

ESTIMATIVA DE VAZÕES DIÁRIAS EM RIOS A PARTIR DE VAZÕES A MONTANTE USANDO REDES NEURAS ARTIFICIAIS

Moisés Correia Freitas¹ e Gustavo Barbosa Lima da Silva²

RESUMO - O desenvolvimento de elementos para tomada de decisão na gestão de recursos hídricos requer o conhecimento de dados hidrológicos por um período significativo de tempo. No Brasil, a inexistência de séries contínuas de vazões obriga a utilização de métodos para estimativas de períodos sem dados. Atualmente, o uso das Redes Neurais Artificiais (RNA) tem mostrado resultados satisfatórios. Neste trabalho, a eficiência das RNA na estimativa de vazões em rios, informando apenas vazões a montante do posto em estudo como dado de entrada foi avaliada. Foram testados sete modelos, considerando como variáveis de entrada as vazões dos afluentes do rio principal da sub-bacia em estudo, no dia da estimativa e em dias anteriores a mesma. Posteriormente utilizou-se as vazões acumuladas dos afluentes nos dias antecedentes ao da estimativa. Os resultados mostraram que o modelo que possui na composição do vetor de entrada as vazões estimadas de uma estação também localizada no rio principal apresentou o melhor desempenho, apesar de tal estimativa ter sido obtida com um período resumido de dados.

ABSTRACT – Decision making in water resources requires the existence of hydrological data for a long time. In cases where consecutive observation are missing, which are common in hydrological data, the use of methods for estimation of missing observation is need. Recently, the use of Artificial Neural Networks (ANN) has shown satisfactory results. In this study, performance of ANN for estimation of daily streamflow using only river upstream information is evaluated. Seven models were considered here using as input data: streamflow upstream of main river, streamflow at tributaries and accumulated streamflow at tributaries. The model which used estimated streamflow in a station localized in main river showed better results.

Palavra-chave: Modelagem hidrológica, Redes Neurais Artificiais, Vazões diárias.

¹Engenheiro Civil, (CT/UFPB), Campus Universitário I, 58051-900, João Pessoa, Paraíba, (83) 3216-7119, E-mail: moisescivilufpb@gmail.com

² Professor Adjunto da UFPB, CT, Campus Universitário I, 58051-900, João Pessoa, Paraíba, (83) 3216-7119, E-mail: gustavo@ct.ufpb.br

INTRODUÇÃO

Estudos relacionados ao planejamento de sistemas de recursos hídricos requerem, normalmente, o conhecimento de dados contínuos de vazão em locais específicos. Mas infelizmente, informações históricas de vazão são altamente limitadas. É comum a existência de períodos sem registro de dados ou com um número limitado de dados para um local de interesse. Nessas situações, a aplicação de modelos hidrológicos do tipo chuva-vazão tem sido uma alternativa largamente utilizada para a estimativa de vazões.

Os resultados obtidos por estes métodos possuem uma margem aceitável de erro. Entretanto, A calibração desses modelos é um processo demorado e subjetivo, que exige, muitas vezes, o levantamento de informações hidrológicas que nem sempre se encontram disponíveis. Essa ausência de informações muitas vezes é responsável pela adoção de modelos simplificados, o que acaba interferindo nos resultados obtidos.

Por outro lado, a aplicação de modelos baseados em Redes Neurais Artificiais (RNA) tem se mostrado uma alternativa atraente para a modelagem de vazões em rios (ASCE, 2000a; ASCE, 2000b, Rajurkaret al., 2004; Tokar e Markus, 2000). O interesse se justifica, em parte, pela capacidade comprovada das RNA na representação de relações fortemente não lineares, característica marcante dos processos hidrológicos. Outro fator que tem impulsionado a utilização das RNA na modelagem de vazões é a sua habilidade de aprender e generalizar as características importantes nas series hidrológicas, como sazonalidade e periodicidade.

Nesse sentido, o objetivo principal deste trabalho foi avaliar a eficiência da técnica de Redes Neurais Artificiais na estimativa de vazões diárias, considerando como dado de entrada as vazões observadas em estações localizadas à montante do posto de interesse.

REDES NEURAS ARTIFICIAIS (RNA)

As Redes Neurais Artificiais (RNA) são ferramentas matemáticas inspiradas no comportamento do cérebro humano, a partir do entendimento de que as funções neurais biológicas, incluindo a memória, são armazenadas nos neurônios e nas conexões entre eles, e que o processo de aprendizado consiste em estabelecer novas conexões entre neurônios ou modificar as conexões existentes.

Um dos aspectos que tem motivado o uso freqüente de RNA em diversos campos da ciência, particularmente em estudos de modelagem e previsão de séries temporais, é a sua capacidade comprovada de representar adequadamente relações fortemente não-lineares entre variáveis. Por meio dessa técnica, a dependência entre variáveis de entrada e saída pode ser modelada por uma

combinação de muitas funções matemáticas não-lineares, o que pode levar a uma representação de sistemas complexos com uma precisão aceitável.

As RNA podem ser entendidas como conjuntos bem estruturados de unidades de processamentos, chamadas neurônios artificiais, dispostas em camadas que são interconectadas entre si. Embora existam, atualmente, diversos tipos de RNA, a rede *Perceptron* Multicamadas (MLP – *Multilayer Perceptron*) é uma das mais conhecidas e aplicadas. Uma das razões para isso é a sua capacidade de aproximação universal e sua flexibilidade para solucionar uma grande classe de problemas, incluindo reconhecimento de padrões, processamento de sinais, controle e otimização, problemas de classificação e previsão de séries temporais. Por esse motivo, essa foi a rede utilizada nesse trabalho.

A estrutura de um MLP consiste de três camadas distintas: uma camada de entrada onde os dados são introduzidos na rede, as camadas intermediárias onde os dados são processados e uma camada de saída onde os resultados são produzidos. A figura 1 apresenta uma estrutura típica de um MLP contendo, nesse caso, apenas uma camada intermediária.

Essa rede possui N_e neurônios de entrada, N_i neurônios na camada intermediária e N_s neurônios na camada de saída. Os neurônios de entrada são representados por η_k ($1 \leq k \leq N_e$), os da camada intermediária por σ_j ($1 \leq j \leq N_i$) e neurônios da camada de saída S_i ($1 \leq i \leq N_s$). Os neurônios de entrada são ligados aos da camada intermediária por pesos α_{jk} e os da camada intermediária aos da camada de saída por pesos ω_{ij} .




Figura 1 - Estrutura de uma rede neural com uma camada intermediária

Matematicamente, a transmissão de informações entre camadas é realizada por meio de uma função de combinação e uma função de ativação. A função de combinação é responsável por compor a informação dos neurônios de entrada. Se ela for linear passa a representar o somatório da entrada pelos respectivos pesos.

No exemplo da Figura 1, os valores dos neurônios da camada intermediária são determinados pela seguinte equação:

$$\sigma_j = f\left(\sum_{k=1}^{N_e} \alpha_{jk} \eta_k\right) \quad (1)$$

De forma semelhante para, os neurônios da camada de saída:

$$S_i = f\left(\sum_{j=1}^{N_i} \omega_{ij} \sigma_j\right) \quad (2)$$

Os pesos das conexões representam matematicamente a importância de cada informação com relação a um dado neurônio. Já a função de ativação (f) é responsável pela intensidade do sinal a ser transmitido pelas conexões para os neurônios das camadas adjacentes. Diversas são as funções de ativação utilizadas nas aplicações com redes neurais. Exemplos dessas funções podem ser encontrados em detalhes em (Haykin, 2005; Hagan *et al.*, 1996; Muller e Reinhardt, 1990).

A construção de uma RNA passa basicamente por três fases: definição da arquitetura da rede, treinamento da rede, verificação da rede. A arquitetura é definida basicamente pela determinação do número de camadas, número de neurônios por camada, tipo de conexão entre as camadas (funções de ativação). O processo de treinamento consiste em fornecer à rede um conjunto de exemplos e alterar os seus pesos de modo a tornar a rede capaz de representar as informações. Esse processo é realizado de forma iterativa, de modo que a cada iteração os valores dos pesos são alterados para se obter o menor desvio entre os valores fornecidos pela rede e os dados observados. Na verificação, um conjunto de dados de entrada, não utilizado na etapa de treinamento, é fornecido à rede, e os resultados obtidos são utilizados para verificar se a rede treinada é capaz de generalizar o comportamento aprendido.

METODOLOGIA

Dados Utilizados

Os dados utilizados neste trabalho foram extraídos do banco de dados da ANA (Agência Nacional de Águas) e correspondem às vazões diárias observadas em seis estações fluviométricas instaladas na Bacia do Rio São Francisco. A área escolhida para estudo está inserida na sub-bacia 42 (Figura 2).

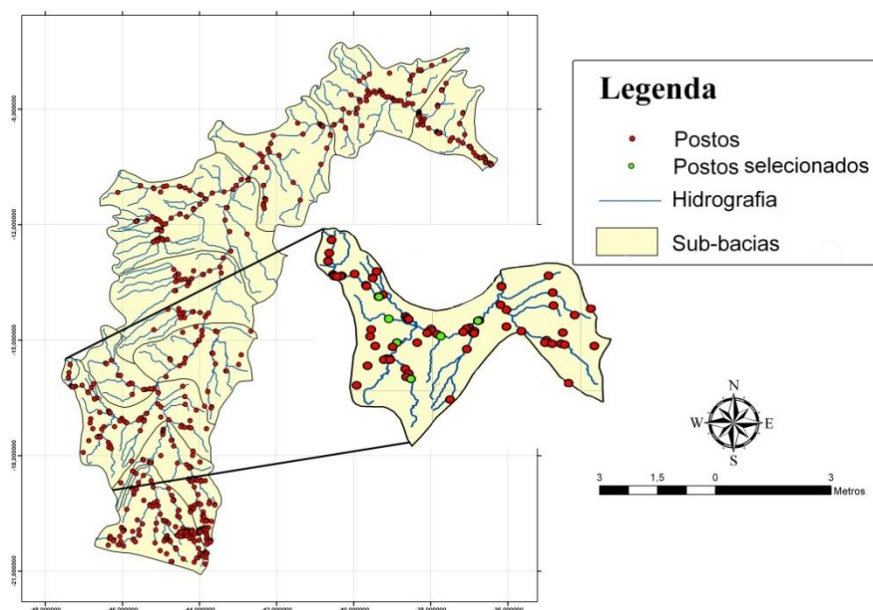


Figura 2 - Bacia do Rio São Francisco

Os postos selecionados foram escolhidos em função da inexistência de qualquer obra hidráulica em suas proximidades que pudesse modificar os valores das vazões naturais. Para o período de 01/04/1999 a 30/11/2004, aproximadamente cinco anos, observou-se a ausência de falhas para todos os postos considerados.

Para facilitar a identificação dos postos, estes foram renumerados com o código entre parêntesis mostrado na figura 3. O posto 6, localizado no rio principal (rio Paracatu), corresponde a seção onde se deseja estimar as vazões. Os postos 3 e 5 também fazem parte do rio principal, enquanto que os demais se localizam em afluentes. As estações instaladas nos afluentes encontram-se afastadas do posto em estudo por distâncias relativamente consideráveis, são aproximadamente 342 km, 183 km e 286 km que separam os postos 1, 2 e 4, do posto 6, respectivamente.




Figura 3 - Rios e estações utilizadas

Modelos de RNA

Neste trabalho, as RNA testadas possuíam apenas uma camada intermediária. Essa opção se deu em função de alguns testes realizados previamente em que se observou que o uso de mais do que uma camada não produzia alterações significativas nos resultados, apenas aumentava consideravelmente o tempo de processamento.

Para a estimativa das vazões atuais no posto 6, $Q_6(t)$, sete RNA foram testadas. Para cada alternativa, foram consideradas como variáveis de entrada as vazões observadas à montante do posto 6 no tempo atual (t) e em n dias anteriores ($t-1, t-2, \dots, t-n$). A tabela 1 mostra a configuração geral de cada uma das Redes avaliadas. Os valores de N_e e N_i foram determinados por um procedimento de tentativa e erro, em que a quantidade de neurônios nas camadas de entrada e intermediária foi variada até se atingir uma quantidade mínima suficiente a partir da qual não foi observada perda significativa de qualidade nos resultados produzidos pela RNA.

No modelo M1 o vetor de entrada foi composto pelas vazões observadas no posto 3 no dia em que se deseja a estimativa e em dois dias anteriores (tabela 1). Procedimento semelhante foi realizado na composição da entrada do modelo M2 que, diferente do primeiro, utiliza as vazões do posto 5 no dia da estimativa em um dia anterior a mesma. Ambos os postos registram as informações de vazões diárias em diferentes seções do rio principal da sub-bacia em questão, onde também se localiza a estação de interesse (Posto 6).

O modelo M3, utiliza como entrada da RNA a combinação das vazões dos afluentes do Rio Paracatu, postos 1, 2 e 4, no dia em que se realiza a estimativa e em dois dias anteriores. Em M4, acumulou-se de dois em dois dias as vazões dos postos localizados nos afluentes. Esse acúmulo teve início no quarto dia anterior ao dia em que se deseja a vazão estimada, $Q_6(t)$. Desta forma somaram-se as vazões nos afluentes no quarto e no terceiro dia anterior ao da estimativa criando uma variável de entrada para RNA. Em seguida somaram-se as vazões dos afluentes no terceiro e no segundo dia também anterior, criando outra variável de entrada. Da mesma maneira gerou-se o terceiro elemento do vetor de entrada do modelo M4, com as vazões registradas no segundo e primeiro dia anterior ao início da estimativa.

O modelo M6 primeiramente estima a vazão do posto 5, através de um RNA que possui como variáveis de entrada uma combinação dos modelos M3 e M4 já mencionados. Em seguida, estima-se as vazões do posto de interesse com outra rede neural, que apresenta no vetor de entrada as mesma variáveis dos modelos M3 e M4, acrescido das vazões estimadas do posto 5 obtidas anteriormente.

As demais redes neurais testadas representam uma combinação dos modelos já citados. A Figura 4 mostra o esquema da rede neural M7. Destaca-se a obtenção da série de vazões estimada para o posto 5 ($Q_{est}(t)$) através da variação do modelo M5, o qual passa a ter como valor de saída da rede neural a vazão $Q_5(t)$ (Tabela1).

RESULTADOS E DISCUSSÕES

Em todos os testes realizados 1200 dias dos dados foram utilizados no treinamento, os 871 restantes usou-se na etapa de verificação. Para evitar problema de saturação no processamento, os dados foram normalizados entre -1 e +1, utilizando a seguinte equação:

$$x = 2 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) - 1 \quad (3)$$

em que x_{\max} e x_{\min} representam os valores máximo e mínimo da série. O algoritmo de treinamento que utiliza o método de otimização de *Levenberg-Marquardt* (LM) foi utilizado para ajuste dos pesos. Essa escolha se deu em função de testes realizados com diferentes algoritmos de treinamento em que se verificou que o algoritmo LM foi o que apresentou o menor tempo de processamento, preservando a qualidade dos resultados obtidos. Neste trabalho, os modelos foram construídos e treinados utilizando-se o *Neural Network Toolbox* do *Software* MatLab.

As funções de transferência utilizadas e a composição do vetor de entrada em cada modelo testado são mostradas na Tabela 1. A medida de desempenho utilizada na avaliação dos resultados foi a Raiz do Erro Quadrático Médio (*Root Mean Square Error – RMSE*) dado por:

$$RMSE = \sqrt{\frac{\sum (Q_{obs} - Q_{cal})^2}{N}} \quad (4)$$

em que Q_{obs} representa a vazão observada, Q_{cal} representa a vazão fornecida pela rede e N o número de pontos utilizados no treinamento.

A figura 5 mostra os gráficos referentes à fase de verificação de cada modelo apresentado, assim como os valores de *RMSE* associados.

Tabela 1 – Estrutura dos modelos testados

Modelos	N_e	Entrada	f_{a1}	N_i	f_{a2}	Saída
M1	3	$VE^* = \begin{bmatrix} Q_3(t) \\ Q_3(t-1) \\ Q_3(t-2) \end{bmatrix}$	purelin ²	3	purelin ²	$Q_6(t)$
M2	2	$VE^* = \begin{bmatrix} Q_3(t) \\ Q_3(t-1) \end{bmatrix}$	purelin ²	2	purelin ²	$Q_6(t)$
M3	9	$VE^* = \begin{bmatrix} Q_1(t) \\ Q_1(t-1) \\ Q_1(t-2) \\ Q_2(t) \\ Q_2(t-1) \\ Q_2(t-2) \\ Q_4(t) \\ Q_4(t-1) \\ Q_4(t-2) \end{bmatrix}$	tansig ¹	2	purelin ²	$Q_6(t)$
M4	3	$VE^* = \begin{bmatrix} \sum_{i=1,2,4} (Q_i(t-1) + Q_i(t-2)) \\ \sum_{i=1,2,4} (Q_i(t-2) + Q_i(t-3)) \\ \sum_{i=1,2,4} (Q_i(t-3) + Q_i(t-4)) \end{bmatrix}$	tansig ¹	3	purelin ²	$Q_6(t)$
M5	12	$VE^* = \begin{bmatrix} M3 \\ M4 \end{bmatrix}$	tansig ¹	2	purelin ²	$Q_6(t)$
M6	12	$VE^* = \begin{bmatrix} M3 \\ M4 \end{bmatrix}$	tansig ¹	2	purelin ²	$Q_{5,est}(t)^{**}$
	15	$VE^* = \begin{bmatrix} M3 \\ M4 \\ Q_{5,est}(t) \\ Q_{5,est}(t-1) \\ Q_{5,est}(t-2) \end{bmatrix}$	tansig ¹	2	purelin ²	$Q_6(t)$
M7	12	$VE^* = \begin{bmatrix} M3 \\ M4 \end{bmatrix}$	tansig ¹	2	purelin ²	$Q_{5,est}(t)^{**}$
	15	$VE^* = \begin{bmatrix} M3 \\ M4 \\ \sum_{i=0}^2 (Q_{5,est}(t-i))/3 \\ \sum_{i=1}^3 (Q_{5,est}(t-i))/3 \\ \sum_{i=2}^4 (Q_{5,est}(t-i))/3 \end{bmatrix}$	purelin ²	2	purelin ²	$Q_6(t)$

$N_e = N^\circ$ Neurônios na camada de entrada; $f_{a1} =$ Função de ativação camada intermediária; $N_i = N^\circ$ Neurônios na camada intermediária; $f_{a2} =$ Função de ativação camada de saída; ¹Tangente sigmóide, ²Linear, ³Levenberg-Marquardt, *Entrada para a RNA, **Vazão estimada.




Figura 4 - Estrutura do modelo M7.




Figura 5 - Resultados da verificação dos modelos: (a) M1, (b) M2, (c) M3, (d) M4, (e) M5, (f) M6, (g) M7

Tabela 2 - Valores de *RMSE*

Modelo	Treinamento	Verificação
M1	35,49	153,48
M2	80,57	83,79
M3	87,18	142,57
M4	97,49	195,70
M5	84,41	138,43
M6	86,78	146,63
M7	89,00	137,02

Como é possível observar, o modelo M2 apresentou melhor resultado do que o M1. Os postos 3 e 5 encontram-se localizados no rio principal da sub-bacia de estudo, assim como o próprio posto de interesse. As funções de ativação em ambas as camadas nos dois modelos foi a linear. As elevadas vazões, aliadas sobre tudo com a proximidade das seções monitoradas do rio principal (posto 5 e 6), tornam o comportamento dos três postos semelhantes, o que comprovam a relevância das informações acrescida pelos postos 5 e 3 na estimativa da vazão $Q_6(t)$.

De acordo com a figura 5 e a tabela 2, observou-se ainda que os modelos M3 e M4 separadamente não obtiveram resultados significativos. Entretanto, a junção dos dois modelos (M5) melhorou tanto os valores de *RMSE* obtidos na fase de treinamento e de verificação, como os gráficos expostos na figura 5. As informações acrescidas ao se acumular por dois dias as vazões dos afluentes diminuem a defasagem entre os valores reais observados e os obtidos pelo modelo, e consequentemente reduz o *RMSE*.

Considerou-se no presente trabalho à obtenção das vazões a jusante informando-se apenas as vazões dos afluentes do rio em estudo. A consideração imposta fez com que os modelos M1 e M2 servissem como um comparativo na eficiência das arquiteturas estabelecidas, além de estimularem a criação dos modelos M6 e M7, que possuem na composição do vetor de entrada da rede neural artificial os valores da média de três dias de vazões estimadas do posto 5 ($Q_{5est}(t)$). Apesar de se utilizar vazões estimadas por outra RNA, as informações oriundas do posto 5 são de grande importância. Os erros relacionados à estimativa de tais vazões são superados pelas informações adicionadas. Observa-se uma considerável melhora nos resultados o que estimula a utilização de tal procedimento.

CONCLUSÃO

Este trabalho apresentou a comparação entre sete modelos de RNA, desenvolvidos para estimativa das vazões em uma estação fluviométrica que monitora uma seção do rio Paracatu (Posto 6), localizado na bacia do rio São Francisco.

Constatou-se que o modelo M7 apresentou os menores valores de *RMSE* na verificação e também maior aproximação entre os gráficos da série real e da estimada, quando comparado com os demais modelos que utilizam apenas vazões afluentes do rio.

Considerando como entrada para a RNA as vazões das estações localizadas no rio principal da sub-bacia em questão, observa-se que o modelo M2 apresentou o melhor comportamento da série. Tal fato serviu de ponto de partida para o desenvolvimento do modelo M7, o qual utiliza a vazão estimada do posto 5, em virtude da comprovada relevância demonstrada pelo modelo M2.

AGRADECIMENTOS

Os autores agradecem à CNPq pelo apoio financeiro ao projeto e pela concessão das bolsas de iniciação científica.

REFERÊNCIAS BIBLIOGRÁFICAS

ASCE TASK COMMITTEE ON APPLICATION OF THE ARTIFICIAL NEURAL NETWORKS IN HYDROLOGY (2000a). “*Artificial neural networks in hydrology I: preliminary concepts*”. J. Hydrol. Engng, ASCE 5(2), pp. 115–123.

ASCE TASK COMMITTEE ON APPLICATION OF THE ARTIFICIAL NEURAL NETWORKS IN HYDROLOGY (2000b). “*Artificial neural networks in hydrology II: hydrological applications*”. J. Hydrol. Engng, ASCE 5 (2), pp. 124–137.

RAJURKAR, M. P, KOTHYARI, U. C AND CHAUBEC U. C (2004). “*Modeling of the daily rainfall-runoff relationship with artificial neural network*”. Journal of Hydrology, 285, pp. 96–111.

TOKAR, A. S.; MARKUS, M. (2000). “*Precipitation – runoff modeling using artificial neural networks and conceptual models*”. Journal of Hydrologic Engineering, 5(2), pp. 156-161.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. (1996). *Neural Network Design*. PWS Publishing Company.

HAYKIN, S. (2005). *Neural Networks: A Comprehensive Foundation*. Prentice-Hall, Nova Deli.

MÜLLER, B.; REINHARDT, J. (1990). *Neural Networks: An Intrduction*. Springer-Verlag, Germany.