

Previsões de Curto Prazo de Vazão Afluente ao Reservatório de Furnas Utilizando Redes Neurais Artificiais

Juan Martín Bravo, Olavo Correa Pedrollo, Walter Collischonn, Adriano Rolim da Paz
Instituto de Pesquisas Hidráulicas, UFRGS

jumarbra@yahoo.com.ar, collischonn@iph.ufrgs.br, olavopedrollo@yahoo.com.br, adrianorpaz@yahoo.com.br

Cíntia Bertacchi Uvo

Dept. of Water Resources Engineering, Lund University, Suécia.
cintia.uvo@tvrl.lth.se.

Recebido: 28/02/07 – revisado: 11/04/07 – aceito: 29/02/08

RESUMO

Decisões relacionadas à operação de reservatórios são tomadas com base no conhecimento antecipado de condições atmosféricas e hidrológicas em diferentes escalas de tempo e espaço. Assim, a utilização de informações obtidas através de previsões climáticas, meteorológicas e hidrológicas subsidia o processo de tomada de decisão, podendo produzir benefícios pela redução dos danos decorrentes de cheias, pelo aumento da segurança da barragem ou pela maior eficiência na geração de energia. Redes neurais artificiais são utilizadas, neste trabalho, para estimar a vazão de afluência ao reservatório de Furnas (Minas Gerais, Brasil) com base em previsões quantitativas de chuvas do modelo regional ETA. As previsões de vazão realizadas possuem um horizonte de doze dias com intervalo diário. Uma metodologia de treinamento e validação da rede é apresentada utilizando previsões perfeitas de chuva (considerando a chuva observada como previsão) e utilizando o maior número de dados disponíveis, favorecendo a representatividade dos resultados obtidos. Os resultados obtidos com previsão perfeita de chuva e considerando a chuva prevista pelo modelo ETA são similares até o quinto dia do horizonte de previsão. A partir do sexto dia da previsão, porém, o desempenho da rede neural utilizando chuvas previstas pelo modelo ETA decai em comparação à previsão de vazão baseada em previsão perfeita de chuva. Entretanto, os resultados do modelo desenvolvido, mesmo quando utilizada a chuva prevista pelo modelo ETA, apresentam ainda melhores índices de desempenho que os obtidos com o modelo matemático atualmente utilizado operacionalmente. Os resultados aqui obtidos mostram que a consideração de previsões quantitativas de chuva pode aprimorar as previsões de curto prazo de vazão afluente ao reservatório de Furnas.

Palavras-chave: previsão de vazão, redes neurais artificiais, previsão quantitativa de chuva.

INTRODUÇÃO

Entre as obras hidráulicas que podem ser criadas para alocação da água para diferentes usos, os reservatórios têm adquirido grande relevância ao longo da história. Reservatórios são obras necessárias e indispensáveis para o controle de cheias, geração de energia, irrigação, abastecimento de cidades, navegação, etc. (Guo et al., 2004; Wurbs, 1996).

A tomada de decisões relacionadas à operação de reservatórios é fortemente dependente do conhecimento antecipado de condições atmosféricas e hidrológicas, para diferentes escalas de tempo e espaço. A utilização de previsões hidrológicas subsidia o processo de tomada de decisão, podendo produzir benefícios pela redução dos danos decorrentes de cheias, pelo aumento da segurança da

barragem e pela maior eficiência na geração de energia (Hamlet et al., 2002; Maurer e Lettenmaier, 2004; Bravo, 2006).

A previsão de vazão em um sistema hídrico consiste na estimativa do escoamento em um curso d'água, com antecedência temporal, e é uma das técnicas utilizadas para minimizar o impacto das incertezas do clima sobre o gerenciamento dos recursos hídricos (Tucci e Collischonn, 2003). Previsões auxiliam na implantação de sistemas de alerta contra cheias, permitindo uma maior antecipação do início das ações de mitigação dos possíveis danos materiais, sociais e humanos decorrentes de eventos extremos.

Tipicamente, a previsão de vazão pode ser realizada para curto ou longo prazo. A previsão de curto prazo é realizada com antecedência de horas ou alguns dias, enquanto que a previsão de longo

prazo é realizada com antecedência de alguns meses (até 9 meses) (Georgakakos e Krysztofowicz, 2001).

A previsão de vazão de curto prazo é empregada na operação em tempo real de reservatórios, com o objetivo de maximizar os benefícios decorrentes da geração de energia, navegação, irrigação e abastecimento de água. Ainda pode ser útil para minimizar os conflitos entre os diferentes usos da água nos reservatórios (Bravo, 2006). Atualmente, o cálculo das previsões de vazões afluentes aos reservatórios de grande porte do Sistema Interligado Nacional (SIN - sistema de produção e transmissão de energia elétrica do Brasil) é realizado com base apenas nas vazões, através de modelos estatísticos como os modelos PAR (*Periodic Auto-Regressive*) e ARMA (*Auto-Regressive Moving Average*) (Maceira e Damazio, 2005; Guilhon, 2002). A inclusão de previsões de precipitação num modelo de previsão hidrológica pode permitir estender o horizonte da previsão para além do tempo de concentração da bacia e melhorar a qualidade da previsão dentro de horizontes determinados. Isso pode trazer benefícios na operação de um reservatório, como foi apresentado em Collischonn et al. (2006), Bravo (2006) e Bravo et al. (2005), e ainda do SIN como um todo.

Entre os diferentes modelos matemáticos que têm sido desenvolvidos para realizar previsões de vazão, as redes neurais artificiais (RNAs) se apresentam como um dos modelos empíricos mais utilizados (Dawson e Wilby, 2001; Maier e Dandy, 2000). A aplicação de RNAs na área de recursos hídricos tem apresentado um notável incremento na última década. Trabalhos como os de Maier e Dandy (2000); Dawson e Wilby (2001); ASCE (2000a); ASCE (2000b) apresentam os conceitos básicos para a aplicação destes modelos na área de recursos hídricos, com ênfase na sua utilização para prever variáveis hidrológicas como a vazão dos rios.

O objetivo do presente trabalho é avaliar a aplicabilidade das RNAs para realizar previsões de curto prazo de vazão afluente ao reservatório de Furnas (Minas Gerais, Brasil) fazendo uso de previsões quantitativas de chuva. O desempenho das RNAs é avaliado com base em diferentes critérios, inclusive comparando-o com o modelo atualmente utilizado pelo Operador Nacional do Sistema Elétrico (ONS) para prever a vazão afluente a esse reservatório.

REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais são modelos matemáticos que procuram imitar o funcionamento do cérebro humano e que têm mostrado um bom de-

sempenho como ferramenta de regressão, especialmente devido a sua capacidade de aprendizado e generalização (Bishop, 1995; Maier e Dandy, 2000). A unidade de processamento das RNAs é o neurônio matemático, sendo seu funcionamento definido pela equação 1:

$$S = F\left(\sum_{i=1}^n w_i \cdot E_i + b\right) \quad (1)$$

onde S é o valor da resposta do neurônio; F é a função de ativação; w_i são os pesos sinápticos; E_i são os valores das entradas que são processadas no neurônio; b é a tendência ou *bias* do valor de saída.

Observa-se na equação 1 que a resposta ou saída de um neurônio é calculada através de uma função de ativação cujo valor é definido com base numa soma ponderada das entradas ao neurônio.

As RNAs são compostas por um determinado número de neurônios dispostos em camadas de processamento. Dentro das diferentes arquiteturas de RNAs, a rede neural *feedforward* de múltiplas camadas (RNFMC) tem sido comumente utilizada (Birikundavy et al., 2002; Dawson et al., 2002; Stokelj et al., 2002; Dawson e Wilby, 2001). Uma RNFMC (Figura 1) é composta por uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. Os dados que alimentam a rede ingressam através da camada de entrada e são posteriormente processados através das diferentes camadas intermediárias, produzindo ao final um resultado apresentado na camada de saída.




Figura 1 - Esquema de rede neural artificial *feedforward* de três camadas.

As RNFMCs se caracterizam por apresentar, unicamente, conexões entre neurônios de camadas

subseqüentes. Tais conexões são representadas pelos pesos (ponderadores) que, juntamente com os *bias* de cada neurônio, representam os parâmetros da RNFMFC a serem definidos através de um processo de otimização conhecido como treinamento.

No treinamento os valores dos pesos e *bias* são ajustados com o objetivo de minimizar alguma medida de desempenho baseada nos erros entre a saída da rede e o valor observado.

Além das RNFMFC, outras RNAs têm sido utilizadas na previsão de variáveis hidrológicas, entre elas: redes neurais nebulosas (por exemplo, Alvim et al., 2005, Cicogna et al, 2003) e redes recorrentes de Elman (por exemplo, Rohn et al., 2006). Apesar das diferenças nas estruturas e funcionamento das diversas RNAs utilizadas na previsão de variáveis hidrológicas, uma característica comum são as variáveis tomadas como entrada. Tipicamente, modelos baseados em RNAs têm definido previsões de vazão a partir de valores prévios da vazão no próprio posto (por exemplo, Cicogna et al., 2003) e nos postos de montante (por exemplo, Sarmento, 1996; Imrie et al., 2000). Nas previsões de curto prazo, informações quantitativas de chuva nos intervalos prévios e futuros são também variáveis de entrada a serem consideradas, como apresentado nos trabalhos de Rohn et al (2006); Coulibaly et al. (2000); Thirumalaiah e Deo (2000), Zealand et al., (1999); Stokelj et al., (2002).

ESTUDO DE CASO E DADOS DISPONÍVEIS

O reservatório de Furnas foi selecionado como estudo de caso devido, principalmente, à disponibilidade de previsões quantitativas de chuva para a região, desenvolvidas no âmbito do projeto FAURGS-FINEP 40.04.0094.00 (IPH, 2005), e pela importância desse reservatório na região analisada e no SIN.

O reservatório de Furnas localiza-se na bacia do Rio Grande, em Minas Gerais, Brasil. A bacia afluente ao reservatório de Furnas compreende uma área de 51.900 km², equivalente praticamente à terceira parte da área da bacia do Rio Grande (Figura 2). A bacia do Rio Grande tem grande importância no contexto da geração hidroelétrica brasileira, com uma capacidade instalada de 7.722MW, representando 11,7% da capacidade instalada do país (ANEEL, 2005). Destacam-se na bacia as usinas hidroelétricas de Marimbondo, Água Vermelha, Es-

treito e Furnas, cada uma com uma potência instalada superior a 1.000 MW.

A vazão do Rio Grande afluente a Furnas tem uma forte variação sazonal, como resultado do inverno seco e do verão chuvoso. A vazão afluente varia entre valores próximos a 350 m³.s⁻¹, no período de estiagem, e valores tipicamente superiores a 2000 m³.s⁻¹ no período de verão, com algumas cheias superiores a 4000 m³.s⁻¹.

Na Figura 2 apresenta-se a bacia afluente ao reservatório de Furnas, cujos dados são utilizados neste trabalho. Essa bacia é integrada por cinco sub-bacias: Ibituruna, Camargos, Porto dos Buenos, Caruaçu e incremental de Furnas. Os círculos pretos identificam os postos fluviométricos ou usinas localizadas nos exutórios das sub-bacias. No caso das usinas, os dados de vazão se referem à vazão natural reconstituída fornecida pelo próprio ONS.

Previsões de curto prazo de vazão afluente a esse reservatório são definidas semanalmente pelo ONS. O modelo atualmente usado para definir essas previsões de vazão não utiliza as previsões de chuva disponíveis.

As previsões quantitativas de chuvas utilizadas no presente trabalho foram geradas pelo modelo regional ETA rodado operacionalmente pelo CPTEC (Chou, 1996; IPH, 2005). As previsões disponibilizadas possuem um horizonte de dez dias, uma frequência de sete dias (começam sempre às quartas-feiras), um intervalo de tempo diário e se estendem de janeiro de 1996 até dezembro de 2000. Os dados utilizados no presente trabalho são: (1) vazões diárias em Furnas e nos exutórios das sub-bacias de montante (Ibituruna, Camargos, Porto dos Buenos e Caruaçu); (2) precipitação diária média observada sobre a área de cada sub-bacia; (3) precipitação diária média prevista pelo modelo ETA sobre cada sub-bacia.

METODOLOGIA

Nesse trabalho são estimadas previsões de vazão afluente ao reservatório de Furnas. Estas previsões possuem horizonte de doze dias com intervalo diário de previsão. Na nomenclatura utilizada, *t* representa o dia no qual é realizada a previsão, *t+1* é o primeiro dia da previsão e *t+12* o último dia da previsão.

Foram desenvolvidos doze modelos usando RNAs. Cada modelo realiza a previsão de vazão afluente ao reservatório de Furnas para um dia do hori-

zonte de previsão. Dessa forma, a camada de saída

de cada modelo possui um único neurônio.




Figura 2 - Localização da área de estudo.

Definida a variável de saída do modelo, as etapas subsequentes para o desenvolvimento dos modelos de RNAs podem ser resumidas em (Dawson e Wilby, 2001): (1) identificação das variáveis de entrada; (2) escolha do tipo de RNA; (3) divisão e pré-processamento dos dados; (4) treinamento da RNA; (5) verificação do desempenho da RNA. Essas etapas são descritas a seguir.

Variáveis de entrada

As previsões de vazão dependem de diferentes fatores, como características da bacia, precipitação, temperatura, condições antecedentes, etc. Em consequência, existe um grande número de variáveis de entrada possíveis à rede neural. Dessa forma, a escolha das variáveis de entrada requer um estudo detalhado das condições físicas e meteorológicas que mais influenciam a geração de vazão naquela bacia.

Maier e Dandy (1997) mostraram que a escolha das variáveis de entrada com base em análises estatísticas (correlação múltipla) pode melhorar o desempenho das RNAs em alguns casos.

Bowden et al. (2005) sugerem que a escolha das variáveis de entrada seja feita a partir de um sistema que combine *Partial Mutual Information* com *Self Organizing Map*, permitindo serem detectadas ainda relações não lineares entre as variáveis. Outras metodologias utilizadas para definir as variáveis de entrada a modelos de RNA incluem a análise de componentes principais e de espectro singular (Stokelj et al., 2002). Ainda, na definição das variáveis de entrada é importante compreender as características físicas da bacia e do processo hidrológico analisado (Dawson et al., 2002).

Tendo em mente o processo físico representado e os dados disponíveis, pode-se assumir que é fundamental alimentar a rede com três tipos de informação: precipitação na bacia contribuinte; vazão nos exutórios das sub-bacias contribuintes e vazão no local de previsão. Neste trabalho, a definição das variáveis de entrada à rede foi realizada com base em análises de correlação entre os dados disponíveis e a saída da rede (vazão afluente ao reservatório de Furnas) no período de 01/01/1970 a 31/12/1980. Optou-se por uma metodologia simples, que conseguisse identificar as variáveis mais influentes sem necessidade de cálculos ou técnicas complexas.

Quanto à informação da precipitação na área de contribuição, inicialmente as precipitações médias diárias de cada sub-bacia (Ibituruna, Portos dos Buenos, Camargo, Caruaçu e Incremental de Furnas) e da bacia total a montante de Furnas foram correlacionadas com a vazão afluente ao reservatório de Furnas considerando defasagens de um a doze dias (Figura 3). Maior correlação foi obtida para a variável precipitação média sobre a bacia total contribuinte a Furnas, embora relativamente baixa ($< 0,60$).

Na tentativa de obter variáveis baseadas nos dados de precipitação com maior grau de correlação com a vazão em Furnas, foram geradas séries de precipitação acumulada em diferentes períodos de tempo a partir das precipitações médias diárias sobre a bacia total contribuinte a Furnas. Isto é, foram criadas novas séries de precipitação acumulada de dois dias (por exemplo, dos dias t e $t-1$), de três dias (por exemplo, dos dias t , $t-1$ e $t-2$), e assim por diante. Posteriormente, essas variáveis foram correlacionadas com a vazão afluente ao reservatório de Fur-

nas com defasagem de um dia (vazão observada em t+1). Os resultados são apresentados na Figura 4.




Figura 3 - Coeficiente de correlação entre diferentes variáveis (precipitação média diária nas sub-bacias de montante e na bacia de montante de Furnas) e a vazão afluente ao reservatório de Furnas com defasagens de um a doze dias.

Como ilustrado na Figura 4, a correlação entre a precipitação média (na bacia) diária acumulada e a vazão afluente ao reservatório de Furnas em t+1 aumenta com o aumento do período de acumulação. Essa tendência se mantém até um período de acumulação de doze dias anteriores ao instante t+1, quando atinge um valor máximo de correlação de 0,82, diminuindo a seguir gradativamente. Dessa forma, a precipitação média (na bacia) diária acumulada de doze dias (Pma12(t)) foi adotada como variável de entrada à RNA.




Figura 4 - Coeficiente de correlação entre diferentes variáveis (precipitação média diária, na bacia, acumulada em diferentes períodos de tempo) e a vazão afluente ao reservatório de Furnas com defasagem de um dia.

Essa variável de entrada tem valores diferentes, conforme o intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão. Por exemplo, quando é feita a previsão para o dia t+1 são considerados os valores de precipitação média (na bacia) diária acumulada entre os dias t-11 e t. Nesse caso são utilizados somente valores observados de precipitação. Entretanto, no caso da previsão feita para o dia t+2, por exemplo, são considerados os valores de precipitação média (na bacia) diária acumulada entre os dias t-10 e t+1. Nesse caso são utilizados valores de precipitação observada entre os dias t-10 e t e o valor de precipitação prevista no dia t+1. A Figura 5 ilustra como a variável Pma12(t) é definida conforme o intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão. Como a previsão de chuva disponível do modelo ETA possui um horizonte de dez dias (até t+10), foi considerada nula a previsão de chuva referente ao dia t+11 ao realizar a previsão de vazão para t+12 (Figura 5).

Na análise das informações referentes às vazões em sub-bacias contribuintes a Furnas, foram correlacionadas as vazões diárias nos exutórios de cada uma (Ibituruna, Portos dos Buenos, Camargo e Caruaçu) e a média delas com a vazão afluente ao reservatório de Furnas, considerando defasagens de um a doze dias. Maiores valores de correlação com a vazão em Furnas foram obtidos tomando o valor médio diário das quatro vazões de montante (QM4(t)), como ilustra a Figura 6. Tal variável e o seu valor incremental ($\Delta QM4(t) = QM4(t) - QM4(t-1)$) foram adotados como variáveis de entrada para a RNA representando as informações das vazões de contribuição de montante. A inclusão da vazão incremental $\Delta QM4(t)$ como variável de entrada à RNA tem o objetivo de facilitar a distinção entre períodos de subida e descida do hidrograma (cheia ou recessão).

Por fim, quanto à informação de vazão no próprio local de previsão (Furnas), foram adotadas duas variáveis para entrada à rede: a vazão afluente a Furnas no período t (QF(t)); e o valor incremental $\Delta QF(t) = QF(t) - QF(t-1)$, também com o intuito de facilitar a distinção entre subida e descida do hidrograma pela rede.

Os modelos de RNAs desenvolvidos neste trabalho para prever a vazão em Furnas são alimentados, portanto, com cinco variáveis de entrada. Quatro dessas variáveis são definidas com base nos dados de vazão: média diária das vazões nos exutórios das sub-bacias de montante no dia t (QM4(t)) e seu valor incremental entre os dias t-1 e t.



Figura 5 - Cálculo da variável precipitação média na bacia diária acumulada (Pma12(t)) em função do intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão (o primeiro dia da previsão é t+1).

($\Delta QM4(t)$); vazão em Furnas no dia t ($QF(t)$) e o valor incremental entre os dias t-1 e t ($\Delta QF(t)$). Os valores dessas variáveis são os mesmos para uma previsão que inicia no dia t, independentemente do intervalo de tempo dentro do horizonte de previsão. A quinta variável de entrada é definida com base nos valores de precipitação média diária (na bacia) acumulada de doze dias ($Pma12(t)$) e apresenta valores diferentes conforme o intervalo de tempo dentro do horizonte de previsão para o qual está sendo efetuada a previsão de vazão.




Figura 6 - Coeficiente de correlação entre diferentes variáveis de entrada (vazão nos exutórios das sub-bacias de montante e valor médio diário QM4(t)) e a vazão afluente ao reservatório de Furnas com defasagens de um a doze dias.

Escolha do tipo de rede neural

São propostos doze modelos de redes neurais artificiais. Cada modelo realiza a previsão de vazão afluente ao reservatório de Furnas para um dia do horizonte de previsão. As RNFMCs com três camadas (uma de entrada, uma intermediária e uma camada de saída) foram utilizadas nesse trabalho.

Cada uma das RNFMC desenvolvidas possui cinco neurônios na camada de entrada (cada neurônio corresponde a uma variável de entrada) e um único neurônio (correspondente ao valor previsto de vazão num dia do horizonte de previsão) na camada de saída.

O número de neurônios da camada intermediária da RNFMC é determinado independentemente para cada modelo desenvolvido.

As funções de ativação utilizadas são, respectivamente, a log-sigmoide unipolar (com variação entre zero e um), para a camada intermediária, e a linear, para a camada de saída. As equações dessas funções são apresentadas a seguir:

$$\text{log sig}(n) = \frac{1}{1 + e^{-n}} \tag{2}$$

$$\text{linear}(n) = n \tag{3}$$

Divisão e pré-processamento dos dados

Definidas as variáveis de entrada e o tipo de RNA, é feita a divisão dos dados em três conjuntos: treinamento, validação e verificação. Essa divisão dos dados é necessária para a utilização da validação cruzada como critério de parada, durante o treinamento das redes neurais. Na validação cruzada, os valores dos pesos são ajustados com base no conjunto de treinamento e o processo de treinamento é parado apenas quando o erro no conjunto de validação encontra um valor mínimo. Entretanto, o conjunto de verificação não é utilizado no treinamento da rede.

As previsões de precipitação do modelo ETA disponíveis para esse trabalho totalizam cerca de 260 semanas. Isto significa que, se fossem utilizados somente esses dados, existiriam apenas 260 pa-

res de dados (dados de entrada e saída) para serem divididos entre os três conjuntos citados. Isto definiria um número relativamente reduzido de pares de dados nos diferentes conjuntos, o que poderia provocar a falta de representatividade dos resultados obtidos.

Com o objetivo de superar esse problema, nesse trabalho é proposta uma metodologia alternativa que é a de se treinar a RNA utilizando previsões perfeitas de chuvas. Isto é, utilizam-se as chuvas observadas como previsão de chuva durante a etapa de treinamento e validação da rede e as previsões reais de chuva na etapa de verificação. Para o caso em estudo, tal escolha permite que sejam utilizados conjuntos de dados para treinamento e validação com números muito superiores de pares de dados, já que as séries de dados observados para essa bacia são longas. Além disso, o treinamento da RNA não fica prejudicado pelas diversas versões e variações do modelo regional ao longo do tempo, um problema muito freqüente no treinamento ou calibração de modelos hidrológicos a partir de dados de modelos meteorológicos (Jónsdóttir e Uvo, 2007).

A divisão dos dados para treinamento e validação foi feita de forma a obter conjuntos com média (μ) e desvio padrão (σ) similares nas diferentes variáveis de entrada (Tabela 1).

Tabela 1 - Estatísticas das cinco variáveis de entrada nos conjuntos de treinamento e de validação.

Variáveis	Treinamento		Validação	
	μ	σ	μ	σ
Pm12(t)	47,93	42,52	43,73	42,35
QF(t)	886,53	595,29	859,46	546,87
QF(t)	0,42	98,98	-0,129	90,74
QM4(t)	127,63	80,00	123,76	71,24
QM4(t)	0,079	17,10	-0,007	14,68

Dessa forma, o período da série histórica 1970-1980 foi dividido em dois conjuntos: treinamento e validação. O conjunto de treinamento é composto de dados dos períodos 12/01/1970 a 17/07/1974 e 13/10/1978 a 31/12/1980, totalizando 2.461 pares de dados (freqüência diária). O conjunto de validação se estende de 18/07/1974 a 12/10/1978, totalizando 1.548 pares de dados (freqüência diária). Todos esses períodos são de chuva prevista perfeita (chuva observada tomada como previsão).

Para avaliar o desempenho da rede são utilizados dois conjuntos de verificação, sendo ambos

compostos de dados de 12/01/1996 a 31/12/2000, totalizando 260 pares de dados (freqüência semanal). No primeiro conjunto de verificação, as previsões de precipitação correspondem às obtidas pelo modelo ETA e no segundo conjunto de verificação são utilizadas previsões perfeitas de chuvas.

Posteriormente, o pré-processamento das variáveis de entrada e saída da rede é feito segundo Maier e Dandy (2000). Os valores das variáveis são padronizados utilizando-se a equação 4:

$$x_{\text{nov}} = 0,1 + \left(\frac{x_{\text{orig}} - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \right) \times 0,8 \quad (4)$$

onde x_{nov} é o valor da variável padronizada no intervalo $[0,10 ; 0,90]$; x_{orig} é o valor original da variável na sua respectiva unidade; x_{min} é o valor mínimo da variável original (considerando os conjuntos de treinamento e validação) na sua respectiva unidade; x_{max} é o valor máximo da variável original na sua respectiva unidade.

Esse processo é repetido em todas as variáveis previamente à sua utilização.

Treinamento da rede neural

As RNFMCs são treinadas neste trabalho com o *scaled conjugate gradient method* (SCGM) (Moller, 1993). Trata-se de um método de treinamento supervisionado que pertence à família dos métodos dos gradientes conjugados. O SCGM é um método iterativo de busca local que considera as derivadas de segunda ordem das funções de ativação durante o treinamento (Moller, 1993; Maier e Dandy, 2000). Com base no valor dessas derivadas é definida a direção de busca no processo de otimização dos valores dos pesos e *bias* da RNFMC.

A função utilizada para avaliar o desempenho da rede neural no treinamento é o erro padrão de previsão (apresentada na equação 5, com N igual ao número de valores no conjunto de treinamento).

Por sua vez, a validação cruzada é utilizada como critério de parada do treinamento. Através dessa técnica é evitado o super-ajustamento ao utilizar o conjunto de validação em paralelo ao processo de treinamento (Tchaban et al., 1998; Maier e Dandy, 2000). O super-ajustamento acontece quando um modelo de rede neural reproduz ruídos existentes nos dados de treinamento, perdendo sua capacidade de generalização quando utilizados outros valores de entrada. Com o procedimento de validação cruzada, os valores dos pesos são ajustados com base no erro (a cada ciclo) no conjunto de

treinamento, e o processo de treinamento é parado apenas quando o erro no conjunto de validação é mínimo. É importante ressaltar que o conjunto de verificação não é utilizado em nenhum momento do processo de treinamento da rede, embora seja importante, posteriormente, para avaliar o desempenho do modelo.

Um processo de tentativa e erro é utilizado, neste trabalho, para definir o número de neurônios da camada intermediária. Inicia-se o procedimento com um número considerado grande de neurônios (10), sendo retirado, sucessivamente, um neurônio a cada treinamento e avaliação de desempenho, até a obtenção de uma configuração com desempenho ainda satisfatório, com menor número de neurônios na camada intermediária.

Desse processo resultou que as RNFMCs para os primeiros sete dias do horizonte de previsão possuem dois neurônios na camada intermediária, isto é, RNFMCs(5-2-1) e as RNFMCs para os dias 8 a 12 do horizonte de previsão possuem três neurônios na camada intermediária, isto é, RNFMCs(5-3-1).

Neste trabalho os modelos de RNAs foram projetados e treinados utilizando o *Neural Network Toolbox* (Demuth et al., 2006) do software MATLAB. No treinamento das RNFMCs(5-2-1) foram necessários em torno de 1300 ciclos. Entretanto, 1800 ciclos, na média, foram necessários no treinamento das RNFMCs(5-3-1).

MEDIDAS DE DESEMPENHO

As medidas de desempenho utilizadas na avaliação dos resultados são: (1) Erro padrão de previsão (EP); (2) Erro médio absoluto (EMA); (3) Erro médio relativo (EMR); (4) Coeficiente de Nash-Sutcliffe (CE), sendo apresentadas a seguir:

$$EP = \left[\frac{1}{N} \sum_{i=1}^N (Qp_i - Qo_i)^2 \right]^{1/2} \quad (5)$$

$$EMA = \frac{1}{N} \sum_{i=1}^N |Qp_i - Qo_i| \quad (6)$$

$$EMR = \frac{1}{N} \sum_{i=1}^N \left| \frac{Qp_i - Qo_i}{Qo_i} \right| \quad (7)$$

$$CE = 1 - \frac{\sum_{i=1}^N (Qo_i - Qp_i)^2}{\sum_{i=1}^N (Qo_i - \overline{Qo})^2} \quad (8)$$

onde Qp_i é o valor previsto; Qo_i é o valor observado; \overline{Qo} é o valor médio dos valores observados no período de verificação; N é o número de valores no conjunto de verificação.

Ainda são calculadas duas medidas de desempenho alternativas: (1) erro médio relativo da previsão no quarto dia da previsão (EMR4) e (2) erro médio relativo da média dos valores previstos, entre o quarto e décimo dia do horizonte de previsão (EMR4-10). Essas medidas de desempenho são tradicionalmente utilizadas pelos operadores dos reservatórios no Brasil para avaliar o desempenho de diferentes modelos de previsão.

RESULTADOS E DISCUSSÃO

Os resultados obtidos na previsão de vazão afluente ao reservatório de Furnas com um horizonte de doze dias, no período de verificação (01/1996–12/2000), são apresentados na Figura 7. É considerada tanto a previsão de chuva obtida pelo modelo ETA como a previsão perfeita de chuva (chuva observada).

Observa-se que o erro nas previsões de vazão afluente ao reservatório de Furnas tende a aumentar conforme aumenta o horizonte de previsão. Entretanto, esse erro na previsão de vazão aumenta em maior medida quando utilizadas as previsões do modelo ETA se comparado aos erros obtidos considerando chuva prevista perfeita (chuva observada como previsão). Isso mostra como os erros na previsão de vazão e deixa em evidência o quanto a previsão de vazão afluente ao reservatório de Furnas poderia ser beneficiada com o aprimoramento das previsões de chuva.

Ainda pode-se destacar que os resultados obtidos com previsão perfeita de chuva e considerando a chuva do modelo ETA são similares até o quinto dia do horizonte de previsão. A partir do sexto dia da previsão de vazão, o desempenho da rede neural utilizando previsões quantitativas de chuva do modelo ETA diminui, em comparação a se considerar previsão perfeita de chuva.

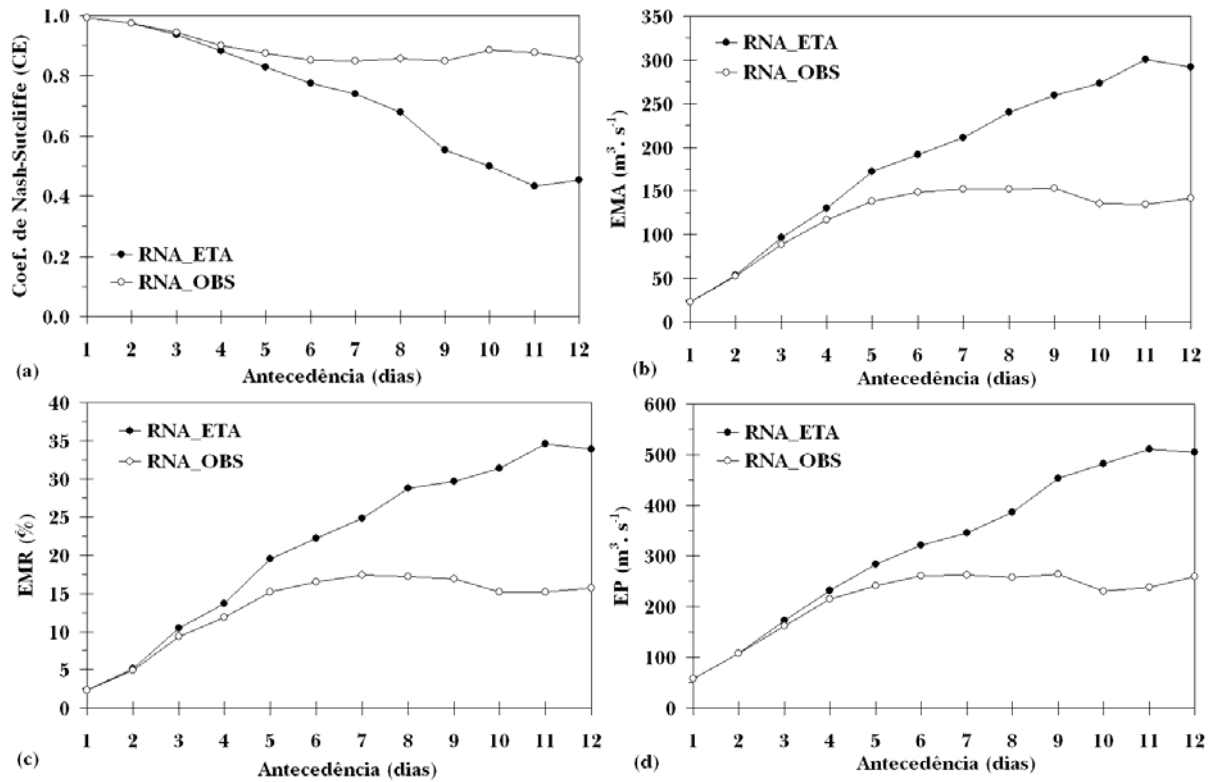


Figura 7 - Valores das medidas de desempenho para os diferentes dias do horizonte de previsão (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)): a) Coeficiente de Nash-Sutcliffe (CE); b) Erro médio absoluto (EMA); c) Erro médio relativo (EMR); d) Erro padrão de previsão (EP).




Figura 8 - Previsões contínuas de vazão afluente ao reservatório de Furnas com horizonte de doze dias (círculos pretos, chuva prevista ETA; círculos brancos, chuva prevista perfeita (chuva observada)) no período 30/10/1996 a 04/12/1996.

A seqüência de gráficos ilustrados na Figura 8 apresenta as previsões contínuas de vazão, realizadas semanalmente, durante o período 30/10/1996 a 4/12/1996, utilizando previsões de chuva do modelo ETA e previsões perfeitas de chuva (chuva observada). Observa-se que as previsões de vazão apresentam bons resultados em termos gerais no período analisado. Para os primeiros dias do horizonte de previsão os resultados são similares utilizando chuva prevista pelo modelo ETA ou previsão perfeita de chuva. Entretanto, conforme aumenta o intervalo de tempo dentro do horizonte de previsão, o desempenho do modelo que utiliza as previsões de chuva do modelo ETA diminui, subestimando as vazões previstas devido a subestimativas na previsão de chuva.

Estimativas do desempenho do modelo atualmente utilizado pelo ONS, que não utiliza previsão de chuva, nas previsões de curto prazo de vazão afluente ao reservatório de Furnas foram disponibilizadas por Guilhon (2007). Valores de EMR4 e EMR4-10 em torno de 22% e 28%, respectivamente, são obtidos empregando a metodologia atual. Os valores dessas estimativas representam valores típicos de desempenho desse modelo na área de estudo

Os valores das medidas de desempenho obtidos com a rede neural desenvolvida no presente trabalho se apresentam melhores, em todos os casos, que os obtidos pelo modelo atualmente utilizado pelo ONS no período analisado. Considerando o uso de chuva prevista pelo modelo ETA como entrada, o EMR4 diminui de 22% para 13,7% e o EMR4-10 diminui de 28% para 22%.

Melhores resultados são obtidos quando utilizada a previsão perfeita de chuva (chuva observada), com valores de EMR4 e EMR4-10 iguais a 11,9% e 13,8%, respectivamente.

Embora a previsão perfeita de chuva seja hipotética (não possui erros), seu uso indica os patamares dos benefícios que poderiam ser obtidos com o aprimoramento das previsões de chuva. A diminuição do EMR4 foi similar utilizando previsão de chuva do modelo ETA e previsão perfeita de chuva. Entretanto, a redução do EMR4-10 quando utilizada a previsão perfeita de chuva pode ser considerada importante, com um valor superior a 50% (de 28% para 13,8%).

CONCLUSÕES

Redes neurais artificiais foram utilizadas no presente trabalho para realizar previsões de vazão diária afluente ao reservatório de Furnas, com hori-

zonte de doze dias, a partir de previsões de chuva. Para tanto, foram desenvolvidos doze modelos de redes neurais artificiais onde cada modelo define a previsão de vazão no posto de Furnas para um dia do horizonte de previsão.

Uma metodologia de treinamento e validação da rede foi desenvolvida utilizando-se previsões perfeitas de chuva (considerando a chuva observada como previsão), o que permitiu utilizar um maior número de dados no treinamento.

Dois conjuntos de verificação foram utilizados, o primeiro com chuva prevista pelo modelo ETA e o segundo com previsão perfeita de chuva (chuva observada). Embora essa última previsão seja hipotética, permite conhecer os patamares superiores dos benefícios (avaliados em termos de redução dos erros na previsão de vazão) que poderiam ser obtidos.

Os resultados obtidos mostraram que o erro nas previsões de vazão afluente ao reservatório de Furnas tende a aumentar com o horizonte da previsão e que o erro na previsão de vazão aumenta em maior medida quando utilizadas as previsões do modelo ETA se comparadas às obtidas com uso de chuva prevista perfeita. Isto mostra como os erros na previsão de chuva influenciam os resultados obtidos na previsão de vazão e deixa em evidência quanto poderia ser beneficiada a previsão de vazão afluente ao reservatório de Furnas pelo aprimoramento das previsões de chuva.

Deve-se destacar que os resultados obtidos com previsão perfeita de chuva e considerando a chuva do modelo ETA são similares até o quinto dia do horizonte de previsão. A partir do sexto dia da previsão o desempenho da rede neural utilizando chuva do modelo ETA diminui em comparação ao desempenho quando se faz uso de previsão perfeita de chuva. Entretanto, os resultados do modelo desenvolvido, mesmo quando utilizada a chuva prevista pelo modelo ETA, apresentam ainda melhores índices de desempenho que os obtidos com o modelo matemático atualmente utilizado pelo ONS, para realizar previsões de vazão afluente a esse reservatório. Os resultados aqui obtidos mostram que a consideração de previsões de chuva pode aprimorar consideravelmente as previsões de curto prazo de vazão afluente ao reservatório de Furnas.

AGRADECIMENTOS

Agrademos ao CNPQ pela bolsa de estudo de doutorado de dois dos co-autores e ao Projeto

FAURGS-FINEP 40.04.0094.00 pela disponibilidade dos dados utilizados nesse trabalho. Cíntia agradece o suporte da *Swedish International Development Cooperation Agency* e da *Swedish Foundation for International Cooperation in Research and Higher Education*.

REFERÊNCIAS

- ALVIM, A.C.; MARTINEZ, C.B.; SILVA, S.R.; CAMINHAS, W.M.; VERSIANI, B.R.; QUINTÃO, C.M.F. 2005. Utilização de redes neo-fuzzy-neuron para predição de vazões. *Revista Brasileira de Recursos hídricos*, v10, n1, p. 61-77.
- ANEEL, Agência Nacional de Energia Elétrica. 2005. Atlas de energia elétrica do Brasil, edn 2, Brasília.
- ASCE (Task Committee on Application of Artificial Neural Networks in Hydrology). 2000. Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, v. 5, n. 2, p. 115-123.
- ASCE (Task Committee on Application of Artificial Neural Networks in Hydrology). 2000. Artificial neural networks in hydrology. II: Hydrologic applications. *Journal of Hydrologic Engineering*, Vol. 5, No. 2, p. 124-137.
- BIRIKUNDAVYI, S.; LABIB, R.; TRUNG, H.T.; ROUSSELLE, J. 2002. Performance of neural networks in daily streamflow forecasting. *J. of Hydrol. Eng.*, v 7, n 5, p 392-398.
- BISHOP, C.M. 1995. *Neural networks for pattern recognition*, Clarendon Press, Oxford, Inglaterra.
- BOWDEN, G.J.; DANDY, G.C.; MAIER, H.R. 2005. Input determination for neural network models in water resources applications. Part 1 – background and methodology. *J. Hydrol.*, v 301, p 75–92.
- BRAVO, J.M. 2006. Otimização da operação de um reservatório para controle de cheias com base na previsão de vazão. 136 p. Dissertação, IPH-UFRGS. Porto Alegre.
- BRAVO, J.M.; COLLISCHONN, W.; PILAR, J.V.; SILVA, B.C.; TUCCI, C.E.M. 2005. Operação de um reservatório com múltiplos usos com base na previsão de curto prazo de vazão. *Revista Brasileira de Energia*, v 11, p 85-110.
- CHOU, S. 1996. O modelo regional ETA. *Climanálise. Edição Especial*. INPE.
- CICOGNA, M.; KADOWAKI, M.; BALLINI, R.; SOARES, S. 2003. Previsão de Vazões Médias Mensais: Uma Aplicação para as Usinas do Rio Paranapanema. *Anais do II CITENEL (Hidrologia)*, p. 440-444.
- COLLISCHONN, W.; BRAVO, J.M.; SILVA, B.C.; TUCCI, C.E.M. 2006. Avaliação de Benefícios de Previsão Meteorológica na Operação de Reservatórios com Usos Múltiplos. IPH-UFRGS, 71 p, Porto Alegre.
- COULIBALY, P.; ANCTIL, F.; BOBÉE, B. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, n 230, p. 244-257.
- DAWSON, C.W.; HARPHAM, C.; WILBY, R.L.; CHEN, Y. 2002. Evaluation of artificial neural network techniques for flow forecasting in the River Yangtze, China. *Hydrol. and Earth System Sci.*, v 6, n 4, p. 619-926.
- DAWSON, C.W.; WILBY, R.L. 2001. Hydrological modeling using artificial neural networks. *Progress in Phys. Geog.*, v 25, n 1, p 80-108.
- DEMUTH, H.; BEALE, M.; HAGAN, M. 2006. *Neural network toolbox user's guide*. The MathWorks. 848 p.
- GEORGAKAKOS, K.P.; KRZYSZTOFOWICZ, R. 2001. Probabilistic and ensemble forecasting. *J. Hydrol.*, v 249, p 1.
- GUILHON, L. G. F. 2002. Modelo heurístico de previsão de vazões naturais médias semanais aplicado à usina de Foz do Areia. Dissertação de mestrado. Universidade Federal do Rio de Janeiro. Rio de Janeiro.
- GUILHON, L.G.F. 2007. Comunicação pessoal.
- GUO, S.; ZHANG, H.; CHEN, H. PENG, D.; LIU, P.; PANG, B. 2004. A reservoir flood forecasting and control system for China. *Hydrol. Sci.*, v 49, n 6, p 959-972.
- HAMLET, A.F.; HUPPERT, D.; LETTENMAIER, D.P. 2002. Economic values of long-lead streamflow forecasts for Columbia River hidropower. *J. Water Resour. Plann. Manag.*, v 128, n 2, p 91-101.
- IMRIE, C.E.; DURUCAN, S.; KORRE, A. 2000. River flow prediction using artificial neural networks: generalisation beyond the calibration range. *Journal of Hydrology*, n 233, p. 138-153.
- IPH, 2005. Previsão de afluência a reservatórios hidrelétricos – Módulo 1 (PREVHIDRO). Projeto FAURGS/FINEP 40.04.0094.00, Relatório Técnico.
- JÓNSDÓTTIR, J.F.; UVO, C.B. 2007. Comunicação pessoal.
- MACEIRA, M. E. P.; DAMÁZIO, J. M. 2005. Periodic autoregressive streamflow models applied to operation planning for the Brazilian hydroelectric system. *Regional hydrological impacts of climatic change – Impact assessment and decision making*. IAHS Publication, 295.
- MAIER, H.R.; DANDY, G.C. 1997. Modelling cyanobacteria (blue-green algae) in the River Murray using artificial neural networks. *Math. and Comp. in Simulation*, v 43, p 377-386.
- MAIER, H.R.; DANDY, G.C. 2000. Neural networks for the predictions and forecasting of water resources variables: a review of modeling issues and applications. *Environm. Model. and Software*, v 15, p 101-124.

- MAURER, E.P.; LETTENMAIER, D.P. 2004. Potential effects of long-lead hydrologic predictability on Missouri River main-stem reservoirs. *J. Climate*, v 17, p 174-186.
- MOLLER, M.S. 1993. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, v 6, n 4, p 525-534.
- SARMENTO, F.J. 1996. Modelagem de séries hidrológicas através de redes de neurônios. *Revista Brasileira de Recursos Hídricos*, ABRH, v 1, n 2, p. 19-31.
- STOKELJ, T.; PARAVAN, D.; GOLOB, R. 2002. Enhanced artificial neural network inflow forecasting algorithm for run-of-river hydropower plants. *J. Water Resour. Plann. Manag.*, v 128, n 6, p 415-423.
- TCHABAN, T; TAYLOR, M.J.; GRIFFIN, J.P. 1998. Establishing Impacts of the Inputs in a Feedforward Neural Network. *Neural Comp. and Applications*, v 7, p 309-317.
- THIRUMALAI, K.; DEO, M.C. 2000. Hydrological forecasting using neural networks. *Journal of Hydrologic Engineering*, v. 5, n. 2, p. 180-189.
- TUCCI, C.E.M.; COLLISCHONN, W. 2003. Previsão de Vazão. In: TUCCI, C.E.M.; BRAGA, B. (Orgs.) *Clima e Recursos Hídricos no Brasil*. Porto Alegre: ABRH, p.281-348.
- WURBS, R. A. Modeling and analysis of reservoir system operations. Prentice-Hall PTR, 356 p, New Jersey, 1996.
- ZEALAND, C.M.; BURN, D.H.; SIMONOVIC, S.P. 1999. Short term streamflow forecasting using artificial neural networks. *Journal of Hydrology*, n 214, p. 32-48.

Improvement in inflow forecasts using the proposed model depends on quality of rainfall forecasts. However, forecast performance was better than the current streamflow forecasts produced by the Brazilian national electric system operator.

The performance of the streamflow forecast model using ETA rainfall forecast and perfect forecast were similar up to the fifth lead time. Meanwhile, quality of streamflow forecasts improves when using perfect rainfall forecast from lead time six to twelve, compared to that using ETA forecast.

Keywords: *Streamflow forecast, artificial neural networks models, rainfall forecast.*

Short Term Forecasts of Inflow to the Furnas Reservoir Using Artificial Neural Networks.

ABSTRACT

This study presents the evaluation of the performance of a streamflow forecast model based on a feed-forward multilayer artificial neural network. Available rainfall forecasts were considered as additional inputs to the model. The Furnas dam, in the Rio Grande basin, was selected as the case study, primarily because of the availability of short-term rainfall forecast data produced in a previous study using an ETA model. Streamflow forecasts have a twelve day horizon at daily intervals (lead times from 1 to 12 days). A new methodology for training and validating the Artificial Neural Network is proposed based on perfect rainfall forecasts (considering observed rainfall as a forecast).

Results show that benefits could be achieved in inflow forecasts to Furnas dam by incorporating rainfall forecasts.