sobradinho, respectivamente. O ajuste dos parâmetros associados a estas variáveis é realizado através do treinamento da rede.

As funções de pertinência das regras nebulosas codificadas na estrutura da RNN utilizadas são do tipo Gaussiana. Esta função foi definida igual para o ajuste do modelo para todas as séries.

O ajuste dos parâmetros da rede, ou seja, valores modais, dispersão e pesos da rede, foram ajustados para cada semana. Assim, foram ajustados 26 modelos no final do treinamento, sendo que para cada semana e para cada posto foi ajustado um determinado número de regras na estrutura da rede. Este número de regras variou de 5 a 35 regras, sendo que, para o início do período de chuva utilizado para teste (primeira semana de novembro de 1999) o número de regras foi menor que para as demais semanas.

Para comparação dos resultados foram analisados, os erros quadráticos médio (EQM), absolutos médio (EAM), relativos percentual médios (ERM(%)), relativos percentual máximos ($ER_{max}(\%)$) e desvios padrões (DP). As Tabelas I, II, III e IV mostram os erros obtidos para os modelos PREVIVAZ e RNN e para os postos de aproveitamentos Furnas, Itumbiara, Tucuruí, Foz do Areia e a incremental Três Marias e Sobradinho, respectivamente.

TABELA I
ERROS PARA O POSTO DE FURNAS.

Modelos	PREVIVAZ	RNN
REQM(m^3/s)	$5,59 \times 10^5$	$2,92 \times 10^5$
EAM(m^3/s)	471,5	399,5
ERM(%)	40,9	37,7
$ER_{max}(\%)$	156,7	157,3
DP	146,6	106,0

TABELA II
ERROS PARA O POSTO DE ITUMBIARA.

Modelos	PREVIVAZ	RNN
REQM(m^3/s)	$8,08 \times 10^5$	$6,76 \times 10^5$
EAM(m^3/s)	671,5	628,6
ERM(%)	35,2	30,3
$ER_{max}(\%)$	130,5	75,4
DP	176,3	161,2

TABELA III
ERROS PARA O POSTO DE FOZ DO AREIA.

Modelos	PREVIVAZ	RNN
REQM(m^3/s)	$5,03 \times 10^4$	$4,46 \times 10^4$
EAM(m^3/s)	170,0	146,0
ERM(%)	44,8	36,7
$ER_{max}(\%)$	225,0	163,3
DP	44,0	41,4

Analisando as tabelas com as estatísticas, se pode observar que o modelo RNN apresentou melhor desempenho que o modelo PREVIVAZ para todos os postos considerados.

Sob a ótica do erro relativo percentual máximo, o modelo RNN somente teve um desempenho ligeiramente pior no caso de Furnas e da incremental Três Marias - Sobradinho.

Durante os estudos, pode-se observar que o modelo RNN é sensível ao número de entradas. Neste trabalho, este número foi fixado para as 26 semanas de teste, variando-se apenas o número de entradas entre os postos de aproveitamento. Observou-se, entretanto, que alterando a configuração do número de entradas ao longo das semanas a serem previstas, assim como é realizado no modelo PREVIVAZ, o desempenho do modelo pode melhorar. O estudo do melhor número de entradas para cada semana prevista deverá ser realizado em trabalhos futuros.

V. CONCLUSÕES

A metodologia que utiliza as técnicas de inteligência artificial para a previsão de séries temporais vem sendo aplicada e abordada por diversos estudos, merecendo especial destaque, pois os resultados, conforme apresentado neste trabalho, são bastante satisfatórios.

A técnica de Redes Neurais Nebulosas foi aplicada para quatro locais considerados essenciais para o Setor Elétrico e representativos de suas bacias, sendo o erro relativo percentual médio apresentado menor que aquele obtido com o uso do modelo PREVIVAZ, baseado em modelagem auto-regressiva médias móveis periódica.

As série de vazões das bacias da Região Sul do país possuem uma alta variabilidade e tempo de resposta, aliado à falta de uma sazonalidade marcadamente conhecida, o que dificulta a pre-

TABELA IV
ERROS PARA O POSTO DE SOBRADINHO.

Modelos	PREVIVAZ	RNN
REQM(m^3/s)	$5,05 \times 10^5$	$3,16 \times 10^5$
EAM(m^3/s)	531,4	376,1
ERM(%)	18,3	12,5
ER _{max} (%)	40,2	42,8
DP	139,3	110,2

visão de vazões para períodos superiores a 5 dias pelos métodos tradicionais.

AGRADECIMENTOS

Os autores agradecem à Fundação de Ampara à Pesquisa do Estado de São Paulo (FAPESP), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Financiadora de Estudos e Projetos (FINEP), pelo auxílio.

REFERÊNCIAS

- [1] C. de Pesquisas de Energia Elétrica, *Modelo de Previsão de Vazões Semanais Aplicado ao Sistema Hidroelétrico Brasileiro-PREVIVAZ*, Relatório Técnico 125/97, 1997.
- [2] D. Rumelhart, G. E. Hinton, and R. Williams, "Learning representations by back-propagating errors," *Nature (London)*, vol. 323, pp. 533–536, 1986.
- [3] A. S. Weigend, D. E. Rumelhart, and B. A. Huberman, "Generalization by weight-elimination application to forecasting," in *Advances in Neural Information Processing Systems 3*, 1991, pp. 875–882.
- [4] A. G. Bakirtzis, J. B. Theocharis, S. J. Kiartzis, and K. J. Satsios, "Short term load forecasting using fuzzy neural networks," *IEEE Transactions on Power Systems*, vol. 10, no. 3, pp. 1518–1524, August 1995.
- [5] H. R. Maier and G. C. Dandy, "Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications," *Environmental Modelling & Software*, vol. 15, pp. 101–124, January 2000.
- [6] G. Lachtermacher and J. D. Fuller, "Backpropagation in time-series forecasting," *Journal of Forecasting*, vol. 14, no. 4, pp. 381–393, January 1995.
- [7] W. Pedrycz and F. Gomide, *An Introduction to Fuzzy Sets: Analysis and Design*. Cambridge, MA: MIT Press, 1998.
- [8] M. Figueiredo and F. Gomide, "Fuzzy system design using neurofuzzy networks," vol. 2. Paris: Proceedings of the 7th International Conference of IPMU'98, 1998, pp. 1416–1422.
- [9] R. Ballini, *Análise e Previsão de Vazões Utilizando Modelos de Série Temporais, Redes Neurais e Redes Neurais Nebulosas*. FEEC-UNICAMP, Brasil: Tese de Doutorado, Setembro 2000.
- [10] M. Figueiredo, R. Ballini, S. Soares, M. Andrade, and F. Gomide, "Learning algorithms for a class of neurofuzzy network and application," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 34, no. 3, pp. 293–301, August 2004.
- [11] R. Yager and D. Filev, *Essentials of Fuzzy Modeling and Control*. New York: Wiley Interscience, 1994.