

DESENVOLVIMENTO DE REDES NEURAIS ARTIFICIAIS PARA A ESTIMATIVA DE VAZÕES DE RIOS

MARIONEI FOMACA DE SOUSA JUNIOR¹, EDUARDO MORGAN ULIANA², LUANA LISBOA³, ESTEVÃO MORGAN ULIANA⁴

¹ Graduando em Engenharia Agrícola, Universidade Federal de Mato Grosso, (66) 99656-6637, mariofomacajr@gmail.com

² Doutor em Engenharia Agrícola, Universidade Federal de Mato Grosso, morganuliana@ufmt.br

³ Doutora em Engenharia Agrícola, CPRM, luana.lisboa@cprm.gov.br

⁴ Graduando em Agronomia, Instituto Federal do Espírito Santo, estevao.morgan@gmail.com

Apresentado no

XLVII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2018
06, 07 e 08 de agosto de 2018 - Brasília - DF, Brasil

RESUMO: A modelagem hidrológica é fundamental em diferentes tipos de estudos relacionados a recursos hídricos, possibilitando o melhor entendimento dos fenômenos que ocorrem na bacia hidrográfica. Dentre os modelos existentes, as redes neurais artificiais (RNAs) têm ganhado espaço no cenário atual por serem capazes de resolver problemas complexos. Com isso, objetivou-se desenvolver RNAs para prever vazões diárias de uma sub-bacia do Rio Teles Pires - Mato Grosso. Os passos para a criação das RNAs foram a coleta e seleção dos dados; definição da arquitetura da rede; treinamento; e validação dos resultados. A seleção dos dados de entrada foi por meio da análise de componentes principais (ACP), sendo analisadas as variáveis precipitação; evapotranspiração de referência; temperatura máxima; temperatura mínima; e vazões defasadas no tempo registradas na estação fluviométrica. Os valores do coeficiente de Nash-Sutcliffe foram 0,93 e 0,94; 0,98 e 0,98; e 0,98 e 0,97, no treinamento e validação, respectivamente para as três RNAs com melhor desempenho. O teste t pareado a 5% permitiu confirmar que estatisticamente os dados preditos e observados não possuem diferenças significativas. Conclui-se que as RNAs são adequadas para estimativa de vazões diárias na área de estudo utilizando vazões defasadas no tempo e precipitação como dados de entrada.

PALAVRAS-CHAVE: gestão de recursos hídricos, inteligência artificial, modelagem hidrológica

DEVELOPMENT OF ARTIFICIAL NEURAL NETWORKS FOR THE ESTIMATION OF RIVER FLOWS

ABSTRACT: The hydrological modeling is fundamental in different types of studies related to water resources, allowing a better understanding of the phenomena that occur in the hydrographic basin. Among the existing models, artificial neural networks (ANNs) have gained space in the current scenario by being able to solve complex problems. The objective was to develop RNAs to predict daily flows of a sub-basin of the Teles Pires River - Mato Grosso. The steps for the creation of the RNAs were the collection and selection of the data; definition of network architecture; training; and validation of results. The selection of the input data was done through principal component analysis (PCA), and the precipitation variables were analyzed; reference evapotranspiration; Maximum temperature; minimum temperature; and time-lagged flows recorded at the fluviometric station. The values of the Nash-Sutcliffe coefficient were 0.93 and 0.94; 0.98 and 0.98; and 0.98 and 0.97, in training and validation, respectively, for the three best performing RNAs. The t test paired at 5% allowed to confirm that statistically the predicted and observed data did not have significant differences. It is concluded that ANNs are suitable for estimating daily flows in the study area using time-lagged flows and precipitation as input data.

KEYWORDS: management of water resources, artificial intelligence, hydrological modeling

INTRODUÇÃO: Os modelos hidrológicos podem ser utilizados em diferentes estudos relacionados a recursos hídricos, permitindo maior entendimento sobre os fenômenos hidrológicos que ocorrem na bacia hidrográfica. São ferramentas importantes para análise de consistência e preenchimento de falhas de séries históricas de vazão; previsão de vazões de projeto para fins de utilização em obras hidráulicas e controle de cheias; previsão de cenários para o planejamento e gestão dos recursos hídricos (TUCCI,

2005). As Redes Neurais Artificiais têm ganhado espaço na modelagem hidrológica devido sua capacidade de extrair a relação entre as entradas e saídas de um processo, sem considerar os processos físicos que estão sendo fornecidos a elas, sendo capazes de aprender e generalizar o conhecimento relacionado a uma série de dados, bem como resolver problemas complexos e de grande escala (GOVINDARAJU, 2000), a exemplo disso a relação chuva-vazão que depende de inúmeros fatores, como umidade inicial do solo, uso e manejo do solo, geomorfologia da bacia hidrográfica, evaporação, infiltração, distribuição, duração da chuva, dentre outros (ARAÚJO et al., 2015). A arquitetura da RNA até chegada nos dados de saída varia e deve ser feita de forma que seja obtido o menor erro de estimativa (ASADI et al., 2013). O desenvolvimento e arquitetura da rede requer elementos básicos, como a definição das variáveis de entrada e saída, números de camadas intermediárias e de neurônios artificiais, além da função de transferência (MENG et al., 2015). Com base nas informações apresentadas, o objetivo do trabalho foi desenvolver Redes Neurais Artificiais (RNAs) e verificar seu desempenho para a estimativa de vazões diárias em cursos de água de uma sub-bacia hidrográfica do Rio Teles Pires-MT.

MATERIAL E MÉTODOS: A área de estudo foi uma sub-bacia hidrográfica do Rio Teles Pires, com área de 10.823,3 Km² (Figura 1). Os dados de entrada foram obtidos do banco de dados da ANA e do INMET, para o período de 01/08/2000 a 1/12/2008 e 01/07/1998 a 31/07/2000, para as etapas de Treinamento e Teste. No desenvolvimento das redes, foram realizados a coleta e seleção dos dados de entrada e saída; a definição da arquitetura da rede; e o treinamento e validação das redes desenvolvidas. A seleção das variáveis de entrada se deu por meio da análise de componentes principais (ACP), permitindo a eliminação daquelas que contribuíram pouco, em termos de variação, no grupo analisado. Analisaram-se as variáveis precipitação, obtida pelo método de Thiessen (BERTONI & TUCCI, 2001); temperatura máxima e mínima; evapotranspiração de referência, calculada pelo método de Camargo (SOUZA et al., 2011) e vazões registradas na estação fluviométrica. Os dados de entrada foram organizados aleatoriamente e normalizados, garantindo que cada dado de entrada receba a mesma atenção durante o treinamento da RNA, implicando melhor eficiência numérica diante das operações matemáticas realizadas pela rede (SILVA et al., 2010). Como paradigma neural foi empregado o Perceptron de múltiplas camadas (ARAÚJO et al., 2015). As funções de transferência escolhidas foram a tangente hiperbólica nas camadas intermediárias e a linear na camada de saída das RNAs (SILVA et al., 2010). O número de neurônios em cada camada intermediária foi definido empiricamente, durante o processo de Treinamento da rede, de forma a obter o menor erro de estimativa das vazões diárias. No Treinamento da rede, foi utilizado o algoritmo *backpropagation* (SILVA et al., 2010), incorporado ao algoritmo de otimização de Levenberg-Marquardt (ASADI et al., 2013), minimizando o esforço computacional e a convergência muito lenta, decorrente da utilização de forma isolada do algoritmo *backpropagation*. Durante o treinamento, estabeleceu-se um limite máximo de épocas (*epochs*), como critério adicional de parada do algoritmo, caso a precisão especificada se tornar inalcançável.

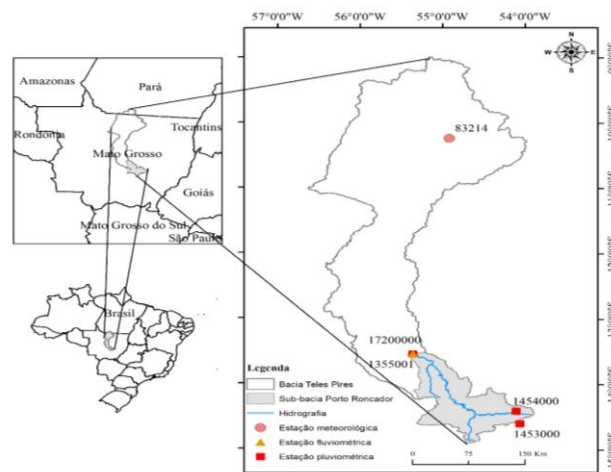


FIGURA 1. Localização da bacia hidrográfica do rio Teles Pires e das estações pluviométricas, fluviométrica e meteorológica utilizadas no estudo.

Para validação do resultado das RNAs, foram utilizadas as medidas estatísticas (KRAUSE et al., 2005; STONE, 1993): erro absoluto médio (MAE); raiz do erro quadrático médio (RMSE); viés; teste t pareado a 5% de significância; índice de concordância de Willmott (d); e índice de eficiência de Nash-Sutcliffe (E). $E = 1$ significa ajuste perfeito dos dados preditos pelo modelo; $E \geq 0,75$ indica que o modelo é adequado e bom; $0,36 < E < 0,75$ indica que o modelo é satisfatório; e $0,36 \leq E$ indica que o modelo não é satisfatório (VAN LIEW et al., 2007).

RESULTADOS E DISCUSSÃO: Na Tabela 1 podem ser observadas informações referentes à arquitetura, bem como as medidas quantitativas do desempenho das Redes Neurais Artificiais (RNAs) desenvolvidas para a estimativa das vazões diárias na Seção de Controle Porto Roncador (17200000).

TABELA 1. Informações referentes à arquitetura, treinamento, teste e medidas quantitativas do desempenho das Redes Neurais Artificiais (RNAs) desenvolvidas para a estimativa das vazões diárias na Seção de Controle Porto Roncador (17200000).

Etapa	Entrada	Épocas	n1	n2	MAE	RMSE	Viés	d	E	t
Treinamento	Q _{mt-4}	309	5	9	38,72	73,51	2,45	0,98	0,93	1,87 ^(NS)
Treinamento	Q _{mt-2} Q _{mt-3} P	254	3	6	20,06	36,96	-0,72	1,00	0,98	1,09 ^(NS)
Treinamento	Q _{mt-2} Q _{mt-3} Q _{mt-4}	320	7	3	20,82	39,64	-0,44	1,00	0,98	0,61 ^(NS)
Teste	Q _{mt-4}	-	5	9	36,81	74,38	3,68	0,98	0,94	1,16 ^(NS)
Teste	Q _{mt-2} Q _{mt-3} P	-	3	6	20,75	38,55	-0,52	1,00	0,98	0,32 ^(NS)
Teste	Q _{mt-2} Q _{mt-3} Q _{mt-4}	-	7	3	21,70	46,04	-0,59	0,99	0,97	0,35 ^(NS)

P é a precipitação média da bacia no tempo t (mm) obtida pelo método de Thiessen; Q_{mt-n} é a vazão média de n (2, 3, ..., n) dias anteriores ($m^3 s^{-1}$); e n1 e n2 são o número de neurônios artificiais na primeira e na segunda camada intermediária, respectivamente. MAE é o erro absoluto médio ($m^3 s^{-1}$); RMSE é a raiz do erro quadrático médio ($m^3 s^{-1}$); d é o índice de concordância de Willmott; E é o índice de eficiência de Nash-Sutcliffe; t é o valor da estatística de teste do teste t pareado; (NS) não significativo a 5% de significância.

Os modelos de RNA são bons para estimativa de vazões diárias na bacia, tendo em vista que apresentaram valores do índice de Willmott (d) próximos a 1 e coeficientes de Nash-Sutcliffe superiores a 0,75 em todas as etapas e configurações dos dados de entrada. Os valores do viés apontaram superestimativa dos dados simulados pelas RNAs na maior parte das configurações. O teste t pareado ao nível de 5% de significância indicou confiabilidade dos dados, uma vez que os valores de vazão preditos pelas RNAs não diferem estatisticamente dos dados observados com 95% de probabilidade. Quanto aos valores do MAE e do RMSE, tem-se que variaram entre 20,055 e 38,722 $m^3 s^{-1}$ e entre 36,963 e 74,383 $m^3 s^{-1}$, respectivamente. O distanciamento entre os valores de MAE e RMSE permite afirmar que a variância dos erros individuais é pequena (Tabela 1).




FIGURA 2. Hidrograma das vazões diárias observadas na Seção de Controle Porto Roncador e estimadas com Rede Neural Artificial com as variáveis de entrada Q_{mt-2}; Q_{mt-3}; P.

A Figura 2 representa o hidrograma da RNA que apresentou melhor desempenho para a predição de vazões diárias. Por meio de avaliação visual, nota-se boa concordância com os valores de vazão observados, destacando a eficiência do modelo na simulação das vazões máximas e mínimas.

Resultados semelhantes foram obtidos por Kisi (2005) ao estimar vazões diárias de rios utilizando redes neurais artificiais. O referido autor obteve diferenças entre os valores observados e os simulados por RNA de até 2% nos picos de vazão. Ao analisar a Tabela 1, percebe-se que todas as arquiteturas de RNA tiveram como variáveis de entrada dados que representassem o armazenamento, isto é, a vazão de dias anteriores observadas no local de interesse para predição de vazão, o que segundo Oliveira et al. (2013) condiciona o bom desempenho de um modelo de Redes Neurais Artificiais para previsão de vazões. Os resultados apresentados para a sessão de controle Porto Roncador assinalam que o uso da precipitação média com dado de entrada é importante, mas não suficiente para se obter boa exatidão na estimativa de vazões diárias. Dessa forma, faz-se necessário o uso de vazões defasadas no tempo. Com base nos resultados expostos, nota-se que RNAs possuem grande potencial para o uso na predição de vazão de curto prazo e no preenchimento de falhas de séries históricas na sub-bacia Porto Roncador.

CONCLUSÕES: Com base nos resultados obtidos, conclui-se que as Redes Neurais Artificiais são eficazes na predição de vazões diárias; as variáveis de entrada das RNAs que apresentaram melhor desempenho para estimativa das vazões diárias foram as vazões do curso de água defasadas no tempo e a precipitação; o resultado satisfatório das RNAs para previsão de vazões está associado a utilização de vazões do rio registradas em dias anteriores por representarem o efeito do armazenamento.

AGRADECIMENTOS: Os autores agradecem a Fundação de Amparo à Pesquisa do Estado de Mato Grosso (FAPEMAT) pelo apoio financeiro ao projeto de pesquisa e a Universidade Federal de Mato Grosso pela concessão da bolsa de PIBIC do primeiro autor.

REFERÊNCIAS:

- ARAÚJO, C. B. C. D.; NETO, S. A. D.; FILHO, F. D. A. S. Streamflow forecasting for the dam Orós/CE from hydrometeorological data using perceptrons. **Revista Brasileira de Meteorologia**, v. 30, p. 37-46, 2015.
- ASADI, S.; SHAHRABI, J.; ABBASZADEH, P.; TABANMEHR, S. A new hybrid artificial neural networks for rainfall-runoff process modeling. **Neurocomputing**, v. 121, p. 470-480, 2013.
- BERTONI, J.C.; TUCCI, C. E. M. Precipitação. In: TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. Porto Alegre: ABRH, Universidade Federal do Rio Grande do Sul, 2001. p. 177-241.
- GOVINDARAJU, R. S. Artificial neural networks in hydrology I: preliminary concepts. **Journal of Hydrologic Engineering**, v. 5, n. 2, p. 115-123, 2000.
- KISI, O. Daily River Flow Forecasting Using Artificial Neural Networks and Auto-Regressive Models. **Turkish J. Eng. Env. Sci.** v. 29, p. 9-20, 2005.
- KRAUSE, P.; BOYLE, D. P.; BÄSE, F. Comparison of different efficiency criteria for hydrological model assessment. **Advances in Geosciences**, v. 5, p. 89-97, 2005.
- MENG, X.; YIN, M.; NING, L.; LIU, D.; XUE, X. A threshold artificial neural network model for improving runoff prediction in a karst watershed. **Environmental Earth Sciences**, v. 74, n. 6, p. 5039-5048, 2015.
- OLIVEIRA, G. G.; PEDROLLO, O. C.; CASTRO, N. M. R.; BRAVO, J. M. Simulações hidrológicas com diferentes proporções de área controlada na bacia hidrográfica. **Revista Brasileira de Recursos Hídricos**, v. 18, n. 3, p. 193-204, 2013.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Editora Artliber, 2010.
- SOUZA, A. P.; CARVALHO, D.F.; SILVA, L.B.D.; ALMEIDA, F. T.; ROCHA, H.S. Estimativas da evapotranspiração de referência em diferentes condições de nebulosidade. **Pesquisa Agropecuária Brasileira**, v.46, n.3, p.219-228, 2011.
- STONE, R. J. Improved statistical procedure for the evaluation of solar radiation estimation models. **Solar Energy**, v. 51, n. 4, p. 289-291, 1993.
- TUCCI, C.E.M. **Modelos Hidrológicos**. Porto Alegre: Editora da Universidade/UFRGS e ABRH; 2005.
- VAN LIEW, M. W.; VEITH, T. L.; BOSCH, D. D.; ARNOLD, J. G. Suitability of SWAT for the conservation effects assessment project: a comparison on USDA-ARS watersheds. **Journal of Hydrologic Engineering**, v. 12, n. 2, p.173-189, 2007.