

ANÁLISE DE METODOLOGIAS DE PREVISÃO DE VAZÕES EM TEMPO REAL ESTUDO DE CASOS: BACIAS DO RIO DOCE (MG) E DO RIO URUGUAI (RS)

Adriano Rolim da Paz¹, Eduardo de Oliveira Bueno¹, Carlos Eduardo Morelli Tucci²

Resumo – Para o gerenciamento de enchentes, a previsão de vazões em tempo real se apresenta como uma medida não estrutural de grande importância na redução dos prejuízos decorrentes das grandes cheias. Diversas metodologias têm sido estudadas para a previsão de vazões de enchentes. Neste trabalho, analisou-se a aplicação do método de diferenças (modelo Prev) e da técnica das redes neurais artificiais (RNAs), nas bacias hidrográficas do rio Doce (MG) e do rio Uruguai (RS). Nesses casos, ambas as metodologias obtiveram desempenhos semelhantes, limitados pelas informações disponíveis e pelas simplificações nos processos que envolvem o escoamento natural em um curso d'água.

Abstract – In a flood management system, real time flood forecasting is an important non structural procedure to reduce damages caused by inundation. Several methods have been studied for river flow forecasting. In this paper, difference method (Prev model) and artificial neural network (ANN) technique were tested, with application to Doce river basin (MG) and to Uruguai river basin (RS). In such cases, both methods presented equivalent performances, limited by both available information and the simplifications of the processes which occur in a natural river flow.

Palavras-chave – previsão de vazões, redes neurais artificiais, método de diferenças

INTRODUÇÃO

A constante ocorrência de inundações tem sido um grande problema em diversas regiões brasileiras, trazendo como consequência prejuízos humanos e materiais consideráveis, justificando, assim, a preocupação dos órgãos de planejamento e gestão dos recursos hídricos. Para isso, a previsão de vazões em tempo real tem-se apresentado como uma medida não estrutural de grande importância na redução dos danos decorrentes das grandes cheias.

1. Eng. Civil, Mestrando em Recursos Hídricos e Saneamento Ambiental. Instituto de Pesquisas Hidráulicas da UFRGS. Av. Bento Gonçalves, 9500, Caixa Postal 15029, CEP 91501-970, Porto Alegre-RS. Telefone: (51) 3316 6327. E-mail: rolimpaz@ppgiph.ufrgs.br; bueno@ppgiph.ufrgs.br.

2. Prof. titular do Instituto de Pesquisas Hidráulicas da UFRGS. Telefone: (51) 3316 6408. E-mail: tucci@iph.ufrgs.br

A variação do nível ou vazão de um rio depende das características físicas da bacia e de condições climatológicas, como as distribuições temporal e espacial da precipitação. Quando as chuvas são intensas, a quantidade de água que chega simultaneamente ao rio pode ser superior à capacidade de drenagem de sua calha normal, resultando na inundação das áreas ribeirinhas. As mesmas só podem ser previstas deterministicamente com antecedência de poucos dias ou horas. O tempo máximo possível de previsão de cheias, a partir da ocorrência da precipitação (modelos chuva-vazão), é limitado pelo tempo médio de deslocamento da água na bacia até a seção de interesse (Tucci, 1993). Uma outra alternativa que tem sido utilizada é a realização da previsão de vazões com base nas informações de níveis ou vazões à montante da seção de interesse (modelos de propagação de vazões) e através da combinação das duas alternativas anteriores, ou seja, modelos chuva-vazão com propagação em rios.

Além de modelos matemáticos convencionais, empíricos ou conceituais, como modelos lineares, modelos de diferenças e modelos distribuídos não-lineares, algumas técnicas mais recentes, como as redes neurais artificiais, também têm sido empregadas com o objetivo de previsão de vazões em tempo real.

Neste trabalho, analisou-se a aplicação do método de diferenças (modelo Prev) e da técnica das redes neurais artificiais (RNAs), para a previsão de vazões para as bacias hidrográficas do rio Doce (MG) e do rio Uruguai (RS).

METODOLOGIA

Modelo Prev

O modelo Prev, desenvolvido no Instituto de Pesquisas Hidráulicas (IPH/UFRGS), trata-se de um modelo empírico e determinístico que realiza previsão de níveis ou vazões em tempo real, com base na propagação do escoamento, utilizando uma equação linear múltipla de diferenças das variáveis envolvidas. O termo dependente é a diferença entre o nível ou a vazão na antecedência desejada ($t+\tau$) e no tempo t , no local escolhido para a previsão, enquanto os termos independentes são as diferenças nos níveis ou vazões no intervalo $(t-\tau)$ a t , em seções a montante.

A previsão de vazões pode ser realizada utilizando uma equação linear da seguinte forma:

$$Q_{t+\tau} = aI_t + bQ_t + c \quad (1)$$

onde $Q_{t+\tau}$ é a vazão de saída no trecho no instante de tempo $(t+\tau)$, Q_t é a vazão de saída no trecho no tempo t , I_t é vazão de entrada no trecho no tempo t . Os parâmetros a , b e c podem ser estimados com base em K e X do modelo de Muskingun (relacionados com as características do trecho em estudo), através de ajuste gráfico, ou com base no método dos mínimos quadrados.

Segundo Tucci (1998), o método de diferenças utiliza as diferenças entre o valor atual da vazão e o do intervalo de previsão. Assim, usando a equação (1) para o instante t , obtem-se:

$$Q_t = aI_{t-\tau} + bQ_{t-\tau} + c \quad (2)$$

Subtraindo a equação (2) de (1), resulta em:

$$\Delta Q_{t+\tau} = a\Delta I_t + b\Delta Q_t \quad (3)$$

Generalizando a equação anterior para um trecho de rio com n afluentes, a equação fica da seguinte forma:

$$\Delta Q_{t+\tau} = a_1\Delta I_t^1 + a_2\Delta I_t^2 + \dots + a_n\Delta I_t^n + b\Delta Q_t \quad (4)$$

onde ΔI_t^i representa a variação de vazão entre os tempos $t-\tau$ e t da entrada de montante i .

O modelo Prev utiliza a equação (4), modificada pela introdução de um termo independente:

$$\Delta Q_{t+\tau} = a_1\Delta I_t^1 + a_2\Delta I_t^2 + \dots + a_n\Delta I_t^n + b\Delta Q_t + a_{n+1} \quad (5)$$

Segundo Tucci (1998), quando não existem dados de vazão, pode-se utilizar os níveis, já que o coeficiente correspondente poderá traduzir a relação com a vazão. E, apesar da não linearidade da relação cota-vazão, o modelo pode representar um trecho retilíneo da curva de descarga, em função da faixa de valores envolvida na simulação. Além disso, uma outra vantagem do modelo Prev é permitir a atualização dos parâmetros da equação (5) ao longo da simulação.

Redes Neurais Artificiais (RNAs)

As redes de neurônios artificiais constituem-se de importante alternativa na modelagem matemática de sistemas que envolvem transformações não lineares. Empregando-se algoritmos matemáticos, as RNAs seguem o princípio do funcionamento das redes de neurônios biológicas, através das quais o sistema nervoso central é capaz de aprender reações face a estímulos externos, em um ambiente hostil (Sarmiento, 1996). Analogamente às propriedades do aprendizado do cérebro humano, nas RNAs, a informação é processada em elementos singulares – os neurônios – sendo os sinais recebidos transformados e retransmitidos, através de ligações entre eles, que são associadas a um fator de ponderação, indicando a força e a influência de um determinado sinal no comportamento da rede.

Basicamente, as redes neurais artificiais são caracterizadas pela sua arquitetura, que corresponde à disposição dos neurônios nas camadas e suas ligações, e pelo tipo de função de ativação, como a função sigmóide, a gaussiana e a tangente hiperbólica, entre outras.

Os neurônios são organizados em três tipos de camadas: uma camada de entrada, uma ou mais camadas intermediárias ou escondidas (havendo a possibilidade de não inclusão destas na rede) e uma camada de saída. Por meio das conexões existentes entre as camadas adjacentes, a informação fornecida aos neurônios da camada de entrada é processada, aplicando-se fatores de ponderação, ao longo da rede, resultando, enfim, na informação apresentada pelos neurônios da camada de saída.

Uma das etapas mais importantes na modelagem com as RNAs é a definição das variáveis de entrada, que constituirão os neurônios da camada de entrada. É interessante pensar no problema que se quer modelar e no modo como as redes funcionam, para escolher quais informações devem ser fornecidas a esses sistemas, de modo a obter o melhor desempenho. Em um estudo de previsão de vazões, com um tempo de antecedência de uma semana, Zealand et al. (1999) utilizaram a precipitação, a temperatura e a vazão em semanas anteriores, em um total de 18 neurônios da camada de entrada. Na camada de saída, a quantidade de neurônios é definida pelas variáveis de resposta que se deseja obter para o fenômeno estudado. Quanto às camadas intermediárias, não existe regra definida para o seu número e nem para os neurônios que as compõem, sendo tais valores determinados através de experiências com diferentes arquiteturas e de observações dos resultados, por meio de tentativa e erro.

Na aplicação das RNAs, procedem-se duas etapas: inicialmente, realiza-se a fase de calibração ou treinamento e, posteriormente, a fase de validação. Na primeira, através de algoritmos como, por exemplo, o mecanismo de propagação regressiva dos erros (*error back-propagation*), determina-se o erro entre os valores observados e os valores calculados pela rede e, a partir dele, recalculam-se todos os parâmetros das ligações entre os neurônios, em um processo iterativo, até que tal erro seja inferior a um valor pré-estabelecido (Hinton, 1992).

Na fase de validação, analisa-se o comportamento da rede para uma série de valores diferente daquela empregada na fase anterior e, caso sejam satisfatórios os resultados, entende-se que a rede está apta a, finalmente, desempenhar os objetivos para os quais foi idealizada, sendo capaz de reproduzir o fenômeno estudado.

Segundo Imrie et al. (2000), se a rede possuir poucos neurônios, pode haver insuficiente quantidade de graus de liberdade para conseguir captar a relação entre as variáveis de entrada e as de saída. Por outro lado, uma rede muito grande pode falhar na generalização do fenômeno, memorizando flutuações dos dados de treinamento que não são representativas do sistema que está sendo modelado.

A principal vantagem das redes neurais – a capacidade de generalização – pode ser prejudicada com um treinamento excessivo, onde se consegue um melhor ajuste aos dados do treinamento devido à memorização da rede, resultando em um fraco ajuste na validação. Assim, a eficiência do método é altamente dependente do critério de parada do treinamento (Coulibaly et al., 2000). Para isso, pode-se dividir o conjunto de dados utilizado nessa fase em dois: “conjunto de treinamento” e “conjunto teste”. Este último é empregado com o objetivo de se avaliar a performance da rede e decidir quando parar o treinamento, enquanto que o primeiro é usado para estabelecer os pesos das ligações entre os neurônios.

Uma das facilidades da utilização das RNAs na modelagem dos recursos hídricos, ou em qualquer outra área, é que não há a necessidade do conhecimento prévio entre as variáveis do modelo. Segundo Maier e Dandy (1996) apud Zealand et al. (1999), na modelagem com as redes neurais não é preciso saber qual distribuição estatística os dados seguem e, além disso, não-estacionariedades dos dados, como tendências e variações sazonais, são implicitamente “absorvidas” pela estrutura interna das redes. O uso desta técnica nos recursos hídricos tem ampla aplicação, como, por exemplo, na operação de reservatórios em tempo real, no desenvolvimento de programas especialistas para suporte a decisões, na previsão de eventos extremos como secas e enchentes, entre outros (Sarmiento, 1996).

ÁREAS EM ESTUDO

Bacia hidrográfica do rio Doce

A bacia do rio Doce está situada na região Sudeste brasileira e pertence à bacia hidrográfica do Atlântico Sul (Trecho Leste). A bacia possui uma área de drenagem de aproximadamente 83.500km², onde 86% estão dentro do Estado de Minas Gerais e 14% no Estado do Espírito Santo, conforme ilustra a figura 1.

O trecho escolhido para a previsão de vazões compreende o trecho médio do rio Doce, entre as estações fluviométricas de Cenibra e Governador Valadares, possuindo um comprimento de 76km e uma declividade média de 0,74m/km. Nesse trecho, está inserida a confluência com o rio Santo Antônio, monitorado pelo posto de Naque Velho.

A área de drenagem em Governador Valadares é de 39.828km², sendo a área total coberta através de Cenibra (24.245km²) e Naque Velho (10.170km²) da ordem de 85% desta.

Neste estudo, utilizaram-se dados dos postos de montante (Cenibra e Naque Velho), além do próprio posto de Governador Valadares, local da previsão de vazões de enchente.

Bacia hidrográfica do rio Uruguai

A bacia do rio Uruguai tem uma área de drenagem de 276.000km² e está localizada na região Sul do país (figura 2). Essa bacia se inicia na Serra do Mar e define os limites dos Estados de Santa Catarina e do Rio Grande do Sul, no trecho brasileiro, representando a fronteira entre Brasil e Argentina, no trecho internacional.

O trecho estudado tem um comprimento de 314km e uma declividade média de 0,09 m/km, correspondendo ao Médio Uruguai entre os postos de Garruchos e Uruguaiana. O posto de Garruchos apresenta uma área de drenagem de 115.700Km² e está situado a montante do posto de Uruguaiana (189.300km²), local escolhido para previsão de vazões.

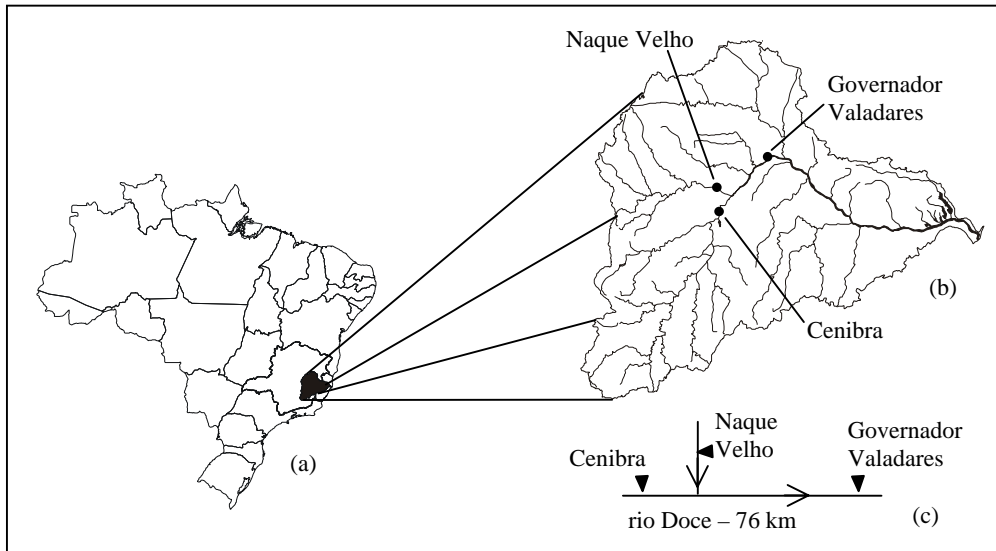


Figura 1: (a) Localização da bacia do rio Doce; (b) Detalhe da bacia com a indicação dos postos utilizados; (c) Esquema do trecho em estudo.

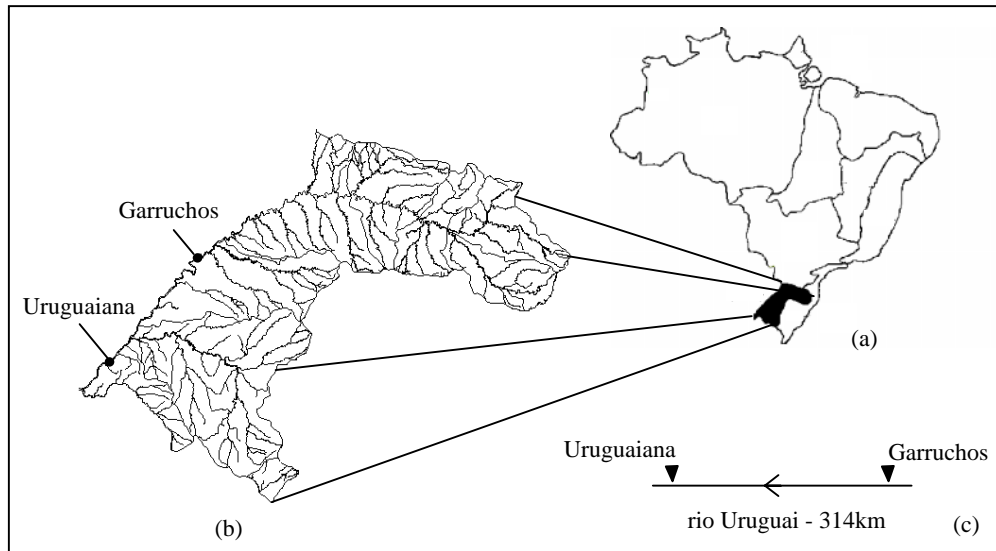


Figura 2: (a) Localização da bacia do rio Uruguai; (b) Detalhe da bacia com a indicação dos postos utilizados; (c) Esquema do trecho em estudo.

RESULTADOS

Estatísticas dos resultados

Para avaliar os resultados das simulações, utilizou-se o coeficiente de Nash (R^2), o erro padrão da estimativa (EP) e o coeficiente RD, dados pelas equações (6), (7) e (8), respectivamente.

$$R^2 = 1 - \frac{\sum (Q_{o_{t+\tau}} - Q_{c_{t+\tau}})^2}{\sum (Q_{o_{t+\tau}} - Q_m)^2} \quad (6)$$

$$EP = \sqrt{\frac{\sum (Q_{o_{t+\tau}} - Q_{c_{t+\tau}})^2}{n}} \quad (7)$$

$$RD = 1 - \frac{\sum (Qo_{t+\tau} - Qc_{t+\tau})^2}{\sum (Qo_{t+\tau} - Qo_t)^2} \quad (8)$$

onde Qo é a vazão observada, Qc a vazão calculada, Qm a vazão média, n é o número de valores do evento, t representa um instante de tempo qualquer e τ o tempo de antecedência da previsão (*lag*).

Segundo Tucci (1998), a estatística R^2 compara a redução do desvio quadrático do erro do modelo com o desvio quadrático do modelo alternativo de prever sempre a média dos valores. No entanto, no caso de previsão de vazões em tempo real, não existe lógica em prever sempre a média dos valores. Assim, o coeficiente RD é importante de ser analisado, pois compara o desvio quadrático do erro do modelo com o desvio quadrático do modelo alternativo de prever o valor atual, uma vez que, na pior das hipóteses, o melhor resultado previsto seria o valor no instante t .

Geralmente, costuma-se avaliar o resultado de um modelo matemático com base na aproximação dos hidrogramas observado e calculado. A parte inicial do hidrograma do evento, onde se encontra o trecho de subida, é a mais importante, quando se trata de ajustar um modelo para previsão em tempo real, já que representa a real fase de antecipação da ocorrência da enchente. Por isso, na etapa de seleção dos eventos, procurou-se não usar um período longo de dados no trecho de recessão do hidrograma, o que poderia gerar estatísticas boas, porém tendenciosas.

Bacia do rio Doce

Eventos selecionados

Para a previsão de vazões na bacia do rio Doce, foram selecionados quatro eventos, apresentados na tabela abaixo (tabela 1). Procurou-se selecionar eventos com vazões máximas acima de $1800\text{m}^3/\text{s}$, valor correspondente à cota de alerta em Governador Valadares.

Tabela 1 - Eventos selecionados para a bacia do rio Doce

Evento	Período
1	22/03/1991 a 29/03/1991
2	14/01/1992 a 19/01/1992
3	25/12/1994 a 29/12/1994
4	02/01/1997 a 11/01/1997

Apesar das estações de Governador Valadares e Cenibra apresentarem dados discretizados a cada duas horas, a estação de Naque Velho possui apenas as leituras dos níveis das 7:00h e 17:00h. Devido a essa limitação, adotou-se um intervalo médio de antecedência de 12 horas, para a previsão de vazões em Governador Valadares, como sugerido por Castilho e Oliveira (2001).

Previsão com o modelo Prev

Na fase de calibração do modelo Prev, utilizou-se o evento 1, por apresentar melhores resultados comparados aos demais eventos, obtendo-se a seguinte equação de previsão:

$$Q_{t+12} = Q_t + 0,79\Delta I_t^1 - 0,26\Delta I_t^2 + 0,61\Delta Q_t - 8,32 \quad (9)$$

onde:

Q_{t+12} é a vazão (m^3/s) no instante de tempo $t + 12h$, em Governador Valadares;

Q_t é a vazão (m^3/s) no instante de tempo t , em Governador Valadares;

ΔI_t^1 é a diferença entre as vazões (m^3/s) nos tempos t e $t-12h$, em Cenibra;

ΔI_t^2 é a diferença entre as vazões (m^3/s) nos tempos t e $t-12h$, em Naque Velho;

ΔQ_t é a diferença entre as vazões (m^3/s) nos tempos t e $t-12h$, em Governador Valadares.

Após a calibração, foram utilizados os eventos 2, 3 e 4 para a validação do modelo, realizada com a opção de atualização dos parâmetros, sendo as estatísticas dos resultados apresentadas na tabela 2. Nas figuras 3 a 6, encontram-se os hidrogramas observado e calculado para todos os eventos.

Castilho e Oliveira (2001) realizaram a previsão de vazões em Governador Valadares, usando uma equação linear ajustada pelo método dos mínimos quadrados. Os melhores resultados foram alcançados utilizando como uma das variáveis independentes a soma das vazões nas estações de Cenibra e Naque Velho. Baseado nesse estudo, realizou-se uma nova simulação com o modelo Prev, considerando como variável independente a soma das vazões de Cenibra e Naque Velho, além da própria vazão em Governador Valadares. A equação (10) representa a equação de previsão para o novo modelo, cujos resultados podem ser verificados na tabela 2 e nas figuras 3 a 6.

$$Q_{t+12} = Q_t + 0,32\Delta S_t + 0,52\Delta Q_t + 10,11 \quad (10)$$

onde ΔS_t é a diferença das somas, nos tempos t e $t-12h$, das vazões (m^3/s) de Cenibra e Naque Velho.

Tabela 2 - Estatísticas dos resultados utilizando o modelo Prev para a bacia do rio Doce.

Etapa	Previsão I				Previsão II			
	Ajuste I	2	3	4	Ajuste II	2	3	4
evento	1				1			
R ²	0,9673	0,8688	0,9920	0,8904	0,9465	0,8877	0,9962	0,8963
RD	0,8646	0,7622	0,7555	0,3756	0,7789	0,7964	0,8831	0,4092
EP (m^3/s)	122	166	144	653	156	154	99	635

obs: I = Simulação utilizando como variáveis independentes as vazões de Cenibra e Naque Velho.

II = Simulação utilizando como variável independente a soma das vazões de Cenibra e Naque Velho.

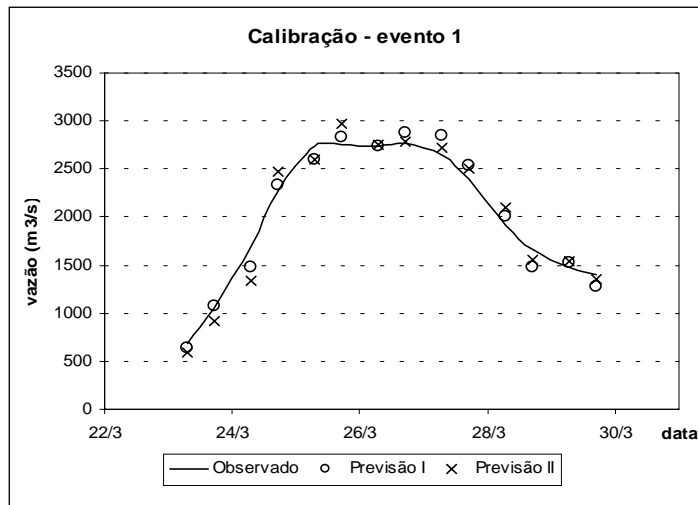


Figura 3. Ajuste do evento 1 - Modelo Prev (bacia do rio Doce)




Figura 4. Previsão do evento 2 - Modelo Prev (bacia do rio Doce)

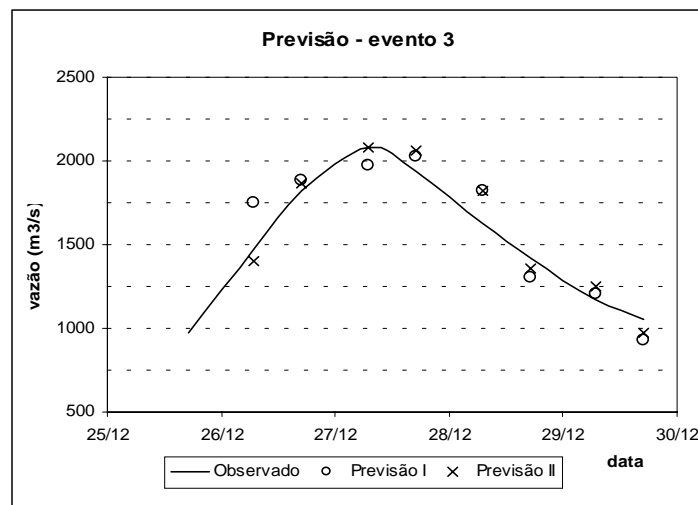


Figura 5. Previsão do evento 3 - Modelo Prev (bacia do rio Doce)




Figura 6. Previsão do evento 4 - Modelo Prev (bacia do rio Doce)

Previsão com as RNAs

Com o intuito de comparar a técnica das redes neurais artificiais com o modelo Prev, centrou-se o foco da aplicação das RNAs na previsão de vazões no posto de Governador Valadares, a partir dos dados dos postos de Cenibra e Naque Velho, com 12 horas de antecedência. Para a etapa de treinamento das redes neurais, adotou-se, novamente, o evento 1, sendo a validação realizada com os eventos 2, 3 e 4 (tabela 1).

Neste estudo, foram realizadas diversas combinações de variáveis de entrada para a rede, sendo definidos 6 diferentes esquemas, descritos no quadro 1. Em todos eles, optou-se pela função sigmóide como função de ativação entre os neurônios, usando o mecanismo de propagação regressiva dos erros para ajuste dos pesos. Como critério de parada do treinamento, adotou-se a correlação do conjunto teste, constituído pelos pontos iniciais do hidrograma de cheia. Para cada esquema adotado, várias arquiteturas de rede foram testadas, variando-se o número de neurônios e de camadas intermediárias.

Buscando uma analogia com o modelo Prev, alguns esquemas utilizaram, como dados de entrada, as diferenças observadas das vazões em instantes de tempo anteriores, sendo prevista a diferença da vazão futura em relação à atual, em Governador Valadares (esquemas 3 e 4). Entendeu-se que isto poderia permitir que a rede neural conseguisse reproduzir melhor quanto e quando ocorresse a subida ou a recessão do hidrograma do evento.

Os esquemas 5 e 6 foram estabelecidos procurando representar a relação sugerida por Castilho e Oliveira (2001), entre a vazão em Governador Valadares e a soma de vazões em Cenibra e Naque Velho. A tabela 3 apresenta um resumo dos resultados obtidos na fase de treinamento e

validação, considerando apenas a melhor arquitetura de rede para cada esquema proposto. A figura 7 mostra a arquitetura da rede do esquema 6, para a qual obteve-se os melhores resultados durante as simulações. Nas figuras 8 a 11, pode-se comparar os valores observados para cada evento com aqueles calculados para os esquemas 6 e 3.

Quadro 1 - Descrição dos esquemas de RNAs utilizados na previsão (bacia do rio Doce)

<p>esquema 1 previsão de $Q(t+1)$ em Gov. Valadares dados de entrada: $Q(t)$ em Cenibra $Q(t)$ em Naque Velho $Q(t)$ em Gov. Valadares</p> <p>esquema 2 previsão de $Q(t+1)$ em Gov. Valadares dados de entrada: $[Q(t)-Q(t-1)]$ em Cenibra $[Q(t-1)-Q(t-2)]$ em Cenibra $[Q(t)-Q(t-1)]$ em Naque Velho $[Q(t-1)-Q(t-2)]$ em Naque Velho $[Q(t)-Q(t-1)]$ em Gov. Valadares $[Q(t-1)-Q(t-2)]$ em Gov. Valadares $Q(t)$ em Cenibra $Q(t)$ em Naque Velho $Q(t)$ em Gov. Valadares</p> <p>esquema 3 previsão de $[Q(t+1)-Q(t)]$ em Gov. Valadares dados de entrada: $[Q(t)-Q(t-1)]$ em Cenibra $[Q(t-1)-Q(t-2)]$ em Cenibra $[Q(t)-Q(t-1)]$ em Naque Velho $[Q(t-1)-Q(t-2)]$ em Naque Velho $[Q(t)-Q(t-1)]$ em Gov. Valadares $[Q(t-1)-Q(t-2)]$ em Gov. Valadares $Q(t)$ em Cenibra $Q(t)$ em Naque Velho $Q(t)$ em Gov. Valadares</p>	<p>esquema 4 previsão de $[Q(t+1)-Q(t)]$ em Gov. Valadares dados de entrada: $[Q(t)-Q(t-1)]$ em Cenibra $[Q(t-1)-Q(t-2)]$ em Cenibra $[Q(t)-Q(t-1)]$ em Naque Velho $[Q(t-1)-Q(t-2)]$ em Naque Velho $[Q(t)-Q(t-1)]$ em Gov. Valadares $[Q(t-1)-Q(t-2)]$ em Gov. Valadares $Q(t)$ em Cenibra $Q(t)$ em Naque Velho $Q(t)$ em Gov. Valadares $Q(t-1)$ em Cenibra $Q(t-1)$ em Naque Velho $Q(t-1)$ em Gov. Valadares</p> <p>esquema 5 previsão de $Q(t+1)$ em Gov. Valadares dados de entrada: $S(t) = Q(t)$ Cenibra + $Q(t)$ Naque Velho $Q(t)$ em Gov. Valadares</p> <p>esquema 6 previsão de $[Q(t+1)-Q(t)]$ em Gov. Valadares dados de entrada: $S(t)$ $[S(t)-S(t-1)]$ $Q(t)$ em Gov. Valadares $[Q(t)-Q(t-1)]$ em Gov. Valadares</p>
---	--

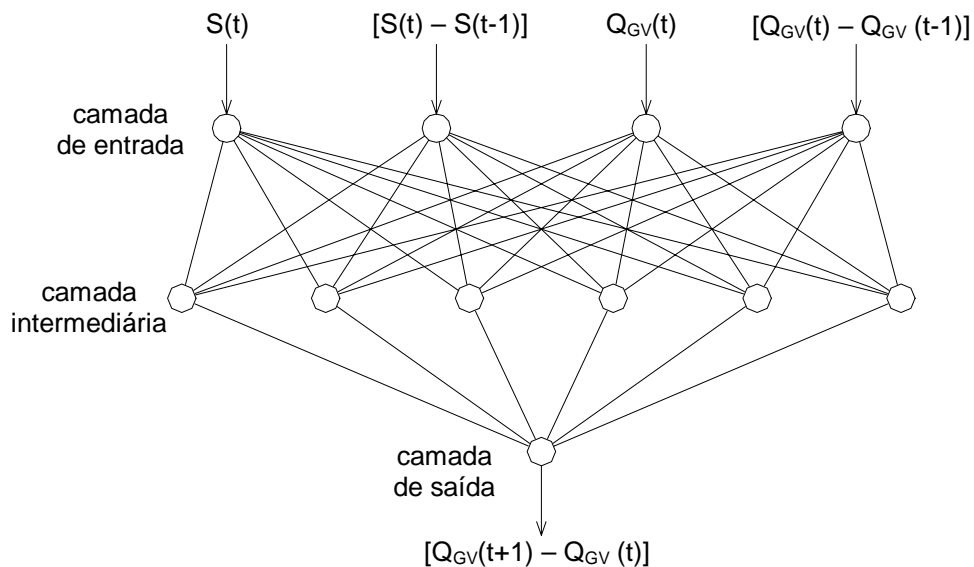


Figura 7. RNA com arquitetura 4-6-1 para o esquema 6. $S(t)$ é a soma das vazões em Cenibra e Naque Velho no tempo t ; $Q_{GV}(t)$ é a vazão em Governador Valadares no tempo t .

Tabela 3 - Estatísticas dos resultados utilizando as RNAs para a bacia do rio Doce.

esq	RNA	calibração - evento 1			previsão - evento 2			previsão - evento 3			previsão - evento 4		
		R ²	RD	EP m ³ /s	R ²	RD	EP m ³ /s	R ²	RD	EP m ³ /s	R ²	RD	EP m ³ /s
1	3-3-1	0,910	0,506	225	0,928	0,790	150	0,800	0,700	166	-0,212	-6,823	2251
2	9-4-1	0,860	0,586	220	0,852	0,808	148	0,433	-0,221	272	-0,963	-8,697	2647
3	9-9-1	0,916	0,753	170	0,841	0,793	153	0,922	0,832	101	0,885	0,433	640
4	12-8-1	0,977	0,931	90	0,819	0,765	163	0,864	0,707	133	0,879	0,404	656
5	2-4-1	0,963	0,800	143	0,953	0,864	120	0,957	0,936	77	-0,249	-7,056	2284
6	4-6-1	0,968	0,869	120	0,925	0,902	106	0,946	0,925	79	0,920	0,547	557




Figura 8. Ajuste do evento 1 - RNA (bacia do rio Doce)




Figura 9. Previsão do evento 2 - RNA (bacia do rio Doce)




Figura 10. Previsão do evento 3 - RNA (bacia do rio Doce)




Figura 11. Previsão do evento 4 - RNA (bacia do rio Doce)

Bacia do rio Uruguai

Eventos selecionados

Na previsão de vazões para a bacia do rio Uruguai, foram selecionados três eventos, apresentados na tabela abaixo (tabela 4). Os dados utilizados na simulação são de vazões diárias nos postos fluviométricos de Garruchos e Uruguaiana. O intervalo de antecedência de previsão foi adotado como sendo de 24h ($\tau = 1$ dia).

Tabela 4 - Eventos selecionados para a bacia do rio Uruguai

Evento	Período
1	16/08/1965 a 06/09/1965
2	09/07/1983 a 29/07/1983
3	18/08/1983 a 29/08/1983

Previsão com o modelo Prev

Da mesma forma que na previsão para a bacia do rio Doce, calibrou-se o modelo Prev com o evento 1, cujos resultados obtidos foram os melhores, comparados aos dos demais eventos. Assim, obteve-se a seguinte equação de previsão:

$$Q_{t+1} = Q_t + 0,09\Delta I_t^1 + 0,85\Delta Q_t + 4,55 \quad (11)$$

onde:

Q_{t+1} é a vazão (m^3/s) no instante de tempo $t+1$ dia, em Uruguaiana;

Q_t é a vazão (m^3/s) no instante de tempo t , em Uruguaiana;

ΔI_t^1 é a diferença entre as vazões (m^3/s) nos tempos t e $t-1$ dia, em Garruchos;

ΔQ_t é a diferença entre as vazões (m^3/s) nos tempos t e $t-1$ dia, em Uruguaiana.

A validação do modelo foi realizada com os eventos 2 e 3, escolhendo-se a opção de atualização dos parâmetros, sendo as estatísticas dos resultados apresentadas na tabela 5. Nas figuras 12 a 14, encontram-se os hidrogramas observado e calculado para todos os eventos.

Tabela 5 - Resultados obtidos - Modelo Prev (bacia do rio Uruguai)

Etapa	Ajuste	Previsão	
	evento	2	3
R^2	0,9836	0,9834	0,9401
RD	0,8150	0,8596	0,8437
EP (m^3/s)	829	814	456

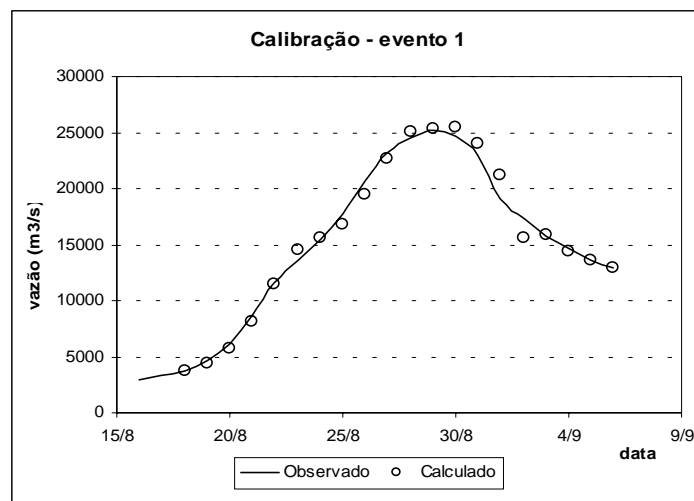


Figura 12. Ajuste do evento 1 - Modelo Prev (bacia do rio Uruguai)




Figura 13. Previsão do evento 2 - Modelo Prev (bacia do rio Uruguai)




Figura 14. Previsão do evento 3 - Modelo Prev (bacia do rio Uruguai)

Previsão com as RNAs

Da mesma forma que na previsão de vazões com o modelo Prev, a aplicação das redes neurais artificiais, para a bacia do rio Uruguai, foi realizada a partir dos dados de vazões diárias de Garruchos e Uruguiana, buscando um intervalo de previsão de 24h.

Para o treinamento das RNAs utilizou-se, novamente, o evento 1, restando à previsão os eventos 2 e 3. Nessa etapa, analogamente à aplicação para a bacia do rio Doce, procurou-se testar diferentes esquemas, variando-se as informações de entrada e a arquitetura da rede, motivado pelas mesmas justificativas apresentadas no caso anterior. Em relação às propriedades das RNAs, tais como o critério de parada de treinamento e a função de ativação, adotou-se as mesmas propostas para a previsão em Governador Valadares.

Os esquemas simulados estão definidos no quadro 2 e os resultados para as melhores arquiteturas apresentados na tabela 6. A figura 15 ilustra a arquitetura da rede do esquema 3, considerada a de melhor desempenho. Nas figuras 16 a 18, constam os hidrogramas observado e calculado, para cada evento, adotando os esquemas 3 e 1.

Quadro 2 - Descrição dos esquemas de RNAs utilizados na previsão (bacia do rio Uruguai)

<p>esquema 1 previsão de $Q(t+1)$ em Uruguiana dados de entrada: $Q(t)$ em Garruchos $Q(t)$ em Uruguiana</p> <p>esquema 3 previsão de $[Q(t+1)-Q(t)]$ em Uruguiana dados de entrada: $[Q(t)-Q(t-1)]$ em Garruchos $[Q(t-1)-Q(t-2)]$ em Garruchos $[Q(t)-Q(t-1)]$ em Uruguiana $[Q(t-1)-Q(t-2)]$ em Uruguiana $Q(t)$ em Garruchos $Q(t)$ em Uruguiana</p>	<p>esquema 2 previsão de $Q(t+1)$ em Uruguiana dados de entrada: $[Q(t)-Q(t-1)]$ em Garruchos $[Q(t-1)-Q(t-2)]$ em Garruchos $[Q(t)-Q(t-1)]$ em Uruguiana $[Q(t-1)-Q(t-2)]$ em Uruguiana $Q(t)$ em Garruchos $Q(t)$ em Uruguiana</p> <p>esquema 4 previsão de $[Q(t+1)-Q(t)]$ em Uruguiana dados de entrada: $[Q(t)-Q(t-1)]$ em Garruchos $[Q(t-1)-Q(t-2)]$ em Garruchos $[Q(t)-Q(t-1)]$ em Uruguiana $[Q(t-1)-Q(t-2)]$ em Uruguiana $Q(t)$ em Garruchos $Q(t)$ em Uruguiana $Q(t-1)$ em Garruchos $Q(t-1)$ em Uruguiana</p>
--	--

Tabela 6 - Estatísticas dos resultados utilizando as RNAs para a bacia do rio Uruguai.

esq	RNA	calibração - evento 1			previsão - evento 2			previsão - evento 3		
		R ²	RD	EP m ³ /s	R ²	RD	EP m ³ /s	R ²	RD	EP m ³ /s
1	2-4-1	0,964	0,501	1329	0,876	-0,110	2474	0,726	0,152	1014
2	6-6-4-1	0,913	0,189	1777	-0,142	-7,018	6167	-3,633	-10,15	4018
3	6-4-4-1	0,987	0,881	681	0,983	0,881	751	0,960	0,904	373
4	8-6-1	0,986	0,872	705	0,982	0,871	783	0,924	0,817	514

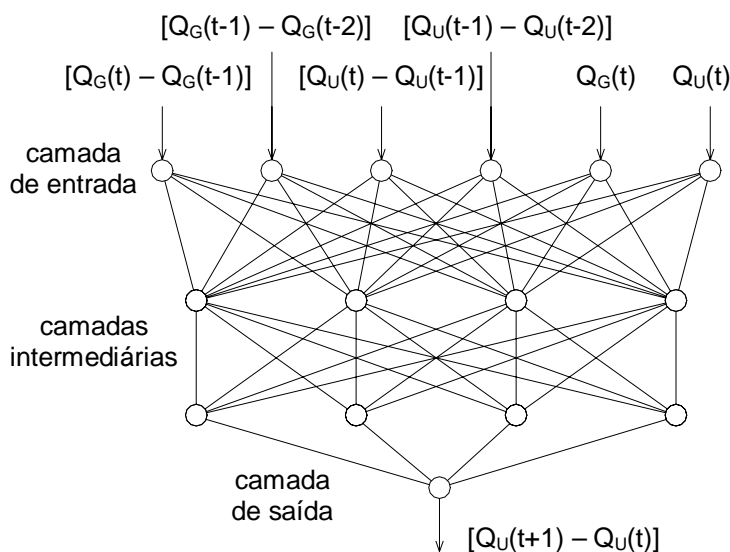


Figura 15. RNA com arquitetura 6-4-4-1 para o esquema 3. $Q_U(t)$ e $Q_G(t)$ são as vazões em Uruguiana e Garruchos, no tempo t , respectivamente.




Figura 16. Ajuste do evento 1 - RNA (bacia do rio Uruguai)




Figura 17. Previsão do evento 2 - RNA (bacia do rio Uruguai)

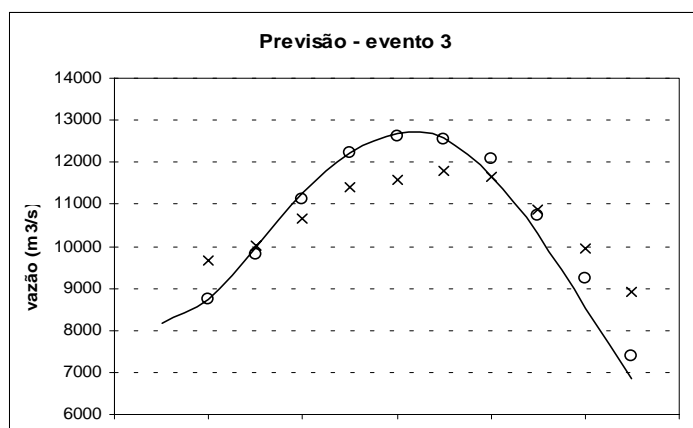


Figura 18. Previsão do evento 3 - RNA (bacia do rio Uruguai)

CONCLUSÃO

Analisando os resultados obtidos com a aplicação do método de diferenças (modelo Prev) para a previsão de vazões em tempo real, algumas considerações podem ser feitas:

- Para a bacia do rio Doce, a simulação utilizando como variável independente a soma das vazões de Cenibra e Naque Velho (Previsão II) obteve, para todos os eventos, melhor desempenho do que considerando as vazões de tais postos isoladamente (tabela 2, figuras 4 a 6). No entanto, para o evento 4, os valores do coeficiente RD indicaram um erro significativo na previsão, evidenciado por um erro padrão da estimativa (EP) da ordem de $650\text{m}^3/\text{s}$, ou seja, 9% da vazão de pico;

- Para a previsão no rio Uruguai, o modelo Prev alcançou resultados melhores do que na bacia do rio Doce, como mostram as estatísticas da tabela 5, onde se verifica que os valores de EP foram inferiores a 3% da vazão de pico. Isto pode ser justificado pela proximidade na magnitude dos eventos utilizados nas fases de calibração e validação do modelo.

Quanto à aplicação das RNAs para a previsão de vazões, constatou-se que:

- Tanto em Governador Valadares quanto em Uruguiana, a previsão do valor da vazão $Q(t+1)$ se mostrou menos eficiente do que se prever a diferença entre a vazão na antecedência desejada e no tempo $t - [Q(t+1)-Q(t)]$. Para o caso da bacia do rio Uruguai, isto pode ser comprovado com a análise dos hidrogramas apresentados nas figuras 17 e 18;

- O acréscimo de variáveis de entrada resultante da inclusão das vazões $Q(t-1)$ ao esquema 3, constituindo o esquema 4, para a bacia do rio Doce, não acarretou em melhores resultados produzidos pelas redes (tabela 3). Isto também foi verificado para a bacia do rio Uruguai, com os esquemas 3 e 4 (tabela 6);

- Para a bacia do rio Doce, o esquema que apresentou os melhores resultados (esquema 6) foi o que, novamente, levou em consideração a soma das vazões de Cenibra e Naque Velho. Comparando os resultados apresentados na tabela 3, referentes a tal esquema, com aqueles resultantes das simulações com o modelo Prev (tabela 2), têm-se evidências para se considerar uma melhor performance das redes neurais em relação ao método de diferenças. Para a bacia do rio

Uruguai, a diferença entre tais metodologias foi menos acentuada, conforme mostrado nas tabelas 5 e 6.

Uma das dificuldades enfrentadas para a previsão de vazões, na bacia do rio Doce, é a falta de dados no posto de Naque Velho, em intervalos de tempo menores, e a ausência de postos que cubram a área de contribuição à Governador Valadares, não monitorada atualmente. Recomendam-se, também, novos estudos, considerando a discretização do trecho analisado em subtrechos, devido a não-linearidade do processo natural de escoamento na calha de um rio, não reproduzido adequadamente na configuração do modelo Prev adotada neste trabalho.

O rio Uruguai, por constituir a divisa entre o Brasil e a Argentina, apresenta dificuldades características da gestão das águas transfronteiriças. Em relação à previsão de vazão, um aspecto importante se refere à disponibilidade de dados hidrológicos, uma vez que parte da área de drenagem que contribui para uma seção do rio Uruguai pode estar inserida em território argentino, podendo comprometer a eficiência do modelo de previsão, caso não se disponha de tais dados.

Na aplicação com as redes neurais artificiais, os diversos esquemas testados ressaltaram a importância da escolha dos dados de entrada, ou seja, de quais variáveis são capazes de transmitir à rede informações suficientes para que esta procure representar mais adequadamente o fenômeno estudado. Assim, recomenda-se considerar novas variáveis de entrada, que não apresentem dificuldades de monitoramento, como a precipitação e a temperatura.

Na tentativa de verificar o desempenho das RNAs frente a uma atualização de seus parâmetros, os autores adotaram um processo de re-treinamento sequencial das redes, denominado de atualização por eventos. Nesse processo, a rede passa por um novo treinamento ao final de cada evento, onde são recalculados os pesos das ligações entre os seus neurônios. Os resultados iniciais das simulações não alcançaram, ainda, a melhoria esperada e, atualmente, novas tentativas estão sendo estudadas para essa metodologia.

Apesar do melhor desempenho das redes neurais em relação ao modelo Prev, principalmente na bacia do rio Doce, resta a questão de avaliar se, na prática, o incremento observado nos resultados justifica a adoção de uma metodologia mais complexa em relação a uma técnica de simples aplicação e compreensão, como os métodos de regressão linear múltipla. No entanto, é importante se conscientizar que as limitações não se encontram apenas nas metodologias empregadas, mas, principalmente, nos dados disponíveis e na forma de explorá-los. Desse modo, recursos e pesquisas devem ser direcionados tanto para o desenvolvimento de técnicas mais precisas de previsão como para a melhoria dos sistemas de aquisição de dados hidrológicos.

Por fim, para que as informações fornecidas pelo sistema de alerta sejam eficientemente aproveitadas, é necessário a adoção de outras medidas de controle que amenizem os prejuízos causados pelas enchentes. Entre essas medidas, destacam-se como prioritárias o zoneamento das

áreas de inundação e a regulamentação do uso do solo, definindo os riscos das enchentes e os mapas de alerta e planejamento das cidades. Tucci (1993) sugere o seguro e a proteção individual como medidas complementares, necessárias para minimizar impactos sobre a economia da população.

AGRADECIMENTOS

Os autores agradecem a CPRM – SUREG/BH, por disponibilizarem os dados do Relatório Técnico da Operação do Sistema de Alerta contra Enchentes da Bacia do Rio Doce, ao CNPq, pela concessão das bolsas de estudo de mestrado, e ao Instituto de Pesquisas Hidráulicas, pela infraestrutura disponibilizada.

REFERÊNCIAS BIBLIOGRÁFICAS

- CASTILHO, A.S.; OLIVEIRA, L.M., 2001. Previsão Hidrológica de vazões para a cidade de Governador Valadares utilizando modelo linear de propagação. **XIV Simpósio Brasileiro de Recursos Hídricos**, ABRH: Aracaju.
- COULIBALY, P.; ANCTIL, F.; BOBÉE, B., 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. **Journal of Hydrology**, no 230, pp 244-257.
- HINTON, G.E., 1992. How neural networks learn from experience. **Scientific American**.
- IMRIE, C.E.; DURUCAN, S.; KORRE, A., 2000. River flow prediction using artificial neural networks: generalisation beyond the calibration range. **Journal of Hydrology**, no 233, pp 138-153.
- SARMENTO, F.J., 1996. Modelagem de séries hidrológicas através de redes de neurônios. **Revista Brasileira de Recursos Hídricos**. ABRH, vol 1, no 2, pp 19-31.
- TUCCI, C.E.M., 1998. **Modelos Hidrológicos**. Associação Brasileira de Recursos Hídricos, Porto Alegre.
- TUCCI, C.E.M., 1993. **Hidrologia: Ciência e Aplicação**. Organizado por Carlos E. M. Tucci. Porto Alegre: Ed. da Universidade: ABRH / EDUSP. Coleção ABRH de Recursos Hídricos, vol. 4.
- ZEALAND, C.M.; BURN, D.H.; SIMONOVIC, S.P., 1999. Short term streamflow forecasting using artificial neural networks. **Journal of Hydrology**, no 214, pp 32-48.