

## Efeito do Controle de Montante de Sub-bacias Embutidas na Previsão Hidrológica de Curto Prazo com Redes Neurais: Aplicação à Bacia de Ponte Mística

Alex Bortolon de Matos\*, Olavo Correa Pedrollo\*, Nilza Maria dos Reis Castro\*

alexortolon@hotmail.com; olavopedrollo@gmail.com; nilza@iph.ufrgs.br

Recebido: 22/11/12 - revisado: 06/05/13 - aceito: 30/10/13

---

### RESUMO

Neste trabalho foi avaliado o efeito do controle de montante em sub-bacias embutidas na previsão hidrológica de curto prazo, com a investigação conjunta de dois aspectos: variação da área controlada e a variação da frequência de aquisição das vazões de entrada do modelo. O local escolhido para essa pesquisa foi a porção da bacia do rio Ijuí com exutório no posto fluviométrico da Ponte Mística e as suas sub-bacias embutidas de Santo Ângelo, Ponte Nova do Potiribu, Colônia Mousquer, Passo do Faxinal e Turcato. Os dados de vazão utilizados foram obtidos da Agência Nacional de Águas (ANA) e do projeto de monitoramento da bacia do Potiribu, enquanto que os dados de precipitação foram obtidos por uma série histórica de precipitações médias de uma grade de chuvas interpoladas a partir dos dados de 65 postos pluviométricos da região. Para este estudo foram utilizados dados de 22/08/1989 à 01/06/1994 (1.408 dias). Esse período foi selecionado por ser o maior período com dados concomitantes em todos os postos fluviométricos. Os modelos escolhidos para esse estudo foram as redes neurais artificiais de múltiplas camadas, com utilização do algoritmo retropropagativo. As entradas nos modelos foram os dados de precipitação média e as vazões médias diárias da bacia de Ponte Mística e de suas sub-bacias, e as saídas foram as vazões médias diárias de Ponte Mística um dia à frente. Foram apresentadas nove alternativas de controle físico de montante. Também foram aplicadas, para cada uma das alternativas, valores defasados das variáveis, com a utilização dos dados de vazão com antecedência de 24h e 48h. A utilização de vazões horárias do Turcato foi comparada com uma alternativa que contempla o mesmo posto, mas com dados diários, para investigar se a utilização de dados com um maior detalhamento temporal pode produzir melhores resultados. Para a análise do desempenho da rede foi aplicado como estatística de qualidade o coeficiente de Nash-Sutcliffe (NS). A avaliação estatística apresentou bons resultados na previsão de vazão para todas as alternativas de controle, sendo o menor NS de 0,91 e o maior de 0,97. A utilização de um maior detalhamento temporal, com aplicação de vazões horárias, provocou uma redução no desempenho do modelo, com o NS caindo de 0,91 para 0,89. Observou-se também que, quanto maior a área controlada das bacias, melhores são os resultados para a previsão de vazão.

**Palavras-chave:** Previsão hidrológica de curto prazo; Redes Neurais.

---

### INTRODUÇÃO

As previsões de curto prazo são baseadas em dados de variáveis de estado, que são atualizados continuamente no tempo. Para cada “tempo atual”, uma previsão é emitida para o futuro próximo. Esta previsão costuma ser feita para intervalos pequenos, desde minutos até alguns dias (LETTENMAIER e WOOD, 1993), pois o intervalo entre a previsão e a realização é uma região temporal desconhecida, não

controlada, e quanto maior for esse intervalo, maiores serão as incertezas da previsão. No caso específico das previsões hidrológicas, as informações desconhecidas são as ocorrências hídricas neste intervalo, cujo limite é o horizonte de previsão.

A previsão hidrológica de curto prazo é comumente utilizada na operação de sistemas hidráulicos e no sistema de alerta para ocorrências de desastres naturais. Na operação de sistemas hidráulicos ela é aplicada para a previsão de vazões afluentes a um reservatório, de modo a permitir melhores decisões quanto à operação do mesmo, visando à manutenção de um volume necessário, tanto para o pleno funcionamento do reservatório, no atendimento às condições de aproveitamento hídrico (CASTA-

---

\*Instituto de Pesquisas Hidráulicas/Universidade Federal do Rio Grande do Sul

NHARO e MINE, 2001; COLLISCHON *et al.* 2005; BRAVO *et al.*, 2008a; SATARRI *et al.*, 2012), quanto para a manutenção de um volume de espera, para o controle de cheias (BRAVO *et al.*, 2008b). As previsões também podem ser usadas nos sistemas de proteção contra inundação (KOUSSIS *et al.*, 2003; RABUFFETTI e BARBERO, 2005; NAPOLITANO *et al.*, 2010; ALFIERI *et al.*, 2012), onde as previsões de níveis fluviais são utilizadas para identificação de áreas que serão, conseqüentemente, inundadas (TODINI, 1999), possibilitando que posteriormente, se necessário, sejam tomadas providências, como o fechamento de comportas, alerta de enchentes e mobilização da defesa civil. Além desses usos, a previsão de curto prazo também já foi utilizada para controle da irrigação (TUCCI *et al.*, 1987).

As sub-bacias que compõe uma bacia hidrográfica convergem para esta nos respectivos exutórios, os quais, se devidamente monitorados para a quantificação das afluições, constituem-se, para um modelo matemático de previsão que contemple propagação de vazões, em seções de controle destas afluições ao rio principal, no sentido de que todos os volumes gerados pela respectiva sub-bacia passam por esta seção. Portanto, a existência de monitoramento em uma seção fluvial estabelece uma sub-bacia controlada, a montante desta, e uma região não controlada a jusante, entre esta seção e o exutório da bacia principal. Esta região não controlada constitui, então, uma bacia de contribuição incremental às vazões propagadas a partir da referida seção de controle.

Uma vez que as vazões resultantes da bacia de contribuição incremental são de determinação mais incerta (dependendo, principalmente, das relações entre chuva e vazão), é importante reduzir esta área, estabelecendo seções que controlem maiores áreas de sub-bacias. Porém, com a redução da bacia de contribuição incremental, o horizonte de previsão também diminui, pois o tempo de propagação das vazões entre as seções de controle e o exutório principal também será menor. Portanto, uma solução de compromisso é necessária para a localização da seção de controle de afluições.

Sub-bacias sucessivamente incluídas, da menor para a maior até a bacia principal, constituem as bacias embutidas, segundo denominação adotada em Castro *et al.* (2000), Girardi *et al.* (2011) e Cardoso *et al.* (2012).

Vários tipos de modelos podem ser usados para se fazer previsão de vazões, entre eles, tradicionalmente, os modelos estocásticos (BENEDITO *et al.*, 2007) e os modelos de base física (BRUN e TUCCI, 2001).

As bacias hidrográficas são sistemas complexos, cujo funcionamento depende principalmente das condições de armazenamento de água, em suas diversas formas (retenção superficial, umidade do solo, volumes restantes nos canais e bermas fluviais), da distribuição, frequentemente desigual, das precipitações, e da evaporação. Dada esta complexidade, os modelos de redes neurais artificiais (RNA) apresentam-se como candidatos naturais para o uso em previsões hidrológicas, pois estes são definidos como aproximadores universais de relações (HORNIK *et al.*, 1989).

No trabalho de Oliveira *et al.* (2013), são apresentados resultados de simulações hidrológicas com diferentes proporções de área controlada na bacia hidrográfica com uso de RNAs. É uma consequência natural que a análise dos efeitos de sub-bacias de diferentes dimensões seja efetuada também para a previsão de curto prazo com estes modelos.

Alguns exemplos podem ser citados, como Dawson e Wilby (2001), Machado (2005) e Sousa e Sousa (2010), que utilizaram RNAs como modelos chuva-vazão para este fim. Batista (2009) realizou um estudo no Rio Grande em Minas Gerais para a previsão de vazões utilizando RNAs, produzindo resultados que podem ser utilizados em tomadas de decisões na operação de reservatórios destinados à geração de energia elétrica. Gomes *et al.* (2010) utilizaram uma rede neural de múltiplas camadas com treinamento com o algoritmo retropropagativo para a previsão de vazão, obtendo bons resultados na bacia do rio São Francisco.

Uma forma de se avaliar a importância das entradas em modelos com RNAs é através da comparação do desempenho destes com a utilização ou não das informações de cada uma delas. Em sub-bacias embutidas, o modelo para a previsão de vazões utilizando RNAs pode ser aplicado sistematicamente, da menor para a maior bacia, através da utilização, além das precipitações, de dados das afluições observadas, exclusivamente, em cada uma das respectivas seções de controle.

As séries temporais podem ter dados registrados com diferentes períodos, em minutos, horas, dias, meses, sendo que cada frequência de aquisição pode produzir resultados com diferentes desempenhos, quando aplicadas como entradas em modelos hidrológicos.

O objetivo deste trabalho é analisar o efeito do controle de montante em sub-bacias embutidas na previsão hidrológica de curto prazo, com a investigação conjunta de dois aspectos: variação da área controlada em bacias a montante e variação da fre-

quência de aquisição das vazões de entrada do modelo (dados diários e horários). O trabalho foi realizado em 3 etapas, sendo que, em todas elas, foi estimada a vazão diária em um mesmo posto (Ponte Mística), utilizando para isso, além dos dados diários de vazão deste posto: a) diferentes alternativas de postos de controle a montante, com as respectivas áreas de contribuição; b) comparação de dados diários e horários de vazão para a bacia de menor contribuição; c) investigação do uso, também, de dados de 24h e de 48h anteriores ao dia da previsão. Na sequência serão apresentados: a) breve descrição dos conceitos e as aplicações de Redes Neurais Artificiais; b) descrição dos materiais e métodos utilizados, que foi subdividida em três partes: b1) apresentação da área de estudo, b2) detalhamento dos dados hidrológicos utilizados, b3) critérios adotados para a aplicação dos modelos, descrição das alternativas testadas e estatística de avaliação do desempenho; c) discussão dos resultados e d) conclusões e recomendações.

## REDES NEURAS ARTIFICIAIS

Redes neurais artificiais são modelos matemáticos desenvolvidos com inspiração nos neurônios biológicos. São, basicamente, compostas por estruturas lógico-matemáticas que representam o funcionamento destes, chamadas de neurônios artificiais (Figura 1). Estes neurônios artificiais executam uma soma ponderada das entradas (cujos pesos são representados graficamente por conexões), a qual é submetida a uma função (dita de ativação, geralmente não linear). As operações de soma ponderada e de submissão à função de ativação ocorrem no núcleo do neurônio, que é o ponto de convergência das conexões, na representação gráfica. Os neurônios, em uma rede neural artificial, são, geralmente, dispostos em camadas, de entrada, intermediária e de saída, o que facilita a construção de algoritmos de operação e de treinamento.

Modelos com uso de RNAs necessitam ser testados com uma série diferente da série que foi usada para o treinamento, chamada de série de verificação, para que seja garantida a capacidade de generalização. Em geral, adota-se uma proporção de 60 a 70% dos dados disponíveis para o treinamento e o restante para a verificação (HECHT-NIELSEN, 1990).

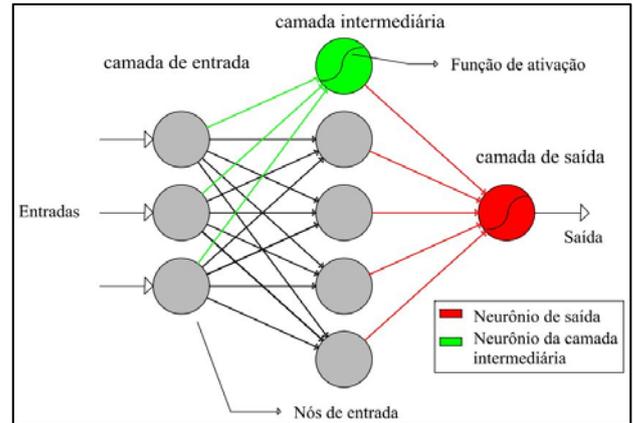


Figura 1 - Rede neural de múltiplas camadas.

Uma vez que o treinamento tende a favorecer as variáveis de maior grandeza, e que as funções de ativação utilizadas possuem domínio de saída restrito (neste trabalho, entre 0 e 1), o uso de redes neurais para a modelagem hidrológica requer alguma forma de escalonamento, tanto das entradas (para reduzi-las à mesma magnitude) como das saídas. Considerando-se as funções de escalonamento como parte do modelo, e adotando-se o escalonamento linear, o modelo completo resultante pode ser representado pela equação 1:

$$\frac{(y_t - b_u)}{a_u} = RN \left( \frac{(x_t - b_e)}{a_e} \right) \quad (1)$$

onde:

$x_t$  e  $y_t$ : Variáveis de entrada e de saída, respectivamente;

$a_u$  e  $b_u$ : Parâmetros de escala e de posição das saídas do modelo;

$a_e$  e  $b_e$ : Parâmetros de escala e de posição das entradas do modelo;

RN: Rede neural utilizada.

As redes neurais de múltiplas camadas são eficientes para aproximação de funções e possuem a capacidade de distinguir padrões complexos. Porém, inicialmente, embora seu potencial fosse sustentado por um teorema de Kolmogorov de 1957, o qual foi posteriormente enunciado para redes neurais como o teorema de Kolmogorov-Nielsen (HET-CH-NIELSEN, 1990), não existia um método para seu treinamento. Este teorema estabelece que, para qualquer função contínua com  $n$  entradas e  $m$  saídas, existe uma rede neural com apenas uma camada interna de  $2n+1$  neurônios capaz de aproximá-la.

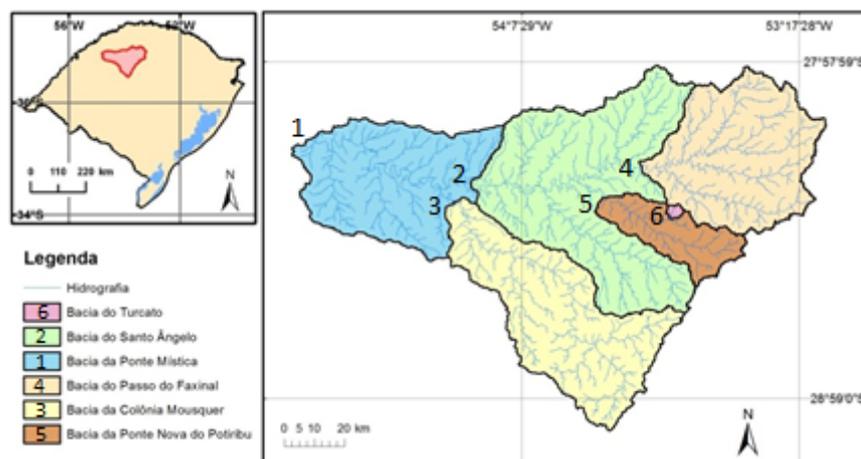


Figura 2 - Bacia da Ponte Mística e as sub-bacias embutidas (Adaptado: Oliveira *et al.*, 2012).

O uso de redes neurais disseminou-se a partir do desenvolvimento e apresentação, por Rumelhart *et al.* (1986), do algoritmo retropropagativo. Este algoritmo consiste em um método de procura dos pesos sinápticos (a partir de valores iniciais, sorteados aleatoriamente) o qual minimiza, em ciclos sucessivos de aplicação à série de registros de treinamento, a soma do quadrado dos erros em cada camada, com o uso da chamada regra delta (WIDROW e HOFF, 1960), após a determinação dos erros na(s) camada(s) intermediária(s), pela retropropagação destes a partir da camada de saída.

O método consiste de duas etapas, sendo que, na primeira, as entradas da rede são propagadas em um movimento para frente, camada por camada, até resultarem as saídas. As saídas calculadas são comparadas com as desejadas, gerando um erro. Na sequência, este erro é retropropagado, no sentido da entrada, e os pesos sinápticos da rede são ajustados conforme a regra de treinamento. A repetição deste processo fornece resultados cada vez melhores e erros cada vez menores, à medida que repetições (ciclos) do procedimento são aplicadas. O ponto de parada é pré-determinado, ou pelo número de ciclos ou por uma precisão estabelecida.

O método de treinamento retropropagativo inicia com a adoção de pesos sinápticos aleatórios iniciais. O processo de busca pode resultar em estacionamento prematuro em um ótimo local da superfície de desempenho. Para evitar esta ocorrência, pode-se executar o treinamento diversas vezes, adotando-se o conjunto de parâmetros que apresenta melhores resultados, de acordo com a recomendação de Hetch-Nielsen (1990). O número ideal de repetições em estudos de modelos hidrológicos, foi

testado por Dornelles *et al.* (2013), o qual concluiu que com 30 repetições os resultados não se alteram significativamente em relação a alternativas de uso de maior número de repetições.

O superajustamento ocorre quando o treinamento consegue reproduzir até mesmo o comportamento individual, inclusive os erros e a aleatoriedade, das amostras de treinamento, o que prejudica a capacidade de generalização. Em geral, quando os resultados da verificação são muito bons, para os propósitos desejados, pode-se admitir que o superajustamento, ou não houve, ou foi irrelevante. Caso contrário, cuidados tornam-se necessários para evitá-lo.

Os métodos para evitar o superajustamento são a limitação da complexidade da rede (com graus de liberdade suficientemente reduzidos para que não permitam a reprodução das oscilações indesejadas), e a interrupção antecipada do treinamento (uma vez que, observa-se, a forma da reprodução proporcionada pela rede evolui a partir de uma explicação nula da variância em direção a complexidades crescentes).

## MATERIAIS E MÉTODOS

### Área de Estudo

A pesquisa foi aplicada em 6 bacias hidrográficas, sendo a maior delas a bacia da Ponte Mística, que está localizada no noroeste do estado do Rio Grande do Sul, entre as coordenadas 27°58' e 29°04' de latitude Sul e 53°12' e 54°48' de longitude Oeste, com o exutório localizado no posto fluviométrico da

Ponte Mística no município de São Luiz Gonzaga, com uma área de drenagem 9450 Km<sup>2</sup>. As demais bacias, que constituem sub-bacias desta, são Santo Ângelo (5440 Km<sup>2</sup>), Colônia Mousquer (2160 Km<sup>2</sup>), Passo do Faxinal (1940 Km<sup>2</sup>), Ponte Nova do Potiribu (609 Km<sup>2</sup>) e Turcato (19,5 Km<sup>2</sup>), apresentadas na Figura 2.

### Dados Hidrológicos

Os dados pluviométricos utilizados neste estudo foram extraídos de Silva (2011). O autor utilizou o método do vizinho natural como interpolador para gerar grades de precipitações com as quais foi feito o cálculo das precipitações médias diárias para a bacia da Ponte Mística a partir de dados de 65 postos pluviométricos e pluviográficos localizados na região no período de 22/08/1989 a 31/12/2010. Os dados observados na bacia foram obtidos por aparelhos pertencentes à ANA (Agência Nacional de Águas) e por pluviômetros e pluviógrafos do projeto de monitoramento da bacia do Potiribu (CASTRO *et al.*, 2010). Nos pluviômetros pertencentes ao projeto, as leituras foram feitas diariamente às 8h da manhã, e esses valores corresponderam à precipitação acumulada nas 24h anteriores a esse horário (SILVA, 2011).

O posto fluviométrico de Ponte Mística foi definido, neste estudo, como o exutório da bacia considerada e está localizado nas coordenadas Latitude 28°10'53" e Longitude 54°44'18". Da mesma forma, os postos de Santo Ângelo, Colônia Mousquer, Ponte Nova do Potiribu, Passo do Faxinal e Turcato são os exutórios das respectivas sub-bacias. As séries históricas de vazão dos postos foram obtidas do *website* Hidroweb da ANA e de linígrafos monitorados desde 1989 (CASTRO *et al.*, 2000). Os dados fornecidos pela ANA consistem em vazões médias diárias, resultantes das médias das vazões correspondentes aos dados de níveis coletados duas vezes ao dia, às 7h e 17h. Para o posto fluviométrico da bacia do rio Turcato, foi instalado um linígrafo em seu exutório, e as vazões médias diárias foram obtidas a partir de níveis resultantes da aquisição automática em intervalos de 15 minutos, e da aplicação da curva-chave, com a leitura que corresponde a 1 dia iniciando-se às 9h do dia *t* e tendo como tempo final as 8h da manhã do dia seguinte. Também foram utilizadas vazões horárias para este posto, coincidentes com o mesmo intervalo temporal.

As médias de vazões, entre 7h e 17h, para um dia à frente (dia *t+1*), no exutório de Ponte

Mística, foram os objetos das previsões. Como entradas nos modelos de previsão foram utilizados os dados de precipitações diárias, acumuladas entre 9h (dia *t*) e 8h (dia *t+1*); vazões diárias dos postos da ANA (dia *t*); vazões diárias do posto do Turcato; e vazões horárias do posto do Turcato. Portanto, o horizonte de informações (limite temporal para as entradas dos modelos) estende-se, para chuvas médias na bacia de Ponte Mística e para vazões do Turcato, até às 8 horas do próprio dia da previsão (dia *t+1*). Assim sendo, este horário corresponde, a cada dia, ao tempo atual, a partir do qual inicia o horizonte de previsão. A Figura 3 ilustra os limites temporais utilizados na previsão.

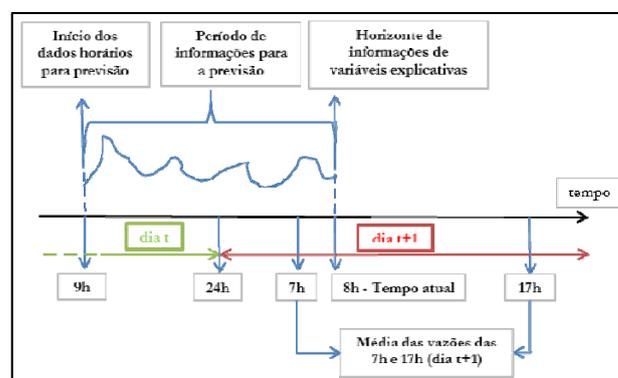


Figura 3 - Limites temporais utilizados na previsão.

Para este estudo foi escolhido o período com maior quantidade de dados concomitantes em todos os postos: de 22/08/1989 à 01/06/1994 (1.408 dias).

### Métodos

Foram desenvolvidos modelos com nove alternativas de controle de montante, sendo seis delas com controles individuais, duas com controle simultâneo de dois postos e uma com dados horários da menor bacia, utilizando dados diários de precipitação média (*P*) da bacia da Ponte Mística e vazão (*Q*) das sub-bacias, para prever a vazão na Ponte Mística. Estas alternativas são descritas abaixo e resumidas na Tabela 1:

1. Alternativa 1: Utiliza apenas dados de precipitação e da vazão da maior bacia (Ponte Mística). Sem contribuições de Vazão das bacias de montante;

2. Alternativa 2: Utiliza dados de precipitação, vazão da Ponte Mística e vazão de Santo Ângelo (Contribuições de montante no posto de Santo Ângelo)
3. Alternativa 3: Utiliza dados de precipitação, vazão da Ponte Mística e vazão de Colônia Mousquer (contribuições de montante no posto de Colônia Mousquer);
4. Alternativa 4: Utiliza dados de precipitação, vazão da Ponte Mística e vazão de Passo do Faxinal (contribuições de montante no Passo do Faxinal);
5. Alternativa 5: Utiliza dados de precipitação, vazão da Ponte Mística e vazão do Potiribu (contribuições de montante no posto de Potiribu);
6. Alternativa 6: Utiliza dados de precipitação, vazão da Ponte Mística e vazão diária do Turcato (contribuições de montante no posto de Turcato);
7. Alternativa 7: Utiliza dados de precipitação, vazão da Ponte Mística, vazão da Colônia Mousquer e vazão de Santo Ângelo (contribuições de montante dos postos de Colônia Mousquer e de Santo Ângelo);
8. Alternativa 8: Utiliza dados de precipitação, vazão da Ponte Mística, vazão de Passo do Faxinal e vazão do Potiribu (contribuições de montante dos postos de Passo do Faxinal e do Potiribu);
9. Alternativa 9: Utiliza dados de precipitação, vazão da Ponte Mística, vazão diária do Turcato e vazão horária do Turcato (contribuição de montante do posto do Turcato, considerando dados diários e dados horários).

Embora tenham sido utilizadas diferentes entradas para cada uma das alternativas de controle de montante, sempre uma mesma saída, o posto fluviométrico de Ponte Mística, foi empregado para a previsão de vazão de um dia à frente (dia  $t+1$ ). As entradas são os dados de precipitação média e de vazão da bacia da Ponte Mística, além dos dados de vazões das sub-bacias, as quais funcionam como controle de montante, conforme esquematizado na Tabela 1. Não foram consideradas as precipitações de dias anteriores, pois uma análise preliminar demonstrou que não houve ganho de desempenho com o uso de RNAs.

As alternativas foram escolhidas de modo a representar as diferentes proporções de área controlada por bacias de montante (de 0% a 78,63%).

Desta forma, a alternativa 1 representa uma situação sem área de montante controlada. As alternativas 2 a 6 representam o acréscimo, em cada alternativa, de uma bacia de montante controlada, com diferentes áreas de contribuição. As alternativas 7 e 8 representam situações com a combinação de duas bacias de montante controladas contíguas (formando uma pequena região hidrográfica), sendo a alternativa 7 com uma área de 78,63% de área controlada, e a 8 de 27,8% de área controlada.

A alternativa 9 corresponde a uma variação da alternativa 6, com o acréscimo dos dados de vazões horárias da sub-bacia do Turcato. Foram inseridas, nessa alternativa, como entradas na rede neural, 24 dados de vazão correspondentes a cada hora das últimas 24 horas antes do horizonte de informações do dia, além dos dados diários de chuva e vazão. A comparação entre as duas alternativas permite investigar se a utilização de vazões com um maior detalhamento temporal pode produzir melhores resultados.

Foram aplicadas, para cada uma das alternativas, entradas constituídas das vazões dos dias anteriores, para avaliar sua influência na previsão de vazão. A avaliação aproximada de até quantos dias anteriores contribuiriam para a melhora do modelo foi feita por análise de correlogramas entre as séries de vazão do exutório em Ponte Mística e de cada uma das alternativas de controle, com defasagem máxima de 10 dias. Uma vez que o modelo de redes neurais artificiais pode aproximar funções não lineares, o uso de correlações lineares pode estar negligenciando outras possibilidades de entradas, para o modelo. Porém, o uso de correlogramas foi adotado como critério, tendo-se em conta os objetivos propostos para a pesquisa.

As entradas de dias anteriores são inseridas como séries de dados de vazão ocorridas um dia antes (dia  $t-1$ ), no caso de ser considerada a influência de até 24 horas antes, e de um e dois dias antes (dias  $t-1$  e  $t-2$ ), no caso de ser considerada a influência das 48 horas anteriores, e assim por diante.

As séries de dados das bacias analisadas apresentam alguns períodos com falhas, podendo existir, para um mesmo dia, falha em uma série e informação em outra. Assim, os dias com falha em pelo menos uma das séries de entrada foram eliminados, sendo considerados como registros apenas os dias onde existem informações em todas as séries de entrada para a alternativa de modelo considerada.

Tabela 1 - Alternativas de entradas das redes neurais usadas como controle para estimativa da vazão na Ponte Mística.

Alternativas	1	2	3	4	5	6	7	8	9	Área (km <sup>2</sup> )	% da área controlada
Q Ponte Mística (t)	■	■	■	■	■	■	■	■	■	9.450	-
Q Santo Ângelo (t)		■					■			5.540	58,6
Q Colônia Mousquer (t)			■				■			2.160	22,9
Q Passo do Faxinal (t)				■				■		1.940	20,5
Q Potiribu (t)					■					690	7,3
Q Turcato diário (t)						■			■	19,5	0,2
Q Turcato horário (t)									■	19,5	0,2
P Ponte Mística (t)	■	■	■	■	■	■	■	■	■	9.450	-

O tipo de redes neurais utilizado neste estudo foi a rede de múltiplas camadas com treinamento pelo algoritmo retropropagativo. Foi utilizada apenas uma camada interna na rede neural, composta por cinco neurônios. Este número de neurônios foi escolhido para atender à recomendação do teorema de Kolmogorov-Nielsen para o modelo mais simples (somente duas entradas – alternativa 1), porém mantendo o mesmo número de neurônios para todas as alternativas e um mínimo de complexidade para evitar o superajustamento.

Funções de ativação do tipo sigmoidal (equação 2), foram utilizadas para todos os neurônios, tanto internos quanto de saída. Os dados de entrada e de saída foram escalonados linearmente para resultarem no intervalo [0 1].

$$a = \frac{1}{1+e^{-n}} \quad (2)$$

onde:

a: é a saída da função de ativação;

n: é a entrada líquida, que consiste na soma ponderada das entradas.

O treinamento da rede neural foi realizado com a utilização de uma rotina própria para o algoritmo retropropagativo. Com base no trabalho de Dornelles *et al.* (2013) que recomenda pelo menos 30 repetições de treinamento, optou-se pela execução de 50 repetições, guardando o melhor resultado, com o objetivo de minimizar os efeitos causados pela aleatoriedade das condições iniciais.

A série de dados foi dividida em duas partes, sendo 65% dos registros utilizados no treinamento da rede neural e os 35% restantes utilizados na verificação. Nesse estudo optou-se pela não utilização da técnica de validação cruzada, que é usada para evitar o superajustamento da rede neural, uma vez que as séries de dados não são muito extensas e o seu particionamento em um conjunto para a validação iria

reduzir ainda mais a quantidade de dados disponível para o treinamento. Assim, para evitar o superajustamento, foi feita a experimentação sistemática com número crescente de ciclos de treinamento, buscando-se aquele que apresentasse melhores resultados, através da avaliação da série de verificação, para todas as alternativas de controle de montante. A ideia é que se, a partir de um certo número de ciclos, a verificação sofresse redução de desempenho, este número de ciclos seria o limite para o treinamento sem o superajustamento. Foram realizadas simulações com variações de 5 mil ciclos, até chegar a 120 mil.

Para a análise do desempenho da rede foi aplicado como estatística de qualidade o coeficiente de Nash-Sutcliffe (NS), o qual representa a proporção da variância dos dados explicada pelo modelo (equação 3).

$$NS = \frac{\sum_{i=1}^N (Q_{oi} - Q_{pi})^2}{\sum_{i=1}^N (Q_{oi} - Q_o)^2} \quad (3)$$

onde:

$Q_{oi}$ : é o valor observado;

$Q_{pi}$ : é o valor estimado pelo modelo;

$Q_o$ : é o valor médio dos valores observados no período da verificação;

N: é o número de valores do conjunto de verificação.

## RESULTADOS E DISCUSSÕES

Os resultados dos correlogramas são apresentados na Tabela 2. Foi adotado como critério para escolha do número de componentes, a ocorrência de correlações maiores que 0,60.

Os resultados da eficiência dos modelos de RNAs são apresentados na Tabela 3, com as nove

**Tabela 2 - Resultados dos autocorrelogramas (Ponte Mística com Ponte Mística) e dos intercorrelogramas (Ponte Mística com postos de controle de montante).**

Defasagens (dias)	Ponte Mística	Colônia Mousquer	Santo Ângelo	Passo do Faxinal	Potiribu	Turcato
1	0,90	0,87	0,92	0,87	0,85	0,62
2	0,71	0,73	0,79	0,81	0,77	0,67
3	0,51	0,55	0,59	0,59	0,59	0,39
4	0,35	0,38	0,42	0,45	0,42	0,18
5	0,26	0,27	0,31	0,32	0,29	0,14
6	0,21	0,19	0,24	0,24	0,22	0,11
7	0,18	0,15	0,19	0,19	0,18	0,09
8	0,15	0,12	0,16	0,15	0,14	0,08
9	0,13	0,10	0,13	0,13	0,11	0,06
10	0,12	0,09	0,10	0,10	0,08	0,03

**Tabela 3 - Entradas da rede, proporção de área controlada (%), número de registros e ciclos e estatísticas de desempenho da RNA na previsão de vazão.**

Alternativas	% de área controlada	Somente dia atual (t)			+ dados do dia t-1			+ dados dos dias t-1 e t-2		
		Nº de registros	Nº de Ciclos	NS	Nº de registros	Nº de Ciclos	NS	Nº de registros	Nº de Ciclos	NS
1	-	1.408	10.000	0,93	1.407	15.000	0,94	1.406	15.000	0,94
2	58,62	1.408	15.000	0,97	1.407	15.000	0,97	1.406	25.000	0,97
3	22,9	1.408	10.000	0,95	1.407	15.000	0,96	1.406	20.000	0,95
4	20,5	1.135	20.000	0,94	1.133	15.000	0,95	1.131	20.000	0,94
5	6,5	1.408	10.000	0,94	1.407	40.000	0,96	1.406	20.000	0,96
6	0,2	523	80.000	0,91	304	75.000	0,91	304	15.000	0,94
7	58,6 e 22,9	1.408	15.000	0,97	1.407	10.000	0,97	1.406	35.000	0,97
8	20,5 e 7,3	1.135	15.000	0,94	1.133	15.000	0,95	1.131	45.000	0,94
9	0,2	470	15.000	0,89	-	-	-	-	-	-

alternativas de modelos, com as respectivas áreas controladas, número de registros (número de dias com informações completas) e ciclos utilizados, bem como as estatísticas correspondentes. O melhor modelo foi escolhido em função do coeficiente NS.

Os melhores resultados para cada alternativa de controle de montante foram encontrados com diferentes números de ciclos. O número de ciclos que proporcionou o melhor ajuste faz parte do procedimento de treinamento, e não é uma característica estrutural da rede neural, tendo sido esgotados os esforços, em termos de número de ciclos, para o treinamento de cada modelo.

Foram encontradas, para todas as alternativas de controle de montante, bons coeficientes Nash-Sutcliffe, tendo-se em conta alguns autores (COULIBALY *et al.*, 2000), para os quais são consi-

derados bons os resultados NS acima de 0,70. Os melhores resultados foram encontrados com as alternativas 2 e 7, com NS de 0,97, apresentando o mesmo resultado com e sem valores defasados de vazão. Portanto, foi selecionado o modelo com menor número de parâmetros, que é o previsto com dados de vazão somente no dia t. Estes resultados demonstram a eficiência dos modelos apresentados para prever vazões de curto prazo, podendo estes modelos servirem de base para a elaboração de sistemas de alertas de enchentes para a região.

Os piores resultados foram obtidos para as alternativas 6 e 9, com NS de 0,91 e 0,89, respectivamente, onde foram utilizados dados da bacia de menor área (Turcato). A quantidade de registros válidos disponíveis para cada uma das alternativas de modelo foi diferente, pois cada série apresenta um

padrão específico de falhas. Assim, as entradas da rede neural das alternativas 6 e 9, que apresentaram os menores coeficientes NS, contaram com apenas 523 e 470 registros, respectivamente, menos que a metade das demais. Uma vez que os registros válidos são em menor quantidade que os das outras alternativas (as quais possuem número de registros bastante semelhantes entre si), a comparação, em termos absolutos, entre as alternativas 6 e 9 e as demais, fica prejudicada, porque as séries utilizadas podem ter magnitude dos dados diferentes. Portanto, as alternativas 6 e 9 devem ser comparadas entre si, mas não com as demais. A utilização de dados horários (alternativa 9), ao contrário do esperado (devido à maior quantidade de informações), produziu um resultado pior do coeficiente NS. Uma explicação para isso pode ser devido ao fato que ao serem consideradas as vazões horárias, o dado é naquela hora discreta, não considerando as flutuações entre as leituras, o que pode causar perda de informações para bacias da magnitude do Turcato. Ao contrário, os dados diários são resultantes da integração das vazões em 24 horas com intervalo discreto de registro a cada 15 minutos, com menor perda de informações. Possivelmente por este motivo, os dados horários não contribuíram para melhoria da eficiência do modelo, causando até mesmo uma redução nesta.

Cruz *et al.* (2010) utilizaram previsão de vazão de curto prazo com RNAs, encontrando coeficientes NS variando de 0,14 à 0,80 para a bacia do rio das Velhas e de 0,23 à 0,78 para a bacia do rio Abaeté. Kumar *et al.* (2005) utilizaram RNAs na previsão de vazão na bacia do rio Malaprabha (Índia), encontrando coeficientes NS variando entre 0,80 e 0,94. Para o sistema hidrológico Chute-du-Diable no norte de Quebec (Canadá), Coulibaly *et al.* (2000) utilizaram diferentes modelos de previsão de vazão, com redes neurais apresentando coeficientes NS entre 0,92 e 0,99 para a previsão de um dia à frente.

A utilização de componentes com 24h de antecedência apresentou melhores resultados em cinco das oito alternativas de controle (alternativa 1, 3, 4, 5 e 8). Já a utilização das componentes com 24h e 48h de antecedência apresentou uma melhora apenas na alternativa 6 (0,94). Isto confirma a ideia de que as vazões dos dias anteriores das bacias contribuintes são, em alguns casos, importantes para a previsão das vazões no exutório. É possível que, pela maior distância da menor bacia (Turcato) ao exutório, as vazões demorem mais tempo para completar o percurso, fazendo com que as vazões de dois dias (dia  $t-2$ ) atrás constituam, neste caso, contribuição

adicional às do tempo atual (dia  $t$ ) e de um dia atrás (dia  $t-1$ ).

Conforme os resultados apresentados, tomando-se como base a alternativa 1, onde o único controle seria no próprio exutório (Ponte Mística), e comparando-se com as demais alternativas de controle, que contemplam as sub-bacias embutidas no seu interior, com áreas controladas entre 0,2% e 58,6%, as alternativas de utilização de postos de montante apresentaram melhores resultados.

A utilização dos dados de vazão referentes à bacia de Passo do Faxinal, juntamente com a bacia do Potiribu (alternativa 8), quando comparadas com quando se utilizou apenas os dados de vazão da bacia do Potiribu (alternativa 5), não produziu uma melhora nos resultados. Igualmente, os resultados do modelo não melhoraram, quando se comparou o uso de dados da bacia de Santo Ângelo (alternativa 2) com o uso simultâneo, além destes, dos dados da bacia de Colônia Mousquer (alternativa 7). Isso ocorre porque, às vezes, uma sub-bacia menor, neste caso, Potiribu (alternativa 5) e Santo Ângelo (alternativa 2), é bem representativa, possuindo informações que são proporcionais às da área maior. A presença de variáveis de estado redundantes pode reduzir a eficiência do modelo, pois os pesos sinápticos internos são influenciados por todas as entradas e uma variável desnecessária pode dificultar o procedimento de treinamento, prejudicando a representatividade dos fenômenos modelados.

A Figura 4 apresenta uma relação entre as proporções das áreas das sub-bacias embutidas (áreas controladas) em relação à área total da bacia de Ponte Mística e os coeficientes de eficiência NS encontrados nas alternativas de controle de montante. Para esta análise não foram considerados os resultados dos modelos que utilizaram valores defasados das entradas, porque as séries de dados utilizadas em cada uma delas são diferentes para cada uma das alternativas, assim para algumas as informações dos dias anteriores são importantes e para outros não. Também não foram consideradas as alternativas que possuem controle simultâneo de dois postos, pois não se podem considerar duas áreas controladas diferentes como sendo uma única.

Verificou-se a tendência de que, quando se utiliza, no modelo de previsão para vazões diárias para um dia à frente, as vazões de bacias a montante além das vazões do próprio posto, como dados de entrada, o modelo consegue uma eficiência que aumenta com a proporção de área controlada.

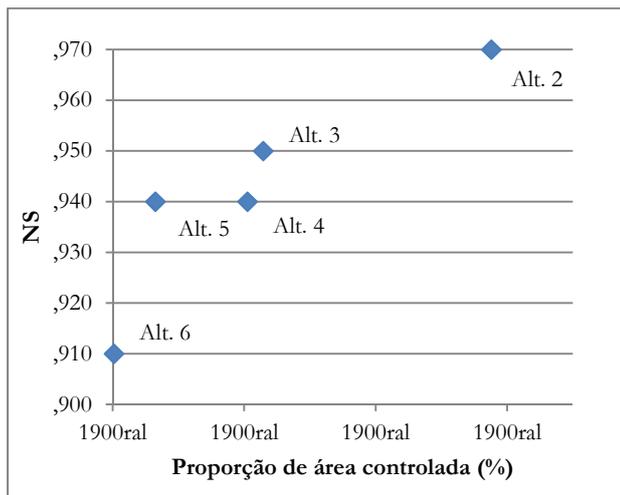


Figura 4 - Proporção de área controlada das bacias de montante e a eficiência do modelo.

A melhora da eficiência do modelo quando se considera vazões diárias de bacias de controle a montante, deve-se ao fato de que ao considerarmos estes dados de vazão a montante, são adicionadas informações hidrológicas muito importantes, cujos efeitos estão integrados nestas vazões, como precipitação, evapotranspiração e umidade do solo. Quanto maior é a proporção de área controlada, menor é a área com informação apenas das precipitações, portanto, melhor é a eficiência do modelo.

## CONCLUSÕES E RECOMENDAÇÕES

A aplicação das redes neurais artificiais para a previsão de curto prazo, com um dia à frente no exutório da bacia da Ponte Mística, permitiu a elaboração das seguintes conclusões:

- A utilização das redes neurais artificiais na previsão de vazão com uso de bacias embutidas se mostrou bastante eficiente se levarmos em conta as estatísticas de desempenho da rede, com coeficientes NS variando entre 0,89 e 0,97;
- Na aplicação do modelo com a utilização de valores defasados das entradas, os resultados apresentaram uma melhora em cinco das oito alternativas de controle de montante (alternativas 1, 3, 4, 5 e 8), com a utilização das chuvas com 24 h de antecedência (t-1), enquanto que, para as demais, os resultados

se mantiveram os mesmos. A introdução de informações de vazão média diária com 48 h de antecedência produziu melhora apenas para a alternativa 6 (de 0,91 para 0,94).

- Os resultados comprovam que, ao contrário do esperado, a utilização de dados com um maior detalhamento temporal (dados horários) não melhoraram o modelo, visto que, para o modelo no qual foram utilizadas vazões horárias do posto fluviométrico do Turcato o coeficiente de NS sofreu uma pequena redução, de 0,91 para 0,89, quando comparado com a alternativa de controle que utiliza apenas dados diários. Isto pode ser devido ao fato de que as vazões médias diárias, neste caso, sendo resultantes da integração de vazões com intervalo de 15 minutos, contém mais informações que as séries horárias, pois estas últimas são valores obtidos a cada hora, sem considerar as flutuações ocorridas no intervalo;
- Quanto à variação da área controlada, os resultados mostram que, conforme aumenta essa área, a eficiência do modelo tende a melhorar. Os melhores resultados foram encontrado nas alternativas 2 (Santo Ângelo) e 7 (Santo Ângelo e Colônia Mousquer), com NS de 0,97;
- Quando foram adicionadas informações de duas sub-bacias, alternativa 7 (Santo Ângelo e Colônia Mousquer) e 8 (Potiribu e Passo do Faxinal), não houve aumento da eficiência dos modelos se comparados com os modelos mais simples das alternativas 2 (Santo Ângelo) e 5 (Potiribu).
- Recomenda-se para trabalhos futuros a adoção de outros critérios para a escolha das variáveis de entrada, em termos do número de defasagens correspondentes, além de considerar como entradas e saídas dados discretos às 07 e às 17 horas, para previsões pois são os horários de leitura dos níveis de régua adotados pela ANA.

## AGRADECIMENTOS

À CAPES pela bolsa de estudos do 1º autor.  
À FINEP pelo financiamento do projeto de pesquisa que produziu boa parte dos dados.

## REFERÊNCIAS

- ALFIERI, L.; SALAMON, P.; PAPPENBERGER, F.; WETTERHALL, F. Operational Early Warning Systems for Water-Related Hazards in Europe. *Environmental Science & Policy*, v.21, p.35-49, 2012.
- BATISTA, A. L. F. Modelos de Séries Temporais e Redes Neurais Artificiais na Previsão de Vazão. Dissertação (mestrado) – Programa de Pós-graduação em Engenharia de Sistemas da UFLA, Lavras/MG, 79p. 2009.
- BENEDITO, C. S.; COLLISCHONN, W.; TUCCI, C. E. M.; CLARKE, R. T.; CORBO, M. D. Previsão Hidroclimática de Vazão de Curto Prazo na Bacia do Rio São Francisco. *Revista Brasileira de Recursos Hídricos*, v.12, n.3, p.31-41, 2007.
- BRAVO, J. M.; UVO, C. B.; PEDROLLO, O. C.; COLLISCHONN, W.; PAZ, A. R. Previsões de curto prazo de vazão afluente ao reservatório de Furnas utilizando redes neurais artificiais. *Revista Brasileira de Recursos Hídricos*, v.13, n.2, p.77-88, 2008a.
- BRAVO, J. M.; COLLISCHONN, W.; TUCCI, C. E. M.; PILAR, J. V.; SILVA, B. C. Avaliação dos Benefícios de Previsão de Vazão na Operação de Reservatórios. *Revista Brasileira de Recursos Hídricos*, v.13 n.1, p.197-213, 2008b.
- BRUN, G. W.; TUCCI, C. E. M. Previsão em Tempo Real do Volume Afluente ao Reservatório de Ernestina. *Revista Brasileira de Recursos Hídricos*, Porto Alegre, v.6, n.2, p.73-80, 2001.
- CARDOSO, A. T.; GIGLIO, J. N.; KOBAYAMA, M.; GRISON, F. Morfometria de bacias embutidas na gestão de bacias hidrográficas do Rio Negrinho-S.C. In: VII Simpósio de Engenharia ambiental. Anais. UNESC ASBCA. Criciúma. 2012.
- CASTANHARO, G.; MINE, M. R. M. Operação de reservatórios baseada em previsão de afluência de curto prazo em tempo real. In: XIV Simpósio Brasileiro de Recursos Hídricos e V Simpósio de Hidráulica dos países de língua oficial portuguesa, Aracaju. Livro de resumos. Porto Alegre : ABRH. v.1. p.284-284, 2001.
- CASTRO, N. M.; CHEVALLIER, P.; GOLDENFUM, J. Projeto Potiribu, Atualização 1989-1998 – Dados Básicos de Fluviometria e Pluviometria (com anexos). Instituto de Pesquisas Hidráulicas da UFRGS, *Revista de Recursos Hídricos*, Vol.35, 2000.
- CASTRO, N. M.; PINHEIRO, A.; FERNANDES, C.; PAIVA, E.; MERTEN, G.; MINELLA, J.; PAIVA, J.; GOLDENFUM, J.; SILVA, M.; GASTALDINI, M.; BRAGA, S. Rede de Pesquisa em Bacias Representativas e Experimentais no Bioma da Mata Atlântica, na Região Sul do Brasil: Relatório Final das Atividades Desenvolvidas de Março de 2007 à Maio de 2010. Universidade Federal do Rio Grande do Sul, 316p. 2010.
- COLLISCHONN, W.; HAAS, R.; ANDREOLLI, I.; TUCCI, C. E. M. Flow forecasts for river Uruguay using rainfall forecasts by a regional weather prediction model. *Journal of Hydrology*. Amsterdam, v.3005, p.87-98, 2005.
- COULIBALY, P.; ANCTIL, F.; BOBÉE, B. Daily Reservoir Inflow Forecasting Using Artificial Neural Networks With Stopped training Approach. *Journal of Hydrology*, v. 230, p.244-257, 2000.
- CRUZ, M. F. M.; RODRIGUES, L. D.; VERSIANI, B. R. Previsão de Vazões com a Metodologia DPFT e com Redes Neurais Artificiais. *Revista Brasileira de Recursos Hídricos*, v.15, n.1, p.121-132, 2010.
- DAWSON, C. W.; WILBY, R. L. Hydrological Modelling Using Artificial Neural Network. *Progress in Physical Geography*. v.25, p.80-108, 2001.
- DORNELLES, F.; GOLDENFUM, J. A.; PEDROLLO, O. Artificial neural network methods applied to forecasting river levels. *RBRH: Revista Brasileira de Recursos Hídricos*. Aceito para publicação no Vol. 18 n° 4, outubro/dezembro/ 2013.
- GIRARDI, R. V.; CASTRO, N. M. R.; GOLDENFUM, J. A.; SILVEIRA, A. L. L.; PINHEIRO, A. Avaliação do efeito de escala em características de chuva e vazão em sub bacias embutidas da bacia do Potiribu-RS. *Revista Brasileira de Recursos Hídricos*, v.16, N.2, p.49-64, 2011.
- GOMES, L. F. C.; MONTENEGRO, S. M. G. L.; VALENCA, M. J. S. Modelo Baseado na Técnica de Redes Neurais para Previsão de Vazões na Bacia do Rio São Francisco. *Revista Brasileira de Recursos Hídricos*, v.15, p.5-15, 2010.

- HECHT-NIELSEN, R. Neurocomputing. Addison-Wesley Publishing Co., New York, 433p. 1990.
- KOUSSIS, A. D.; LAGOUVARDOS, K.; MAZI, K.; KOTRONI, V.; SITZMANN, D.; LANG, J.; ZAISS, H. BUZZI, A.; MALGUZZI, P. Flood Forecasts for Urban Basin with Integrated Hydro-Meteorological Model. Journal of Hydrologic Engineering, v. 8, n.1, 2003.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H.. 1989. Multilayer feedforward networks are universal approximators. Neural networks, v. 2, n. 5, p. 359-366.
- KUMAR, A. R. S.; SUDHEER, K. P.; JAIN, S. K.; AGARWAL, P. K. Rainfall-Runoff Modelling Using Artificial Neural Networks: Comparison of Network Types. Hydrological Processes, n.19, p.1277-1291, 2005.
- LETTENMAIER, D. P.; WOOD, E. F. Hydrologic Forecasting. In: MAIDMENT, D. R. Handbook of Hydrology. Ed. McGraw-Hill, p.26.1-26.30, 1993.
- MACHADO, F. W. Modelagem Chuva-Vazão Mensal Utilizando Redes Neurais Artificiais. Dissertação (mestrado) – Programa de Pós-graduação em Engenharia de Recursos Hídricos e Ambiental da UFPR, Curitiba/PR, 128p. 2005.
- NAPOLITANO, G.; SEE, L.; CALVO, B.; SAVI, F.; HEPPESTALL, A. A Conceptual and Neural Network Model for Real-Time Flood Forecasting of the Tiber River in Rome. Physics and Chemistry of the Earth. Parts A/B/C. v.35, p.187-194, 2010.
- OLIVEIRA, G. G.; PEDROLLO, O. C.; CASTRO, N. M. R. Metodologia de Análise de Sensibilidade e Exclusão de Variáveis de Entrada em Simulação Hidrológica por Redes Neurais Artificiais (RNAs): Resultados Preliminares. XIX Simpósio Brasileiro de recursos Hídricos. Maceió. Anais [recurso eletrônico], 2011.
- OLIVEIRA, G., PEDROLLO, O. C., CASTRO, N. M. R., BRAVO, J. M. Simulações hidrológicas com diferentes proporções de área controlada na bacia hidrográfica. RBRH: Revista Brasileira de Recursos Hídricos. Aceito para publicação n° Vol. 18, n.3 (jul/set), 2013.
- RABUFFETTI, D.; BARBERO, S. Operational Hydro-Meteorological Warning and Real-Time Flood Forecasting: The Piemonte Region Case Study. Hydrology and Earth System Sciences, v.9, n.4, p.457-466, 2005.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning Internal Representations by Error Propagation. In: RUMELHART, D. E.; MCCLELLAND, J. L. Parallel Distributed Processing: Explorations in the Microstructure of Cognition. v.1, p.318–362, MIT press, Cambridge, 1986.
- SATARRI, M. T.; YUREKLI, K.; PAL, M. Performance Evaluation of Artificial Network Approaches in forecasting reservoir inflow. Applied Mathematical Modelling. v.36, p.2649-2657, 2012.
- SILVA, V. S. V. Estimativa de Precipitação Pontual em Diferentes Escalas para Uso em Modelo Concentrado Chuva-Vazão. Dissertação (Mestrado), Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS, 2011.
- SOUSA, W. S.; SOUSA, F. A. S. Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó. Revista Brasileira de Engenharia Agrícola e Ambiental, v.14, p.173-180, 2010.
- TODINI, E. An Operational Decision Support System for Flood Risk Mapping, Forecasting and Management. Urban Water, p.131-143, 1999.
- TUCCI, C. E. M.; VILANUEVA, A.; BERTONI, J. C. Previsão de vazão para irrigação. VII Simpósio Brasileiro de Recursos Hídricos, São Paulo. Livro de resumos São Paulo : ABRH. v.1. p. 536-549, 1987.
- WIDROW, B.; HOFF, M. E. Adaptive switching circuits. IRE WESCON Convention Record, New York: IRE Part 4, pp. 96-104. 1960.

***Effect Of Upstream Control Of Entrenched Sub-Basins In Short-Term Meteorological Forecasting With Neural Networks: Application To The Ponte Mística Basin***

**ABSTRACT**

*In this study, the effect of upstream control of two entrenched sub-basins on the short-term hydrological forecast, with the joint investigation of two aspects: variation of the area controlled and variation of the frequency of acquisition of model inflows. The site chosen for this study*

was the portion of the Ijuí river basin with its outflow at the rivergaging station of Ponte Mística, and its entrenched sub-basins in Santo Angelo, Ponte Nova do Potiribu, Colônia Mousquer, Passo do Faxinal and Turcato. The flow data used were obtained from the National Water Agency (ANA-Agência Nacional de Águas) and from the Potiribu Basin monitoring project, while the data on precipitation were obtained through a historical series of mean precipitations from a grid of interpolated rainfalls based on the data from 65 raingaging stations in the region. For this study, data from August 22, 1989 to June 1, 1994 (1,408 days) were used. This period was selected because it is the longest period with concomitant data at all rivergaging stations. The models chosen for this study were the multiple-layer artificial neural networks, using the retropropagation algorithm. The inputs to the models were the mean precipitation data and the daily mean flows of the Ponte Mística basin and their sub-basins, and the outflows were the daily mean flows of Ponte Mística one day ahead. Nine alternatives of upstream physical control were presented. Also, for each of the alternatives, lagged values of the variables were applied using the flow data 24h and 48h in advance. The use of hourly flows from Turcato was compared to an alternative that covers the same station, but with daily data to investigate whether the use of data with greater details regarding time can produce better results. The Nash – Sutcliffe (NS) coefficient was applied as quality statistics to analyze the network performance. Statistical evaluation presented good results in the flow forecast for all alternatives of control, and the smallest NS was 0.91 and the biggest 0.97. The use of greater time details, applying hourly flows, caused a reduction in model performance, with the NS dropping from 0.91 to 0.89. It was also observed that the larger the controlled area of the basins, the better the flow forecasting results.

**Key-words:** Hydrological forecasting, neural networks.