

Simulações Hidrológicas com Diferentes Proporções de Área Controlada na Bacia Hidrográfica

Guilherme Garcia de Oliveira*; Olavo Correa Pedrollo*; Nilza Maria dos Reis Castro*; Juan Martín Bravo*
 g.g.oliveira10@gmail.com; olavopedrollo@gmail.com; nilza@iph.ufrgs.br; jumabra@iph.ufrgs.br

Recebido: 21/11/12 - revisado: 15/02/13 - aceito: 07/06/13

RESUMO

Este trabalho tem como hipótese que é possível identificar um padrão de aumento no desempenho esperado das simulações de vazão diária com redes neurais artificiais (RNAs) à medida que aumenta a proporção de área controlada, isto é, a área da bacia até o ponto de monitoramento à montante dividida pela área total da bacia simulada. O objetivo deste estudo é avaliar o desempenho de simulações hidrológicas com RNAs, do tipo vazão-vazão, em bacias hidrográficas com diferentes proporções de área controlada. Oitenta e três simulações foram realizadas em 15 bacias embutidas (967 km² - 71.401 km²) na Região Hidrográfica do Guaíba, RS, Brasil. O desempenho das RNAs foi bastante satisfatório, com coeficiente de Nash-Sutcliffe (NS) médio de 0,75 para 35,5% de área controlada média, e apresentou um crescimento que segue uma equação potencial à medida que aumenta a proporção de área controlada. Adotando-se um limiar razoável (NS > 0,8), pode-se afirmar que o modelo do tipo vazão-vazão com RNAs é recomendado quando atendida a condição de pelo menos 50% de área controlada. Ainda que os resultados obtidos se refiram a bacias com características semelhantes às simuladas neste estudo, este limiar pode ser adotado como referência em estudos de dimensionamento de redes hidrométricas, considerando as necessidades de extrapolação em locais sem postos fluviométricos e de preenchimento de falhas nas séries temporais dos postos existentes.

Palavras-chave: Bacias hidrográficas embutidas. Redes neurais artificiais. Modelagem hidrológica. Vazão diária.

INTRODUÇÃO

O surgimento das redes neurais artificiais (RNAs) e o crescente desenvolvimento tecnológico em computação têm proporcionado resultados promissores na modelagem hidrológica (JAIN; SUDHEE; SRINIVASULU, 2004). As RNAs têm se mostrado eficientes para modelar os complexos fenômenos observados na natureza, destacando-se a sua aplicação no desenvolvimento de modelos para simulação, previsão e classificação.

A criação das RNAs está ligada à publicação de McCulloch e Pitts (1943) com inspiração puramente biológica. A rede possuía apenas capacidade de representar, embora de forma semelhante aos neurônios biológicos, funções lógicas simples. Portanto, somente com o algoritmo retropropagativo, desenvolvido por Rumelhart, Hinton e Williams (1986), é que as RNAs passaram a ser difundidas e receber investimentos em pesquisa de forma contí-

nua e crescente. O algoritmo retropropagativo é uma generalização, aplicada às redes multicamadas, da Regra Delta, criada por Widrow e Hoff (1960). A atualização dos pesos de um neurônio depende apenas dos erros, das entradas e da derivada do próprio neurônio. Os erros da camada oculta de neurônios são calculados a partir dos erros da camada de neurônios de saída.

Atualmente, diversas pesquisas obtiveram excelentes resultados com a aplicação de RNAs, às quais são apresentadas como importantes ferramentas de modelagem, capazes de resolver complexos problemas em recursos hídricos e hidrologia (ASCE, 2000a,b). Shamseldin (1997) utilizou RNAs em simulações hidrológicas do tipo chuva-vazão em seis bacias hidrográficas, com áreas de drenagem entre 1.207 e 18.000 km². Em cinco bacias, obteve coeficiente NS superior a 0,7. No estudo de Sajikumar e Thandaveswara (1999), as RNAs foram aplicadas para a simulação hidrológica em duas bacias hidrográficas, rio Lee (Reino Unido) e rio Thuthapuzha (Índia), com 1.419 km² e 1.030 km², respectivamente, resultando coeficientes de Nash-Sutcliffe (NS) superiores a 0,8. Anmala, Zhang e Govindaraju (2000) aplicaram a técnica das RNAs em simulações

*Instituto de Pesquisas Hidráulicas/UFRGS

hidrológicas com dados mensais em três bacias hidrográficas no Kansas, EUA, obtendo desempenho superior a dois outros modelos empíricos, com coeficiente R^2 superior a 0,9. Hsu, Gupta e Sorooshian (1995) utilizaram a técnica das RNAs para a simulação da vazão diária na bacia do rio Leaf, Mississippi, Estados Unidos (EUA). A técnica apresentou desempenho superior à simulação com o modelo conceitual SAC-SMA (Sacramento Soil Moisture Accounting) e o modelo autorregressivo ARMAX.

A pesquisa de Campolo, Soldati e Andreussi (2003) aborda a previsão de níveis em tempo real para a bacia do rio Arno, atingida por severas inundações, com a utilização de RNAs. Foram obtidos erros percentuais reduzidos, entre 7 e 15%, evidenciando que o modelo de previsão com RNAs é adequado para tal aplicação. Igualmente, Elshorbagy, Simonovic e Panu (2000) utilizaram as RNAs para a previsão de vazão no Red River Valley, Canadá. Na comparação entre as RNAs e modelos com regressões lineares e não lineares, foi observado um significativo incremento no desempenho da previsão com as RNAs. Nos estudos de Rajurkar, Kothiyari e Chaube (2002, 2004) as RNAs foram aplicadas na modelagem chuva-vazão com dados diários em períodos de cheia, na Índia, obtendo resultados muito satisfatórios com coeficiente de NS superior a 0,8 na maioria das previsões. Na mesma temática, Jain e Kumar (2007) aplicaram RNAs e modelos autorregressivos para a previsão hidrológica em três séries de dados de vazão na bacia do rio Colorado, Estados Unidos. Em todos os casos, os modelos baseados em RNAs obtiveram resultados melhores na previsão.

Usualmente, as variáveis de entrada de um modelo com RNAs para simulação hidrológica compreendem dados de precipitação na bacia hidrográfica estudada e dados de vazão em postos fluviométricos à montante, como em Rajurkar, Kothiyari e Chaube et al. (2004), Shamseldin (1997) e Sajikumar e Thandaveswara (1999). Se a aplicação das RNAs estiver relacionada à previsão hidrológica, costuma-se acrescentar também os dados de vazão do posto fluviométrico de interesse na previsão, para incorporar a variável relacionada ao armazenamento no processo hidrológico (exemplos: CAMPOLO; SOLDATI; ANDREUSSI, 2003; ELSHORBAGY; SIMONOVIC; PANU, 2000; JAIN; KUMAR, 2007).

A figura 1 ilustra duas arquiteturas usuais de modelos hidrológicos com RNAs. No caso de simulações hidrológicas (modelo RNA I), o objetivo pode ser a ampliação da extensão da série de vazões à jusante existente ou o preenchimento de falhas. Portanto, embora exista dados para o treinamento da rede, o modelo será utilizado em situações em

que não se pode contar com observações anteriores da variável predita. Já para previsões de curto prazo (modelo RNA II), os valores anteriormente observados da variável a ser prevista desempenham um papel fundamental, sendo, em geral, os maiores responsáveis pelo bom desempenho do modelo. Deve-se ressaltar também que a utilização de dados de vazões e de chuva de dois ou mais dias anteriores ($t-2$, $t-3$, etc.) está condicionada ao tempo de concentração da bacia.

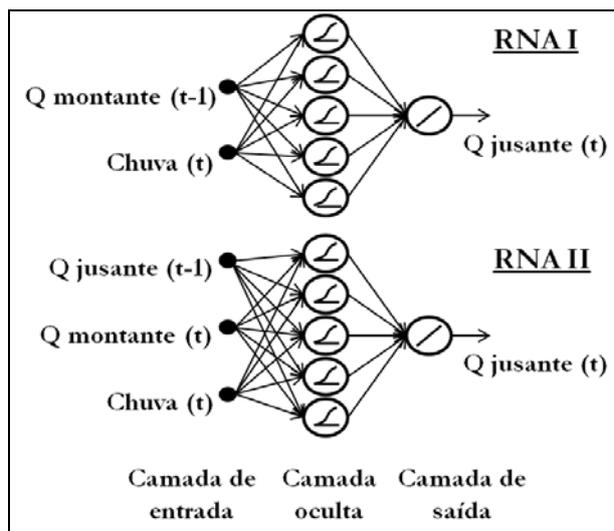


Figura 1 - Arquiteturas usuais de RNAs para aplicações hidrológicas

Este trabalho investiga a hipótese de que é possível identificar um padrão de aumento no desempenho das simulações à medida que aumenta a proporção de área controlada, isto é, a área da bacia até o ponto de monitoramento à montante dividida pela área total da bacia simulada (até o ponto onde as vazões são estimadas). Para testar a hipótese, a chuva foi ignorada para não influenciar na avaliação do efeito da área controlada por postos fluviométricos no desempenho das RNAs.

Deste modo, o objetivo deste estudo é avaliar o desempenho das RNAs em simulações hidrológicas do tipo vazão-vazão, em bacias com diferentes proporções de área controlada, dimensões e características hidrológicas. Este trabalho se justifica em virtude da escassez de dados hidrológicos no Brasil, havendo, portanto, a necessidade de avaliar o desempenho de técnicas como as RNAs em simulações hidrológicas simplificadas, com poucos dados de entrada. Além disso, este estudo pode oferecer su-

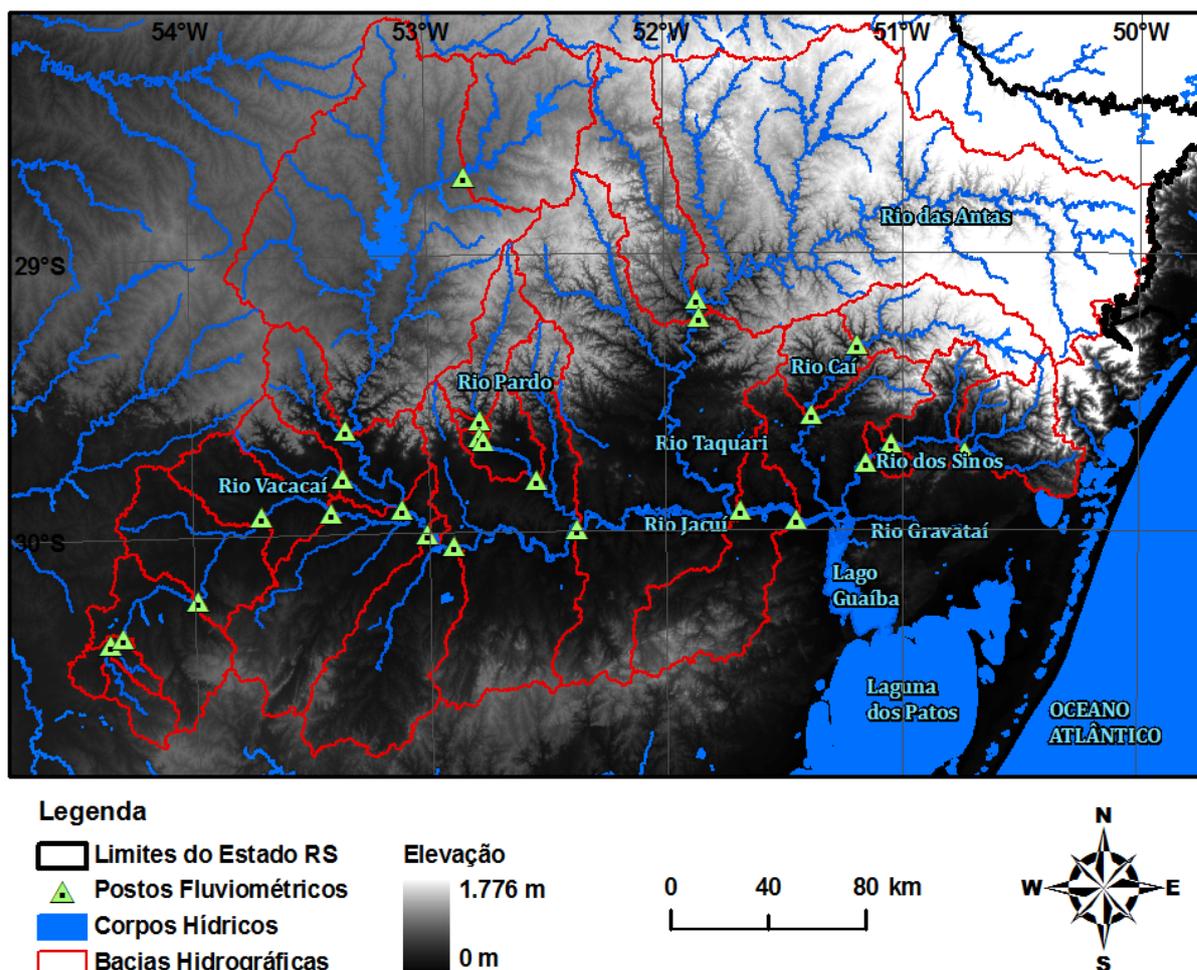


Figura 2 - Região Hidrográfica do Guaíba, Rio Grande do Sul, Brasil

porte para a implantação de redes de monitoramento hidrológico mais eficientes, uma vez que estuda a variação do desempenho do modelo a medida que os dados de entrada se tornam mais representativos (maior área controlada).

MATERIAIS E MÉTODOS

Área de estudo

As simulações foram realizadas em 15 bacias hidrográficas embutidas na Região Hidrográfica do Guaíba, na porção centro-leste do estado do Rio Grande do Sul, Brasil (Figura 2). Os principais rios da região são o Jacuí, Taquari, das Antas, Vacacai,

Caí, Pardo, dos Sinos e Gravataí. A área das bacias varia entre 967 e 71.401 km². A escolha da área de estudo se deve à existência de um grande número de postos fluviométricos, o que permite realizar diversas combinações de dados de entrada, além de ser uma região onde as informações hidrológicas são de vital importância para a tomada de decisão na gestão de recursos hídricos.

Materiais

Os seguintes materiais foram utilizados no presente estudo: a) dados de vazão média diária de 25 postos fluviométricos com séries históricas relativamente extensas, obtidos no portal Hidroweb, da Agência Nacional de Águas (ANA); b) arquivo vetorial de hidrografias do estado do Rio Grande do Sul, disponibilizado pelo Laboratório de Geoprocessa-

mento do Centro de Ecologia da Universidade Federal do Rio Grande do Sul (UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL S, 2010), em formato shapefile; c) dados de elevação da missão Shuttle Radar Topography Mission (SRTM), com resolução espacial de aproximadamente 90 metros, obtidos no sítio virtual da Jet Propulsion Laboratory, California Institute of Technology, National Aeronautics and Space Administration (NASA).

Métodos

Neste estudo, foram realizadas todas as combinações possíveis de postos fluviométricos para a simulação da vazão em 15 bacias hidrográficas da região, totalizando 83 simulações do tipo vazão-vazão no período de 1940 a 2009. Devido ao tamanho diferente das séries de dados dos 25 postos, e a disponibilidade destes dados em períodos distintos, as simulações não puderam ser realizadas para períodos coincidentes e de mesma extensão temporal.

A figura 3 ilustra de forma esquemática a disposição dos postos fluviométricos utilizados nas simulações, desde o posto Santa Brígida (517 km²) até o posto Passo do Raso (71.402 km²).

A programação do modelo de RNA foi realizada com o aplicativo MATLAB R2010a, utilizando no treinamento o algoritmo retropropagativo com validação cruzada, com uma camada de nós de entrada (vazão à montante, nos tempos t , $t-1$, ..., $t-j$, onde j depende da memória da bacia), uma camada de neurônios intermediários e outra camada de saída com um único neurônio (vazão simulada). Para contornar a incerteza associada à aleatoriedade dos valores iniciais dos parâmetros da RNA para o treinamento, o procedimento foi repetido um conjunto de vezes, de forma iterativa, onde cada iteração, começando pela estimativa dos parâmetros iniciais, de forma aleatória, compreende certo número de ciclos.

Antes de cada procedimento, procedeu-se uma análise de correlação entre as vazões observadas nos postos de montante (entradas) e de jusante (saída) com diferentes defasagens temporais. Em seguida, as variáveis baseadas na vazão à montante (com diferentes defasagens) foram ordenadas pelo coeficiente de correlação (r), sendo selecionadas como entradas do modelo apenas aquelas com $r > 0,5$.

Em cada procedimento foi avaliada a melhor arquitetura da RNA, isto é, o número ideal de variáveis de entrada e de neurônios na camada oculta. A arquitetura mais simplificada avaliada apresentou três variáveis de entrada e um neurônio na ca-

mada oculta, enquanto que a arquitetura mais complexa avaliada incluiu todas as n possíveis variáveis de entrada identificadas e $2n+1$ neurônios na camada oculta. Este valor foi adotado com base no Teorema de Kolmogorov (KOLMOGOROV, 1957 apud HETCH-NIELSEN, 1990), que estabelece que sempre existe uma rede neural com n variáveis de entrada e apenas uma camada intermediária (com $2n+1$ neurônios), com a qual se consegue aproximar exatamente qualquer função contínua.

Para comparar a qualidade dos modelos foi utilizada a medida de desempenho conhecida como Akaike's information criterion (AIC) (Equação 1), que identifica o modelo mais parcimonioso, relacionando o desempenho e o número de parâmetros utilizados no mesmo (AKAIKE, 1974).

$$AIC = nd \ln(ep) + 2np \quad (1)$$

onde: nd corresponde ao número de dados; ep é o erro padrão e np é o número de parâmetros do modelo.

Todas as simulações tiveram as seguintes características em comum: a) 30 iterações em cada procedimento, valor definido com base no estudo de Dornelles (2007); b) o número de ciclos máximo em cada iteração foi definido a partir de diversos testes para cada série hidrológica. Na primeira iteração, foram utilizados 6.000 ciclos. Nas iterações seguintes, utilizou-se o número de ciclos necessários para a estabilização dos erros no procedimento anterior, acrescido de 20% (margem de segurança); c) a série de treinamento, de modo geral, compreendeu aproximadamente 50% das amostras, a série de validação entre 15 e 20% e a série de verificação entre 30 e 35%; d) os dados de entrada foram normalizados no processo de escalonamento que antecede as simulações.

Como o escalonamento considera a normalização dos dados, foi desenvolvido um programa que realiza iterativamente a divisão das séries de treinamento, validação e verificação, considerando os percentuais estabelecidos, porém preservando os valores médios e de dispersão dos dados, garantindo que os três conjuntos de amostras possuam características semelhantes. De acordo com testes preliminares, foi observado um considerável incremento no desempenho dos modelos após esse procedimento, justificando sua implantação na metodologia do estudo.

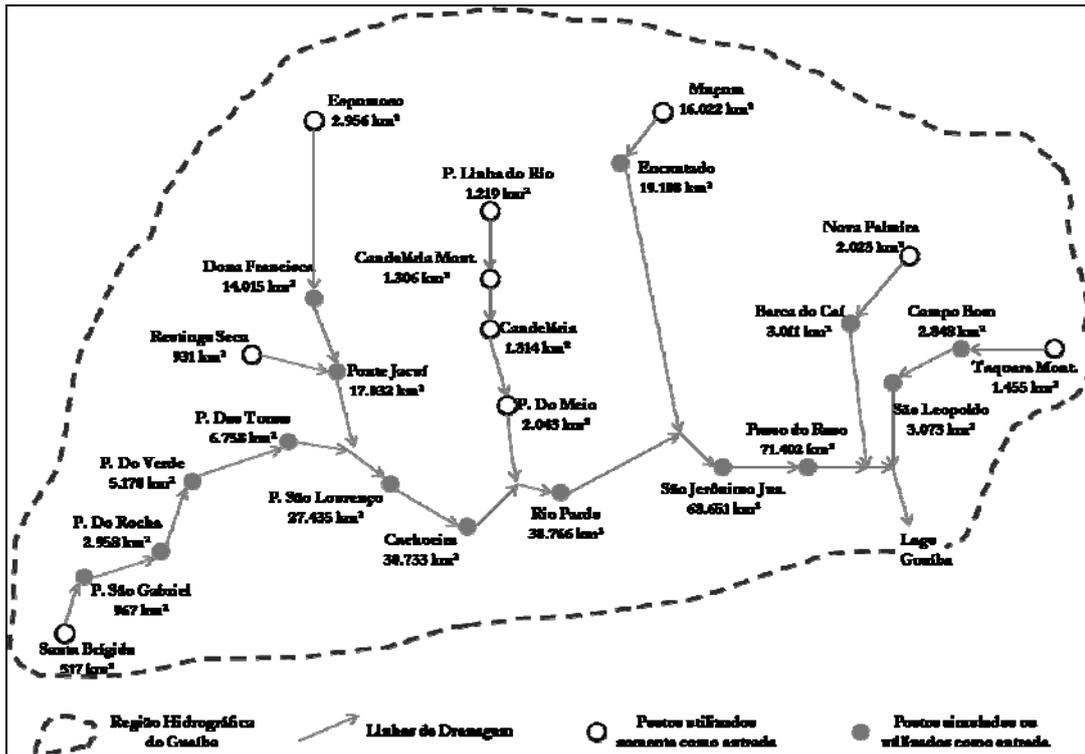


Figura 3 - Esquema representativo da Região Hidrográfica do Guaíba

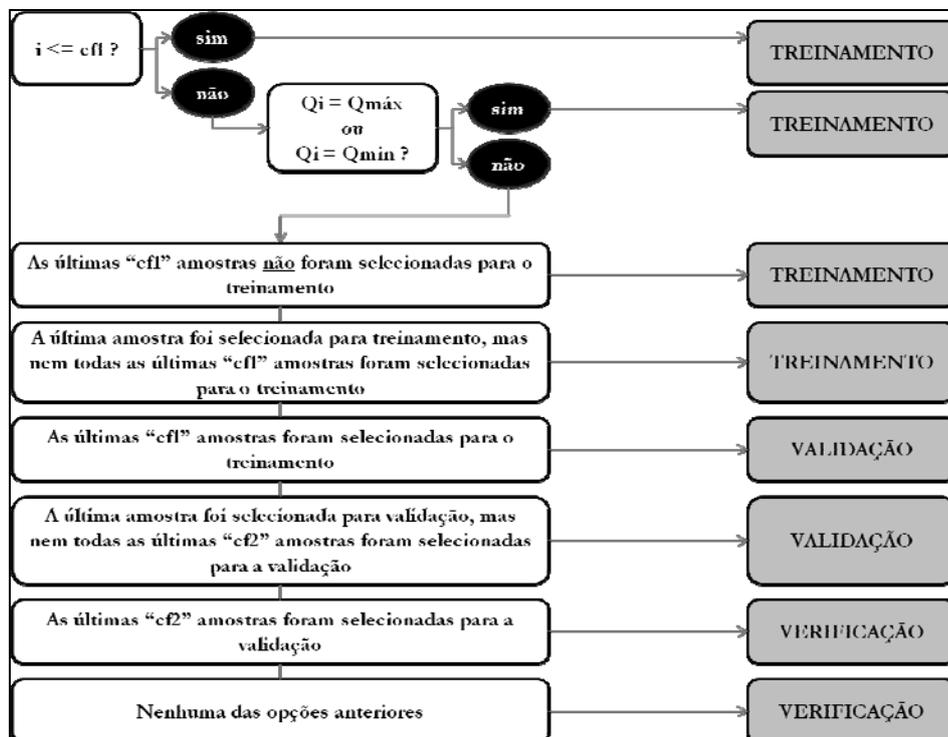


Figura 4 - Procedimento iterativo para divisão das séries amostrais de treinamento

Nesse programa foram utilizados apenas dois parâmetros, $cf1$ e $cf2$. O primeiro, com valores que variaram de 5 a 25, corresponde à amplitude temporal que define cada parcela da série de treinamento, e o $cf2$ corresponde ao valor arredondado de $cf1/3$, e define a amplitude temporal de cada parcela das séries de validação e verificação. Exemplificando: se $cf1$ for igual a 12, $cf2$ é igual a quatro, o que significa que, para cada 12 amostras de treinamento, são selecionadas quatro amostras de validação e oito de verificação. Ao variar $cf1$, não modifica significativamente o número de amostras em cada série, somente os intervalos que dividem as séries. Por fim, é selecionado o valor de $cf1$ que proporciona a melhor divisão das amostras, em séries semelhantes quanto à média e desvio padrão. A figura 4 ilustra o procedimento iterativo.

Considerando que a divisão das amostras e a arquitetura dos modelos (número de iterações, de ciclos, de variáveis de entrada, de neurônios na camada oculta) foram definidas com base nos mesmos critérios para todas as simulações, em procedimentos iterativos, pode-se afirmar que a avaliação do desempenho das RNAs em diferentes características de bacias apresenta imparcialidade. Esse aspecto é de suma importância para comparar os desempenhos dos modelos em distintas circunstâncias hidrológicas.

RESULTADOS E DISCUSSÕES

O primeiro resultado de destaque no trabalho diz respeito ao padrão observado na relação entre os nós de entrada e o número de neurônios da camada de oculta dos modelos desenvolvidos. Como descrito anteriormente, no item relacionado aos métodos, a configuração ideal para cada procedimento foi selecionada de acordo com o melhor valor do índice AIC.

Foi observado que em 75% das simulações, o número de neurônios na camada oculta foi igual a $n-1$, onde n é o número de variáveis de entrada no modelo. O número de neurônios na camada oculta foi igual a n em 20% das simulações. Apenas 5% das 83 simulações realizadas apresentaram uma configuração mais complexa, com $n+1$ ou $n+2$ neurônios na camada oculta.

Esse resultado indica que não há necessidade de adotar um grande número de neurônios na camada oculta das RNAs com aplicações semelhantes às deste estudo. Adotando-se aproximadamente n neurônios na camada oculta (n = número de variáveis de entrada) obtêm-se um modelo eficiente, com menos parâmetros e desempenho equivalentemente superior aos modelos mais complexos.

A configuração mais observada (em 18% das simulações) apresentou apenas três variáveis de entrada e dois neurônios na camada oculta, totalizando 11 parâmetros. O desempenho médio dos modelos com essa característica simplificada foi satisfatório, com coeficiente de Nash-Sutcliffe (NS) de 0,784 e coeficiente de correlação (r) de 0,883.

De modo geral, os modelos com as configurações mais simplificadas, menor número de nós na camada de entrada e de neurônios na camada oculta, estão associados às simulações em bacias de pequenas dimensões e com períodos mais reduzidos (menos de dez anos). Os modelos mais complexos estão relacionados às simulações que tiveram como dados de entrada a vazão em mais de um posto fluviométrico de montante. Nestes casos, observou-se que o desempenho das simulações apresentou valores acima do desempenho médio observado.

De modo geral, os modelos com as configurações mais simplificadas, menor número de nós na camada de entrada e de neurônios na camada oculta, estão associados às simulações em bacias de pequenas dimensões e com períodos mais reduzidos (menos de dez anos). Os modelos mais complexos estão relacionados às simulações que tiveram como dados de entrada a vazão em mais de um posto fluviométrico de montante. Nestes casos, observou-se que o desempenho das simulações apresentou valores acima do desempenho médio observado.

Desempenho das RNAs nas simulações

O desempenho dos modelos com RNAs nas 83 simulações realizadas foi bastante satisfatório, considerando a simplicidade dos dados de entrada e que, em média, a proporção de área controlada (razão entre a área da bacia do posto fluviométrico à montante e a área da bacia simulada) foi de apenas 35,5%. Os coeficientes NS e r foram de 0,75 e 0,862, respectivamente. A tabela 1 apresenta a frequência do desempenho (NS) das RNAs nas simulações hidrológicas.

Tabela 1 - Frequência do desempenho de RNAs nas simulações hidrológicas

NS	Frequência (F)	F Acum.	Percentual (%)	% Acum.
> 0,9	19	19	23%	23%
0,8 - 0,9	19	38	23%	46%
0,7 - 0,8	18	56	22%	67%
0,6 - 0,7	15	71	18%	86%
< 0,6	12	83	14%	100%

Observou-se que o desempenho das simulações hidrológicas com RNAs apresenta, de forma geral, um crescimento potencial à medida que aumenta a proporção de área controlada (Figura 5). O ajuste da curva de tendência central apresentou R^2 de 0,712.

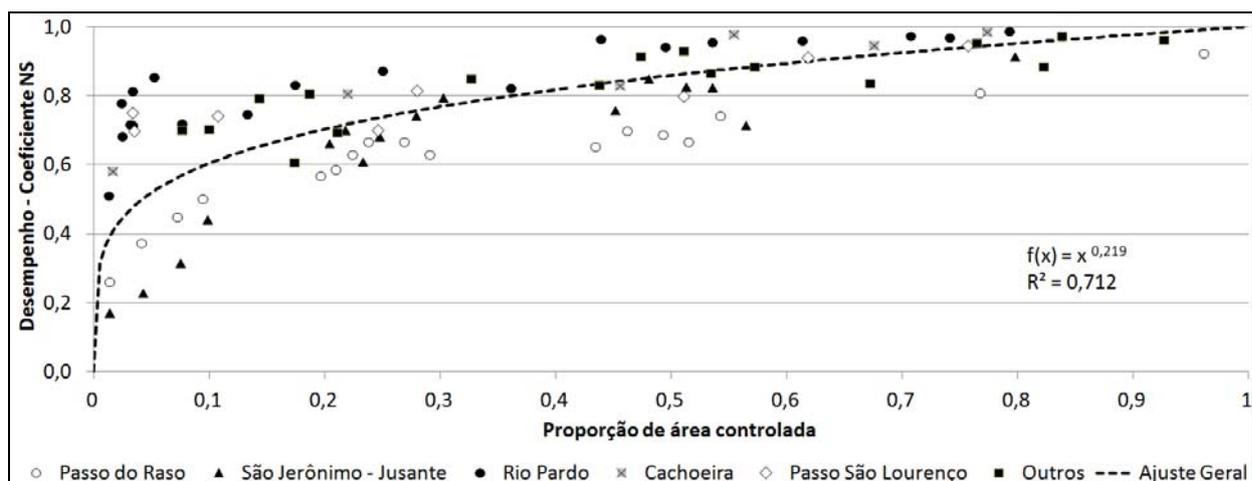


Figura 5 -Desempenho das simulações (NS) em função da proporção de área controlada (x)

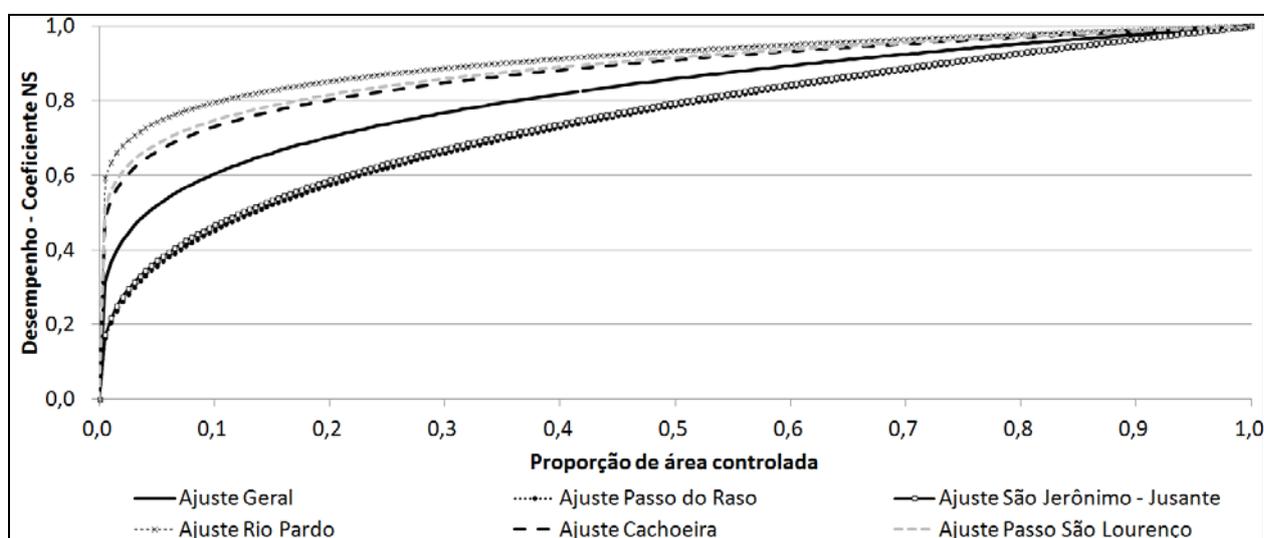


Figura 6 - Ajuste de funções potenciais do desempenho das simulações em função da proporção de área controlada nos postos fluviométricos de maior área de drenagem

De modo geral, é necessário pouco mais de 20% de proporção de área controlada para obter o coeficiente NS de 0,7 nas simulações com RNAs com dados de vazão à montante. Com pouco mais de 35% de proporção de área controlada obteve-se coeficiente NS geralmente superior a 0,8 e com mais de 65%, coeficiente NS superior a 0,9 (Figura 5). Em nenhuma das 17 simulações com proporção de área controlada superior a 60%, o coeficiente NS foi inferior a 0,8.

No entanto, a figura 5 ilustra outro aspecto interessante: a) as simulações com desempenho inferior ao esperado (de acordo com o ajuste da

função potencial) foram as dos postos fluviométricos de maior área de drenagem, Passo do Raso (71.402 km²) e São Jerônimo – Jusante (68.651 km²). De modo geral, as simulações nos postos fluviométricos com dimensões intermediárias, Rio Pardo (38.766 km²), Cachoeira (30.733 km²) e Passo São Lourenço (27.435 km²) apresentaram desempenho superior ao esperado (Figuras 5 e 6). Já nas simulações em bacias menores (ex.: Passo do Verde, 5.170 km²; Passo do Rocha, 2.958 km²; Passo São Gabriel, 967 km²) observou-se que o desempenho foi bem semelhante ao valor esperado, considerando o ajuste ilustrado na figura 5.

As simulações no posto Rio Pardo obtiveram excelentes resultados, com coeficiente NS superior a 0,8 na maioria das combinações realizadas. Observou-se que seis das 19 simulações neste posto, apresentaram coeficiente NS superior a 0,95. Essa constatação é ilustrada pela figura 7, que representa o hidrograma resultante da simulação da vazão no posto Rio Pardo no período entre 09/1941 e 09/1946, tendo como dados de entrada a vazão no posto Cachoeira (79% de proporção de área controlada) nos três dias anteriores.

Por outro lado, as simulações no posto de maior área de drenagem (Passo do Raso), apresentaram resultados bem inferiores aos obtidos no posto Rio Pardo. A maioria das simulações (65%) apresentou coeficiente NS entre 0,5 e 0,7 e apenas 12% obtiveram coeficiente NS superior a 0,8. Um dos hidrogramas resultantes da simulação da vazão no posto Passo do Raso é apresentado na figura 8. Nesta simulação foram utilizados como dados de entrada a vazão no posto São Jerônimo – Jusante (96% de proporção de área controlada) nos três dias que antecedem a data de interesse.

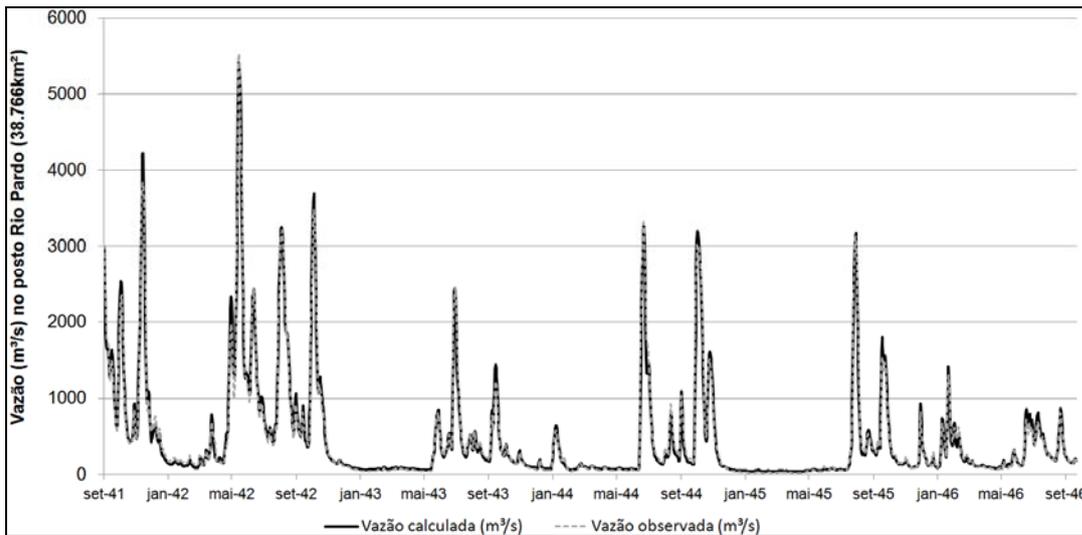


Figura 7 - Hidrograma do rio Jacuí, posto Rio Pardo, entre 1941 e 1946. Hidrograma calculado por modelo com dados do posto à montante de Cachoeira nos três dias anteriores

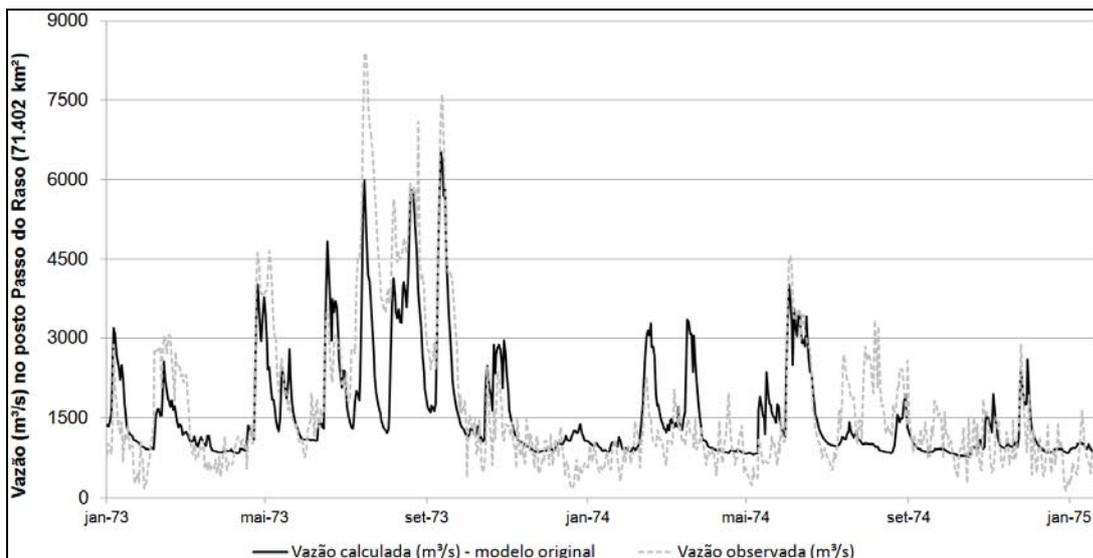


Figura 8 - Hidrograma do rio Jacuí, no posto Passo do Raso, entre 1973 e 1975. Hidrograma calculado por modelo com dados do posto à montante de São Jerônimo – Jusante

Existem quatro explicações plausíveis para o decréscimo do desempenho dos modelos de RNAs nas bacias de maior área de drenagem. A primeira se refere à qualidade da curva-chave obtida para cada posto, que interfere diretamente na confiabilidade dos registros hidrológicos. A segunda explicação refere-se ao período não coincidente das simulações, podendo ter afetado negativamente a estatística do desempenho do modelo nestes postos. A terceira está relacionada ao efeito de remanso observado nos trechos próximos à foz do rio Jacuí, no lago Guaíba. A última explicação diz respeito à simplificação dos modelos com RNAs adotados neste estudo, utilizando apenas os dados de vazão de estações à montante, sem considerar o efeito do armazenamento, que poderia ser representado ao utilizar como entrada no modelo a vazão do local de interesse no dia anterior.

Quanto ao efeito de remanso pode-se afirmar que o mesmo depende do nível do lago Guaíba, da direção dos ventos, entre outros fatores hidrometeorológicos, e pode influenciar a relação cota-vazão dos principais rios da Região Hidrográfica do Guaíba, principalmente no trecho correspondente aos postos Passo do Raso e São Jerônimo - Jusante, ambos muito próximos à foz do rio Jacuí. No entanto, não é possível quantificar a influência destes fatores no decréscimo de desempenho das simulações nos postos fluviométricos próximos à foz do rio Jacuí. Por este motivo, a questão do remanso não será discutida neste estudo.

Por sua vez, a última explicação, relacionada ao armazenamento, pode ser quantificada e, portanto, merece ser destacada nessa discussão. Pode-se afirmar que o efeito negativo da simplificação dos modelos com RNAs utilizados neste estudo é superior em bacias maiores, como as observadas nos postos São Jerônimo – Jusante (68.651 km²) e Passo do Raso (71.402 km²), já que a vazão observada nesses locais depende em grande parte da vazão registrada no dia anterior. Deste modo, em bacias grandes, o armazenamento é uma importante variável hidrológica a ser considerada na simulação da vazão, sendo parcialmente desconsiderada pelo modelo adotado de simulação com RNAs, sem os dados de vazão no dia anterior do próprio local de interesse.

A figura 9 apresenta uma comparação entre o hidrograma calculado a partir do modelo simplificado original (NS = 0,629) e do modelo alterado (NS = 0,908), com dados de vazão do posto Muçum (22% de proporção de área controlada) e do próprio posto Passo do Raso no dia anterior. Ao observar os hidrogramas da figura 9, fica evidente a im-

portância da variável responsável pela assimilação do armazenamento no interior do modelo.

A importância da incorporação de dados que representem o armazenamento (vazão no local de interesse no dia anterior) em simulações de bacias com maior área de drenagem ficou ainda mais evidente ao serem novamente realizadas as simulações em todos os postos, incluindo desta vez como variáveis de entrada, os dados de vazão no local de interesse no dia anterior. Observou-se que a inclusão dessa variável de entrada proporcionou uma significativa elevação no desempenho das 83 simulações (Figura 10), aumentando a média do coeficiente NS de 0,75 para 0,94 (+25,3%). Porém, é importante ressaltar que o efeito positivo dessa inclusão foi muito superior nas bacias de maior área de drenagem, como nos postos Passo do Raso e São Jerônimo – Jusante. No posto Passo do Raso a média do coeficiente NS aumentou de 0,62 para 0,91 (+46,8%) e no posto São Jerônimo – Jusante, aumentou de 0,64 para 0,92 (+43,8%). O mesmo não foi verificado em bacias menores, como nos postos Passo das Tunas e Passo São Lourenço, com crescimento de 17,6% e 21,2%, respectivamente.

Esses resultados revelam que a utilização de modelos de RNAs em simulações hidrológicas do tipo vazão-vazão pode apresentar limitações em bacias de grande área de drenagem, com forte influência da variável armazenamento. Desse modo, para obter bons resultados em bacias de grandes dimensões, com um modelo simplificado como o apresentado neste estudo, seria necessária a presença de postos fluviométricos com maior proporção de área controlada ou mais próximos do local de interesse.

Ainda assim, de modo geral, adotando-se um limiar razoável de desempenho (NS > 0,8), e considerando as simulações realizadas, pode-se afirmar que o modelo simplificado do tipo vazão-vazão com RNAs é recomendável, desde que seja atendida a condição de pelo menos 50% de área controlada. É importante recordar que apenas três das 28 simulações realizadas nestas condições apresentou coeficiente de NS inferior a 0,8, referentes aos postos Passo do Raso (71.402 km²) e São Jerônimo – Jusante (68.651 km²).

É evidente que essa proporção de área controlada pode oscilar de acordo com as características físicas das bacias hidrográficas, sendo influenciada pela geomorfologia, geologia, solos, clima, entre outros. Ainda assim, esse limiar é importante, tendo em vista que pode ser levado em consideração em futuras aplicações do modelo apresentado neste

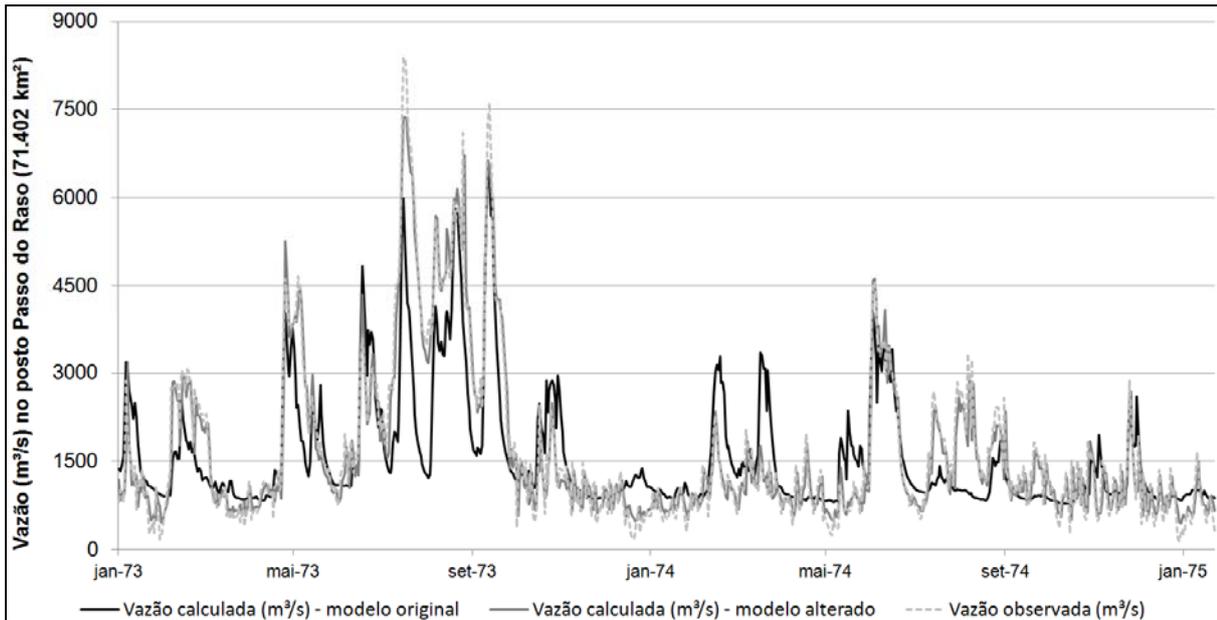


Figura 9 - Hidrograma do rio Jacuí, posto Passo do Raso, obtido por modelo com dados do posto à montante de Muçum e vazão do próprio posto no dia anterior

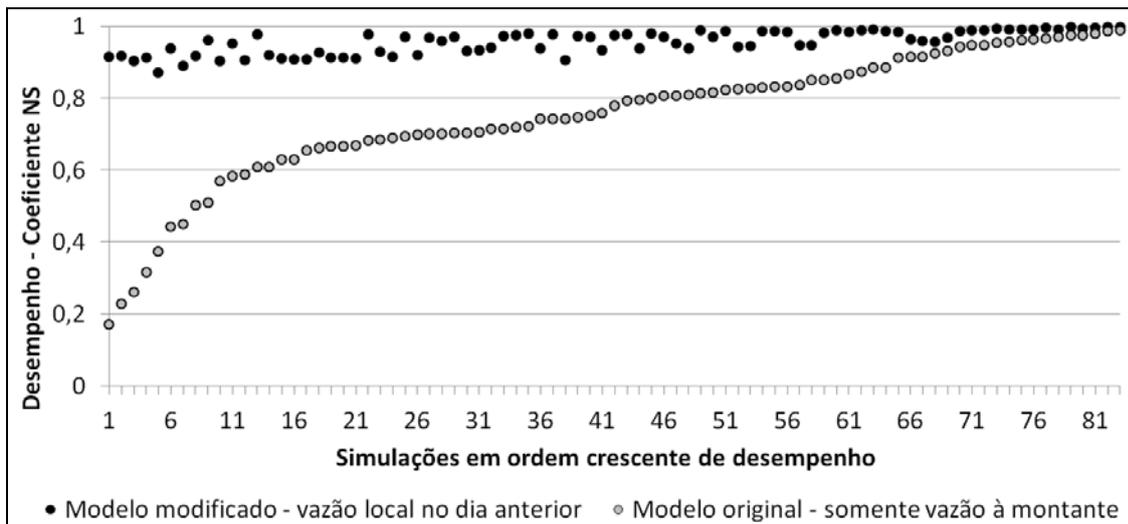


Figura 10 - Melhoria do desempenho das simulações ao incorporar uma variável que representa o armazenamento – vazão no local de interesse no dia anterior

trabalho, servindo de referência para a validação do desempenho.

Além disso, esse limiar pode ser utilizado no planejamento de futuras redes de monitoramento hidrológico, a fim de aperfeiçoar os resultados obtidos em simulações hidrológicas com poucos dados de entrada. Espera-se que a utilização do conceito

de proporção de área controlada no planejamento futuro de redes fluviométricas possa ser um recurso que venha a contribuir para a obtenção de redes fluviométricas mais eficientes, nas quais seja reduzida a ocorrência de escassez de dados hidrológicos.

CONCLUSÕES

De modo geral, o desempenho dos modelos do tipo vazão-vazão, com RNAs, foi bastante satisfatório, com coeficiente NS médio de 0,75 para 35,5% de área controlada média, nas 83 simulações realizadas. Foi observado que o desempenho das simulações hidrológicas apresentou um crescimento potencial à medida que aumenta a proporção de área controlada. Foi necessário mais de 35% de área controlada para obter um coeficiente NS superior a 0,8 e mais de 65% para atingir um coeficiente NS superior a 0,9.

Identificou-se uma forte relação entre o desempenho das simulações e a dimensão da bacia de interesse. As simulações com desempenho inferior ao esperado, de acordo com a função ajustada, foram as dos postos fluviométricos de maior área de drenagem, Passo do Raso (71.402 km²) e São Jerônimo – Jusante (68.651 km²).

A principal explicação é a simplificação dos modelos com RNAs utilizados neste estudo, utilizando apenas os dados de vazão de estações à montante. Com a simplificação, o efeito do armazenamento é parcialmente ignorado. Observou-se que o efeito negativo dessa simplificação é superior em bacias maiores, em que o armazenamento é uma das variáveis hidrológicas mais importantes a ser considerada na simulação da vazão. Esta explicação foi comprovada ao realizar-se novamente as 83 simulações, incluindo-se, nestas, os dados de vazão no local de interesse no dia anterior. O efeito positivo da inclusão dessa variável de entrada mostrou um impacto superior nas bacias de maior área de drenagem, como nos postos Passo do Raso (incremento de 46,8% no coeficiente NS) e São Jerônimo – Jusante (+43,8%).

Este estudo foi feito para uma bacia hidrográfica com características morfológicas, hidrológicas e climáticas específicas. Porém, as conclusões obtidas podem ser estendidas para bacias com características semelhantes. Além disso, a metodologia pode ser aplicada a bacias com características diferentes para identificar o padrão de aumento de desempenho do modelo em função da proporção da área controlada.

REFERÊNCIAS

AKAIKE, H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, v. 19, n. 6, p. 716-723, 1974.

ANMALA, J.; ZHANG, B.; GOVINDARAJU, R. S. Comparison of ANNs and empirical approaches for predicting watershed runoff. *Journal of Water Resources Planning and Management*, v. 126, n. 3, p. 156-166, 2000.

ASCE. Task Committee on Applications of Artificial Neural Networks in Hydrology. Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, v. 5, n. 2, p. 115-123, 2000a.

ASCE. Task Committee on Applications of Artificial Neural Networks in Hydrology. Artificial neural networks in hydrology. II: Preliminary concepts. *Journal of Hydrologic Engineering*, v. 5, n. 2, p. 124-137, 2000b.

CAMPOLO, M.; SOLDATI, A.; ANDREUSSI, P. Artificial neural network approach to flood forecasting in the River Arno. *Hydrological Sciences Journal*, v. 48, n. 3, p. 381-398, 2003.

DORNELLES, F. Continuous forecasting of river levels by neural networks using rainfall-forecasting: methodology and techniques (in Portuguese). 2007. Master's dissertation (Post-Graduate Program in Water Resources and Environmental Sanitary Engineering) - Hydraulic Research Institute, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

ELSHORBAGY, A.; SIMONOVIC, S. P.; PANU, U. S. Performance evaluation of artificial neural networks for runoff prediction. *Journal of Hydrologic Engineering*, v. 5, n. 4, p. 424-427, 2000.

HECHT-NIELSEN, R. *Neurocomputation*. Reading, MA: Addison-Wesley, 1990.

HSU, K. L.; GUPTA, H. V.; SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research*, v. 31, n. 10, p. 2517-2530, 1995.

JAIN, A.; KUMAR, A. M. Hybrid neural network models for hydrologic time series forecasting. *Applied Soft Computing*, v. 7, n. 2, p. 585-592, 2007.

JAIN, A.; SUDHEER, K. P.; SRINIVASULU, S. Identification of physical processes inherent in artificial neural network rainfall runoff models. *Hydrological Processes*, v. 18, n. 3, p. 571-581, 2004.

MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, n. 4, p. 115-133, 1943.

RAJURKAR, M. P.; KOTHYARI, U. C.; CHAUBE, U. C. Artificial neural networks for daily rainfall-runoff modelling. *Hydrological Sciences Journal*, v. 47, n. 6, p. 865-877, 2002.

RAJURKAR, M. P.; KOTHYARI, U. C.; CHAUBE, U. C. Modeling of daily rainfall-runoff relationship with artificial neural network. *Journal of Hydrology*, v. 285, n. 1-4, p. 96-113, 2004.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, v. 323, p. 533-536, 1986.

SAJIKUMAR, N.; THANDAVESWARA, B. S. A non-linear rainfall-runoff model using an artificial neural network. *Journal of Hydrology*, v. 216, n. 1-2, p. 32-55, 1999.

SHAMSELDIN, A. Y. Application of a neural network technique to rainfall-runoff modelling. *Journal of Hydrology*, v. 199, n. 3-4, p. 272-294, 1997.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL. Instituto de Biociências. Centro de Ecologia. Laboratório de Geoprocessamento. *Base cartográfica vetorial contínua do Rio Grande do Sul*. Porto Alegre: UFRGS, 2010.

WIDROW, B.; HOFF, M. E. Adaptive switching circuits. In: IRE WESCON Convention Record. New York: IRE, 1960. part 4, p. 96-104.

Hydrological Simulations With Different Proportions Of Controlled Area In The Watershed

ABSTRACT

This research presents as fundamental hypothesis the existence of a pattern of increase in the performance of daily streamflow simulations based on artificial neural network (ANN) models when it uses input information related to upstream gauging stations with a higher proportion of controlled area (dividing the area of the drainage watershed at the upstream gauging station by the total area of the simulated watershed). We performed 83 simulations based on 15 nested watersheds aiming to assess the

performance of ANNs in hydrologic simulations of watersheds with several proportions of controlled area. Watersheds with areas from 967 km² to 71401 km² located in the Guaíba Region, Brazil, were analyzed. The performance of ANNs models was satisfactory showing a mean Nash-Sutcliffe Coefficient (NS) equal to 0.75 when upstream streamflow input information is related to a controlled area of 35.5% . The relationship between ANN model performance and controlled area of the upstream gauging station showed a growth behavior that was approximated by a potential equation. Based on our results and adopting a reasonable threshold (NS>0.8), the development of an ANN model is recommended when it has upstream streamflow information available for at least 50% controlled area. Although the results refer to watersheds with similar characteristics to those simulated in this study, this threshold can be adopted as a reference for defining streamflow gauging station networks, considering the needs of extrapolation in places without gauging stations and completing time series recorded at existing gauging stations.

Keywords: Nested drainage basins; Artificial neural networks; Hydrological modelling; Daily streamflow.