

PREVISÃO DE VAZÃO DA BACIA DO RIBEIRO JOÃO LEITE UTILIZANDO REDES NEURAS ARTIFICIAIS

Júlio César Ferreira¹; Mônica Sakuray Pais²; Keiji Yamanaka³; Gilberto Arantes Carrijo⁴; Marconi Batista Teixeira⁵; Rogério Teixeira da Silva⁶; Clarisse Guimarães Rabelo⁷

¹Matemático, doutorando em engenharia elétrica – Universidade Federal de Uberlândia, MG, Prof. Instituto Federal Goiano – Campus Urutaí, IFGoiano, Rod. Geraldo Silva Nascimento Km 2,5, Urutaí, GO. CEP 75790-000. Fone: (64) 3464-1900. e-mail: jc@ifgoiano.edu.br

²Bacharel em Ciência da Computação, doutoranda em engenharia elétrica, Universidade Federal de Uberlândia, MG, Prof^a. Instituto Federal Goiano – Campus Urutaí, Rod. Geraldo Silva Nascimento Km 2,5, Urutaí, GO. CEP 75790-000. Fone: (64) 3464-1900. e-mail: monicaspais@gmail.com

³Prof. Associado, Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia – UFU, campus Santa Mônica, Av. João Naves de Ávila 2160, Uberlândia, MG. CEP 38400-902. Fone: (34) 3239-4706. e-mail: keiji@ufu.br

⁴Prof. Titular, Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia – UFU, campus Santa Mônica, Av. João Naves de Ávila 2160, Uberlândia, MG. CEP 38400-902. Fone: (34) 3239-4706. e-mail: gilberto@ufu.br

⁵Eng. Agrônomo, Prof. Doutor Instituto Federal Goiano – Campus Rio Verde, IFGoiano, Rio Verde, GO. C.P. 66, CEP 75901-970. e-mail: marconibt@gmail.com

⁶Eng. Agrícola, Prof. Doutor Centro Universitário Adventista de São Paulo – UNASP, Engenheiro Coelho, SP, C.P. 11, CEP 13165-970. e-mail: rogerio.teixeira.silva@hotmail.com

⁷Geógrafa, Mestre em Engenharia do Meio Ambiente, Universidade Federal de Goiás – UFG – Campus Samambaia (Campus II), Goiânia, GO. C.P. 131, CEP 74001-970. e-mail: clarisserabelo1981@gmail.com

1 RESUMO

A manutenção da água, recurso finito em padrões de quantidade e qualidade, representa um desafio para a sociedade e exige estudo sobre conservação, manutenção, escoamento e tratamento. O modelo de previsão de vazão e o modelo de transformação precipitação-vazão desenvolvidos neste trabalho para a bacia do Ribeirão João Leite, em Goiás, utilizaram Redes Neurais Artificiais (RNA) com múltiplas camadas e treinamento pelo algoritmo de *Levenberg-Marquardt*. Elaborou-se a entrada da RNA a partir das séries históricas dos dados diários de precipitação e vazão observadas nos postos pluviométricos e fluviométricos existentes ao longo da bacia em um período de seis anos, de 1991 a 1997. Os dados foram pré-processados para correção de casos de inconsistência ou inexistência e o cálculo da precipitação média diária foi realizado pelo método de Thiessen. O uso do algoritmo de *Levenberg-Marquardt* possibilitou explorar diversas combinações de parâmetros de configuração para escolha do melhor modelo, com melhores resultados que os modelos conceituais existentes.

Palavras-chave: precipitação, modelagem, algoritmo, redes neurais artificiais.

FERREIRA, J. C.; PAIS, M. S.; YAMANAKA, K.; CARRIJO, G. A.; TEIXEIRA, M. B.; SILVA, R. T. da; RABELO, C. G.
INFLOW FORECASTING OF THE JOAO LEITE RIVER BASIN USING ARTIFICIAL NEURAL NETWORK

2 ABSTRACT

This paper provides a model that represents the behavior of the hydrological basin of the João Leite river, in Goiás, helping managers of water resources in their decision-making. The presented inflow forecasting model and rainfall-runoff model use Artificial Neural Networks (ANN) with multiple layers and the *Levenberg-Marquardt* learning algorithm. The input is the time series data of observed daily precipitation and observed daily inflows measured by stations along of the Joao Leite basin, in a period of six years, from 1991 to 1997. The data were pre-processed to correct cases of inconsistency or missing information, and the computation of the average daily precipitation was performed by the Thiessen method. The *Levenberg-Marquardt* training algorithm allowed exploring different combinations of configuration parameters for selecting the best model. The results obtained by the presented model show the feasibility of using ANNs in the modeling of river basins and better results than the conceptual models.

Keywords: precipitation, modeling, algorithm, artificial neural networks.

3 INTRODUÇÃO

A água é um recurso natural que apresenta os mais variados usos e é indispensável ao desenvolvimento humano. A manutenção desse recurso finito em padrões de quantidade e qualidade representa um desafio para a sociedade e exige estudos sobre conservação, manutenção, escoamento e tratamento de água. Nesse sentido, estudos que proponham desenvolver modelos para representar o comportamento hidrológico de bacias são cada vez mais valorizados.

A bacia hidrográfica do ribeirão João Leite está localizada na região Centro-Oeste do Brasil e é a principal fonte de abastecimento de Goiânia, capital do Estado de Goiás. Portanto, modelos de previsão de vazão confiáveis para esta área tem importância estratégica.

3.1 Modelos de Previsão de Vazão

Modelos de precipitação-vazão são complexos devido à grande quantidade de variáveis envolvidas (precipitação, condensação, infiltração, interceptação, escoamento superficial e subterrâneo, percolação, evapotranspiração). Outra dificuldade é a não linearidade entre essas variáveis e sua modificação no tempo e no espaço.

Os modelos atuais, denominados de modelos conceituais, procuram, com certo grau de precisão, simular os processos físicos da bacia hidrográfica. Após a calibração de tais modelos, são alterados os parâmetros e verificam-se os impactos de tais alterações sobre a bacia hidrológica. Apesar de fornecerem bons resultados, os modelos conceituais apresentam certas dificuldades, tais como: dificuldade na interpretação do algoritmo, incerteza fora do intervalo de ajuste, grande número de parâmetros a serem calibrados, necessidade de conhecimento aprofundado de hidrologia e levantamento de dados no campo.

O modelo PREVIVAZH, desenvolvido pelo Centro de Pesquisas de Energia Elétrica – CEPTEL (COSTA et al., 2000), é o mais empregado. Ele consiste em utilizar apenas informações históricas de vazões observadas. A análise de desempenho disponibilizada para esse modelo, ao longo dos anos, mostra que os índices Mape (Erros Médios Absolutos Percentuais) estão entre 10% e 52%, onde:

$$Mape = \frac{1}{N} \sum_{i=1}^N \frac{|v_{previsto_i} - v_{observado_i}|}{v_{observado_i}} 100 \quad (1)$$

Sendo assim, o sistema de precipitação-vazão é não linear e complexo. Uma alternativa aos modelos conceituais são os modelos baseados em Redes Neurais Artificiais, que procuram relacionar entrada e saída sem se fazer necessário simular todo o ciclo hidrológico.

Flexibilidade: Uma rede neural não pode lidar com grandes mudanças na informação de entrada, tais como sinais ruidosos ou outras alterações na entrada (por exemplo, se a informação de entrada é a imagem de um objeto, a correspondente resposta mantém-se inalterado, se a imagem muda um pouco de brilho ou o objeto muda um pouco)

3.2 Redes Neurais Artificiais

Segundo (HAYKIN, 1999), Redes Neurais Artificiais (RNA) são modelos paralelos distribuídos, compostos por unidades de processamento simples, chamadas de neurônios, interligadas entre si e com o ambiente. As RNAs aprendem através de exemplos e as conexões entre os neurônios estão associadas a pesos que armazenam o conhecimento da rede. As redes possuem grande habilidade para lidar com problemas complexos, imprecisos e com grandes mudanças na informação de entrada tais como casos de inconsistência ou ausência de dados nas séries históricas de precipitação e vazão, o que justifica seu uso em previsão de vazão. A arquitetura mais utilizada, nesta metodologia, para resolver problemas não lineares é a de redes de múltiplas camadas - *Multilayer Perceptron* (MLP). Essa arquitetura é organizada em camadas, com neurônios que podem estar conectadas aos neurônios da camada posterior.

O algoritmo de treinamento das RNAs de múltiplas camadas mais utilizado é o algoritmo da retropropagação do erro (*backpropagation*). Ao se apresentar um determinado padrão de entrada e o respectivo padrão de saída a uma RNA não treinada, uma saída aleatória é produzida. A partir da saída produzida pela rede é calculado um erro, representando a diferença entre o valor obtido e o desejado. O objetivo do treinamento consiste em reduzir continuamente o erro até um determinado valor aceitável. Cada camada tem seus pesos ajustados de modo a minimizar o erro da rede. Uma vez definidos os pesos, a rede obtém o procedimento necessário para executar adequadamente o processo desejado para dados diferentes dos fornecidos no treinamento. Existem algumas variações do algoritmo de retropropagação do erro básico que são inspirados em técnicas de otimização numérica, como o gradiente conjugado, *Quasi-Newton* e *Levenberg-Marquardt* (LM).

3.3 Algoritmo *Levenberg-Marquardt* (LM)

O algoritmo LM foi projetado para se aproximar da velocidade dos algoritmos de treinamento de segunda-ordem, sem ter que calcular a matriz Hessiana. Quando a função objetivo tem a forma do somatório de potências:

$$\varepsilon(n) = \frac{1}{N} \sum_{i=1}^N [d_j(n) - y_j(n)]^2 \quad (2)$$

onde $d_j(n)$ é a saída desejada para o neurônio j e $y_j(n)$ é a saída calculada para o neurônio j . Então a matriz Hessiana pode ser aproximada como:

$$H = J^T J \quad (3)$$

e o gradiente pode ser calculado como:

$$g = J^T e \quad (4)$$

onde J é a matriz Jacobiana que contém as primeiras derivadas dos erros da rede em relação aos pesos e bias; e e é o vetor de erros da rede.

A matriz Jacobiana pode ser calculada pela técnica padrão de retropropagação do erro que é uma maneira bem menos complexa que o cálculo da matriz Hessiana, de forma que J é a matriz Jacobiana que contém as primeiras derivadas dos erros da rede em relação aos pesos e bias da rede neural artificial (HAGAN e MENHA, 1994).

A atualização dos pesos e bias é feita por:

$$x_{j+1} = x_j - [J^T J + \mu * I]^{-1} J^T e \quad (5)$$

Quando o escalar μ é zero, o método torna-se o método de Newton usando a aproximação da matriz Hessiana (HAGAN e MENHA, 1994). Quando μ é grande, ele torna-se o método do gradiente descendente com passo de tamanho pequeno. O método de Newton é mais rápido e mais preciso quando perto de um erro mínimo, e desta forma o objetivo é ir em direção ao método de Newton o mais rápido possível. Então, o valor de μ é decrementado após cada passo em que houver redução da função objetivo e é aumentado somente quando é verificado que se o passo for executado haverá um aumento da função objetivo. Desta forma, a função objetivo é sempre reduzida a cada iteração do algoritmo.

Para o treinamento com o algoritmo de LM são necessários os parâmetros: μ , μ_{dec} , μ_{inc} e μ_{max} . O parâmetro μ é o valor inicial de μ . Este valor é multiplicado por μ_{dec} sempre que a função objetivo é reduzida em um dado passo. É multiplicada por μ_{inc} sempre que é verificado se a execução de um passo implicará no aumento da função objetivo. Se μ torna-se maior que μ_{max} , o algoritmo cessa.

A descrição original do algoritmo de LM está em (MARQUARDT, 1963), e uma aplicação do algoritmo no treinamento de redes neurais aparece em Duda et al. (2001) e em Hagan e Menha (1994).

Este algoritmo é eficiente e rápido para redes neurais MLP de tamanho moderado (até algumas centenas de pesos) e possui uma implementação eficiente no software MATLAB®, onde o cálculo da equação com matriz é uma função *built-in* do software. Apesar da grande eficiência do algoritmo LM, o custo computacional é grande, pois o tamanho da matriz J é determinado pelo número de padrões de treinamento, bias e pesos.

Nesse contexto, objetivou-se desenvolver um algoritmo computacional capaz de construir uma Rede Neural Artificial para prever a vazão diária para um dia seguinte a dados fornecidos e comparar os resultados obtidos com trabalho semelhante realizado por Figueiredo et al. (2007) para a bacia hidrográfica do Ribeirão João Leite.

4 MATERIAL E MÉTODOS

A área objeto de estudo foi a bacia hidrográfica do Ribeirão João Leite, cujo curso principal e seus afluentes percorrem os municípios de Ouro Verde, Campo Limpo, Anápolis, Goianápolis, Terezópolis de Goiás, Nerópolis e Goiânia (Figura 1). O Ribeirão João Leite é um importante afluente do Rio Meia Ponte e este, por sua vez, pertence à bacia hidrográfica do Rio Paranaíba.

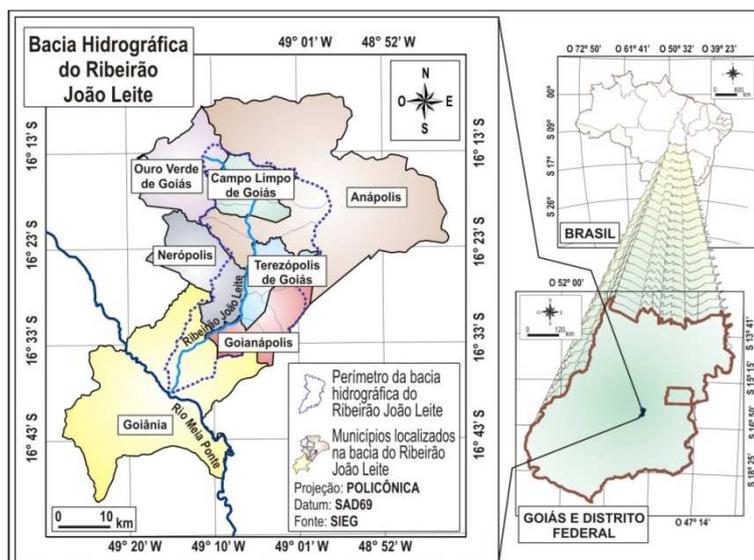


Figura 1. Localização da bacia hidrográfica do Ribeirão João Leite. Fonte: (RABELO, 2009).

4.1 Características morfométricas

A bacia hidrográfica do Ribeirão João Leite é composta por uma área equivalente a 764 km², com precipitação anual de 1589 mm (média aritmética), sendo o comprimento do Ribeirão João Leite igual a 86 km e o comprimento total dos cursos d'água igual a 679,88 km. Na Tabela 1 estão destacadas as demais características morfométricas (escala 1:50.000) da bacia hidrográfica do Ribeirão João Leite.

Tabela 1. Características morfométricas da Bacia hidrográfica do Ribeirão João Leite

Coeficiente de compacidade		1,59
Fator de forma		0,10
Densidade de drenagem		0,89
Extensão média do escoamento superficial		0,29
Comprimento do talvegue principal (km)		48,58
Sinuosidade do curso d'água		1,77
Altitude (m)	mínima	696
	média	920
	máxima	1143
Declividade (m/m)	média	4,8
	máxima	25,7

O clima regional da área da bacia é do tipo AW, segundo a classificação de Koeppen. A Figura 2 mostra o comportamento da precipitação pluvial durante o período analisado.

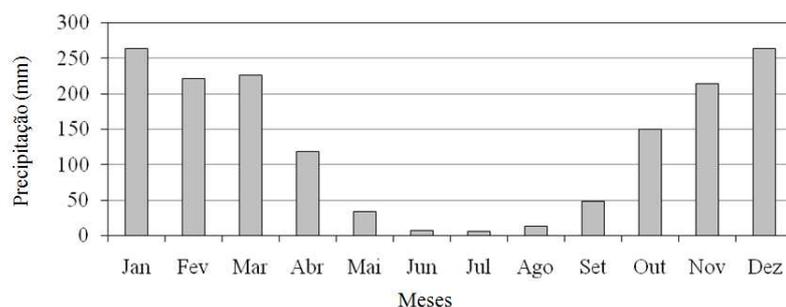


Figura 2. Distribuição da precipitação pluvial media mensal (1973/2007) na bacia hidrográfica do Ribeirão João Leite. Fonte: Série histórica dos postos pluviométricos Jaraguá, Fazenda Boa Vista, Ouro Verde de Goiás, Goianópolis, Ponte Anápolis/Brasília (HIDROWEB, 2009), CCTA/Secretaria da Agricultura, Goiânia/Agronomia e Embrapa Arroz e Feijão (ASSAD, 2005).

A Figura 3 mostra a distribuição hierárquica das drenagens que compõem a bacia hidrográfica do Ribeirão João Leite e a localização de alguns de seus principais corpos d'água.

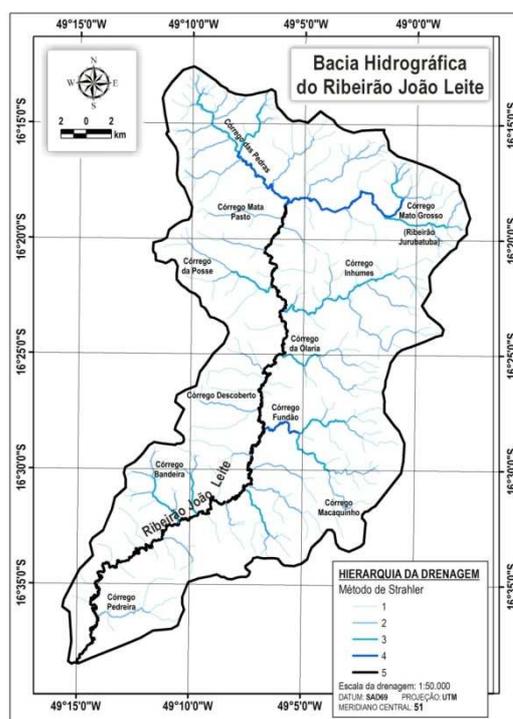


Figura 3. Hierarquia da drenagem na bacia hidrográfica do Ribeirão João Leite segundo o método de Strahler e localização de alguns de seus principais corpos d'água. Fonte: (RABELO, 2009).

4.2 Séries Históricas

Os dados de precipitação e vazão diária foram disponibilizados pelo Sistema Nacional de Informações Hidrológicas coordenado pela Agência Nacional de Águas (ANA), através de seu site. Na Tabela 2, estão apresentadas as principais informações das estações pluviométricas e da estação fluviométrica empregadas nesse estudo.

Tabela 2. Informações das três estações pluviométricas e da estação fluviométrica Captação João Leite.

CÓDIGO	NOME	MUNICÍPIO	LATITUDE	LONGITUDE
1649004	Goianápolis	Goianápolis	16°51'64" S	49°02'03" O
1649005	Goiânia – Agronomia	Goiânia	16°66'67" S	49°26'67" O
1649009	Ouro Verde de Goiás	Ouro Verde de Goiás	16°22'81" S	49°14'36" O
60642000	Captação João Leite	Goiânia	15°30'00" S	49°14'34" O

Os dados utilizados para a construção do modelo de previsão de vazão foram divididos em dois tipos:

- Precipitação diária observada em três estações pluviométricas, em *mm*, de 1 janeiro de 1991 a 31 de julho de 1997;
- Vazão diária observada na estação de captação João Leite, em $m^3 s^{-1}$, para o mesmo período.

Os dados disponíveis na Agência Nacional de Águas possuem inconsistência, falhas de dias e até anos. Além disso, a estação pluviométrica Goiânia-Agronomia foi desativada em 1997.

4.3 Pré-processamento de Dados

Para o cálculo da precipitação média diária utilizou-se o método de polígonos de Thiessen. Segundo Pinto et al. (1976), o método consiste em calcular a área influenciada por cada estação (polígono) e utilizá-la como pesos para o cálculo da média ponderada a cada dia, através da equação abaixo:

$$h_m = \sum_{i=1}^n \left[\frac{A_i}{\sum A_i} 100 \right] h_i \quad (6)$$

onde h_m é a precipitação média (mm), A_i é a subárea i (m^2) e h_i é a precipitação na subárea i (mm)

Para os casos de inconsistência ou ausência de dados em uma estação ou mais, utilizou-se o método de Thiessen para calcular a precipitação média diária. Neste caso, foi feito um recálculo de novos pesos para as estações que possuíam dados, deixando-se o peso da estação ausente de fora, através da seguinte equação:

$$novo_{\text{peso}} = \frac{\text{peso}_{\text{antigo}}}{\sum \text{pesos}_{\text{postos}} - \sum \text{pesos}_{\text{ausentes}}} \quad (7)$$

Após uma análise minuciosa dos dados, eles foram divididos em dados de entrada e de saída. Os dados de entrada consistiram das precipitações médias e das vazões observadas e os dados de saída das vazões observadas. Posteriormente, os dados foram separados em dois conjuntos: um conjunto para treinamento constituído por 2192 dias, e o outro estritamente para teste da rede constituído por 212 dias:

- treinamento - uma matriz de entrada com 2 linhas e 2192 colunas, onde a primeira linha apresenta as precipitações, a segunda apresenta as vazões e as colunas, os dias observados. E uma matriz de saída com 1 linha e 2192 colunas contendo as vazões diárias observadas.

- teste - uma matriz de entrada com 2 linhas e 212 colunas, onde a primeira linha apresenta as precipitações, a segunda linha apresenta as vazões e as colunas, os dias observados. E uma matriz de saída com 1 linha e 212 colunas contendo as vazões diárias observadas.

Devido ao fato de a maioria das funções de ativação utilizadas em redes neurais artificiais trabalhar com dados entre -1 e 1 ou entre 0 e 1 e ao fato de precipitação e vazão estarem em escala diferentes, foi necessário normalizar os dados.

Semelhante a Sajikumar e Thandaveswara (1999), neste trabalho foi utilizada a seguinte equação de normalização:

$$x_{norm} = F_{min} + \frac{x - x_{min}}{x_{max} - x_{min}} (F_{max} - F_{min}) \quad (8)$$

onde x_{norm} é o valor normalizado, x é o valor a ser normalizado, F_{min} e F_{max} são os valores a serem definidos, x_{max} é o menor valor dos dados e x_{min} é o maior valor dos dados.

Por último, os dados foram agrupados em pares (X,y) , onde X foi constituído de sete valores de precipitações, sete valores de vazões e um valor da última vazão e y foi a vazão do oitavo dia em relação aos sete anteriores. Deste modo, passou-se a ter 2185 pares no formato a seguir:

$$(p_1 p_2 p_3 p_4 p_5 p_6 p_7 v_1 v_2 v_3 v_4 v_5 v_6 v_7 v_8, y) \quad (9)$$

Estes dados foram apresentados na entrada da rede no seguinte percentual: 60% para treinamento, 20% para validação e 20% para teste, ou seja, 1311, 437 e 437, respectivamente.

5 RESULTADOS E DISCUSSÃO

Os resultados mostrados na Tabela 3 enfatizam que o melhor desempenho, considerando o menor Mape e a maior correlação linear R , foi alcançado pela configuração 9.

Tabela 3. Variação de parâmetros de treinamento

#	Parâmetros			Treino		Teste		Nº de entradas no teste	η
	Nº de entradas treinamento	Neurônios na camada oculta	Normalização	Mape (%)	R	Mape (%)	R		
1	2185	17	[.05-.95]	6.26	0.97	11.61	0.82	212	rand
2	2185	22	[.05-.95]	6.85	0.97	12.10	0.53	212	rand
3	2185	30	[.05-.95]	6.65	0.97	24.80	0.34	212	rand
4	2185	100	[.05-.95]	6.67	0.98	30.67	0.58	212	rand
5	2185	17	[.1-.9]	5.30	0.96	12.18	0.77	212	rand
6	2185	30	[.1-.9]	5.10	0.98	11.93	0.74	212	rand
7	2185	100	[.1-.9]	4.82	0.97	25.36	0.31	212	rand
8	2185	17	[.3-.7]	1.90	0.96	10.36	0.84	212	rand
9	2185	30	[.3-.7]	1.85	0.97	10.05	0.84	212	rand
10	2185	47	[.3-.7]	1.88	0.96	11.21	0.81	212	rand
11	2185	30	[.3-.7]	1.83	0.96	11.28	0.71	212	.01
12	2185	30	[.3-.7]	1.95	0.96	11.71	0.74	212	.001
13	2185	30	[.3-.7]	1.83	0.96	13.05	0.66	212	.1

14	1000	30	[.3-.7]	1.92	0.93	16.11	0.90	1397	rand
15	2185	47	[.2-.5]	2.03	0.96	10.91	0.80	212	rand
16	1700	30	[.3-.7]	1.94	0.95	15.23	0.90	704	rand
17	1500	30	[.3-.7]	1.97	0.96	14.76	0.82	904	rand
18	1000	30	[.3-.7]	1.94	0.95	16.88	0.90	1404	rand
19	700	30	[.3-.7]	2.11	0.94	14.32	0.94	1704	rand
20	500	30	[.3-.7]	2.13	0.96	13.90	0.92	1904	rand
21	200	30	[.3-.7]	0.61	0.99	20.86	0.81	2204	rand
22	100	30	[.3-.7]	0.44	0.99	97.94	0.05	2304	rand
23	50	30	[.3-.7]	0.00	1	24.30	0.88	2354	rand
24	10	30	[.3-.7]	0.00	□	626.79	0.64	2394	rand

Para a obtenção dos dados mostrados na Tabela 3 realizaram-se 24 baterias de testes com 200 repetições em cada bateria. Fixaram-se alguns parâmetros da configuração da RNA, tais como: camada intermediária, função de ativação logarítmica sigmóide na camada intermediária e linear na camada de saída, percentagens 60–20–20 de apresentação dos dados; e variou-se o número de neurônios na camada oculta, normalização e número de entradas no treinamento.

Baseado nessa configuração armazenou-se o Mape e o coeficiente de correlação R entre a saída observada e a prevista para duas situações: o momento de TREINO e o momento de TESTE.

A partir desse momento, definiu-se a linha 9 da Tabela 3 como a configuração utilizada no modelo. Neste contexto, utilizaram-se as sete últimas precipitações, as sete últimas vazões e a última vazão, todas observadas, de forma a prever a vazão do dia subsequente para alguns exemplos.

Em Figueiredo et al. (2007) foram realizadas previsões diárias para 1 dia entre as bacias UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório usando Redes Neurais Backpropagation (*Levenberg-Marquardt*) com 11 neurônios na camada oculta e o Mape resultante foi igual a 10,46. Já para as análises realizadas neste trabalho para a bacia do Ribeirão João Leite utilizou-se RNAs com 30 neurônios, obtendo-se valor de Mape igual a 10,05.

A Tabela 4 mostra a previsão para o dia 18 de abril de 1997 e para o dia 8 de janeiro de 1997, sendo importante salientar que estes dias não fazem parte dos dados de treinamento. Na Tabela 4 estão mostradas as duas previsões geradas: a primeira linha das partes correspondente à cada previsão mostra os valores da precipitação diária e a segunda linha os valores da capacitação diária. Na última coluna temos os valores da vazão observada e da vazão calculada, juntamente com o erro obtido.

Tabela 4. Duas previsões diárias nos meses de abril e janeiro de 1997

Ano: 1997							
11/abr	12/abr	13/abr	14/abr	15/abr	16/abr	17/abr	18/abr
0,00	0,00	0,00	0,00	6,02	0,42	3,28	Q _{observada} : 9,49
7,97	7,81	7,67	7,81	7,81	7,81	9,32	Q _{prevista} : 9,04
							Erro: 4,74%
1/jan	2/jan	3/jan	4/jan	5/jan	6/jan	7/jan	8/jan
0,00	15,70	0,00	0,00	10,02	0,68	3,84	Q _{observada} : 13,76
6,94	7,65	15,72	15,55	10,64	8,51	10,08	Q _{prevista} : 10,20
							Erro: 25,87%

Após a obtenção e armazenamento dos melhores pesos para as opções de treinamento anteriormente definidas, foram feitas diversas previsões de 1 dia para verificar a capacidade da rede em responder corretamente, como mostra o gráfico apresentado na Figura 4.

Desse modo, armazenaram-se os melhores pesos para serem aplicados no conjunto total de dados, permitindo a verificação da capacidade de modelagem do sistema hidrológico (Figura 4).

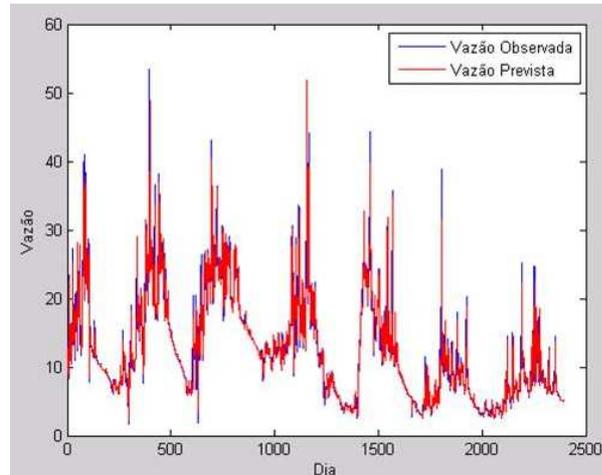


Figura 4. Modelo hidrológico de vazão para o intervalo de 01/01/1991 a 31/07/1997.

Observa-se pela Figura 4 que ocorreu bom ajuste do modelo previsto em relação ao modelo observado, inclusive a partir do 2192 dia, cujos dados não foram utilizados no treinamento da rede. Para esse modelo, obteve-se Mape igual a 8,66 e correlação entre vazão observada e vazão prevista igual a 0,96. Além disso, verificou-se a dificuldade da rede responder a vazões extremas e há mudanças drásticas no comportamento de vazão ou de precipitação.

Para mudanças bruscas na vazão observou-se que a rede não permitiu ajuste adequado dos dados observados em relação aos dados previstos para um primeiro momento. No entanto, após tais mudanças bruscas a função aproximou-se adequadamente dos valores observados, indicando boa correlação linear entre vazão prevista e vazão observada para os dados ajustados.

Dessa forma, RNAs bem treinadas e parametrizadas podem ser utilizadas satisfatoriamente na modelagem de previsões de vazões.

A Figura 5 mostra a regressão linear para o modelo computacional gerado pela RNA.

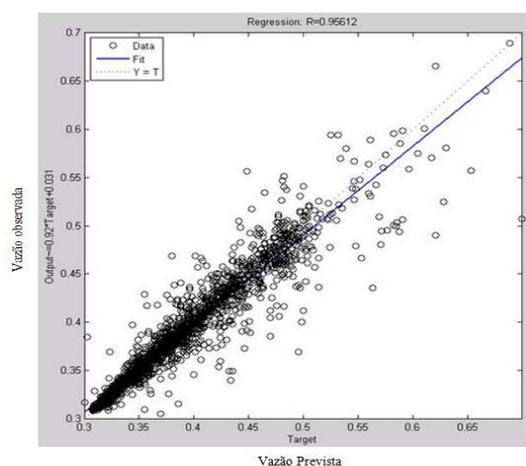


Figura 5. Regressão linear entre vazão prevista e vazão observada para o intervalo analisado (01/01/1991 a 31/07/1997).

Na Figura 5, observa-se que o gráfico gerado pelo modelo não é estacionário, ou seja, possui leve tendência de diminuição de vazão com coeficiente de correlação de 0,96. Além disso, percebe-se uma sazonalidade de 1 ano, o que representa os aumentos de vazão durante os meses de outubro a março, com picos em dezembro e janeiro e diminuição nos meses de julho e agosto. Santos (2009) encontrou resultados semelhantes (redução de $0,07 \text{ m}^3\text{s}^{-1}$ ao ano e significância igual a 95%).

De acordo com a Secretaria do Meio Ambiente e Recursos Hídricos - SEMARH (2007) a distribuição pluviométrica na bacia do Ribeirão João Leite encontra-se associada à topografia, com os maiores índices na seção setentrional (1.711 mm anuais em Ouro Verde de Goiás e 1.650 mm em Anápolis) e os menores índices na porção centro-meridional (1.633 mm em Goianópolis e 1.605 mm em Goiânia).

Além do objetivo principal de fazer previsão diária para a bacia do ribeirão João Leite, criou-se um modelo que pode ser utilizado por gestores de recursos hídricos em tomadas de decisões. O modelo obtido por meio da aplicação de Redes Neurais Artificiais apresentado nesse trabalho representa bem a transformação de precipitação em vazão sem o custo operacional exigido pelos modelos conceituais.

Os gráficos mostrados na Figura 4 e Figura 5 foram gerados pelo software MATLAB®.

6 CONCLUSÕES

Observou-se que o comportamento dos dados observados em relação aos dados gerados pela técnica de Redes Neurais Artificiais com treinamento *Levenberg-Marquardt* apresentaram melhor ajuste para vazões na faixa de 5 a $10 \text{ m}^3\text{s}^{-1}$.

Para vazões superiores a $10 \text{ m}^3\text{s}^{-1}$ ocorreu discrepância quanto ao ajuste, principalmente nos picos correspondentes aos períodos de maior precipitação, como é mostrado no gráfico da Figura 4.

Os resultados desse trabalho obtiveram Mape igual a 10,05. Este resultado é melhor do que o apresentado por Figueiredo et al. (2007) para as bacias UHE Foz do Areia, Reservatório Jordão e UHE Salto Osório com Mape de 10,46.

Observou-se boa representação do modelo hidrológico utilizando-se RNAs devido à obtenção de coeficientes de correlação no intervalo de 0,75 a 0,90 durante a etapa de teste. Além disso, reduziu-se significativamente o custo operacional exigido pelos modelos convencionais de previsão de vazão. Portanto, o modelo hidrológico utilizando-se Redes Neurais Artificiais pode ser utilizado por gestores de recursos hídricos em tomadas de decisões.

Como trabalhos futuros, sugere-se:

- melhorar o ajuste para dados discrepantes, através da abordagem do problema no domínio da frequência utilizando-se a Transformada de Wavelet;
- aumentar o horizonte de previsão de vazão de 1 dia para valores maiores;
- avaliar o uso desta metodologia em uma bacia hidrográfica de maior porte.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- AFONSO, A.A. **Avaliação do potencial de risco de contaminação das águas superficiais da microbacia do rio João Leite por agrotóxicos**. 2004. 130f. Dissertação (Mestrado em Geografia) – Universidade Federal de Goiás, Goiânia, 2004.
- COSTA, F. S.; DAMÁZIO J. M., LIVINO DE CARVALHO, A. R. e DANTAS, H. M.; (2000). PREVIVAZH – Modelo Estocástico de Previsão de Vazões Diárias, In: TRABAJOS TECNICOS DO SEMINÁRIO INTERNACIONAL SOBRE HIDROLOGIA OPERATIVA, CIER., 2000, Salto Grande.
- DUDA, R.O.; HART, P.E.; STORK, D.G. **Pattern Classification**. 2.ed. New York: Wiley, 2001.
- FIGUEIREDO, K.; VELLASCO, M.M.B.R.; PACHECO, M.A.C.; CRUZ, A.V.A.; CONTRERAS, R.J.; BARBOSA, C. Neural Networks for Inflow Forecasting Using Precipitation Information. In: 20TH INTERNATIONAL CONFERENCE ON INDUSTRIAL, ENGINEERING AND OTHER APPLICATIONS OF APPLIED INTELLIGENT SYSTEMS, 4570. 2007, Berlin.
- HAGAN, M.T.; MENHA, M. Training feedforward networks with the Marquardt Algorithm, **IEEE Transactions on Neural Networks**, 5, n.6, p.989-993, 1994.
- HAYKIN, S. **Neural Network - A Comprehensive Foundation**. New Jersey: Prentice-Hall, p.23-57, 1999.
- MARQUARDT, D. An algorithm for least squares estimation of non-linear parameters. **J. Soc. Ind. Appl. Math.**, p.43141, 1963.
- PINTO, N.L.de S.; HOLTZ, A.C.T.; MARTINS, J.A.; GOMIDE, F.L.S. **Hidrologia Básica**. São Paulo: Edgard Blucher, 1976. 278p.
- RABELO, C.G. **Mapeamento de áreas vulneráveis para a qualidade das águas superficiais na bacia hidrográfica do Ribeirão João Leite (GO) utilizando técnicas de geoprocessamento**. 2009. 110f. Dissertação (Mestrado em Engenharia do Meio Ambiente: Recursos Hídricos e Saneamento Ambiental) – Universidade Federal de Goiás, Goiânia, 2009.
- SAJIKUMAR, N.; THANDAVESWARA, B.S. A non-linear rainfall-runoff model using artificial neural network. **Journal of Hydrology**, London, v.216, n.1-2, p.32-55, 1999.
- SANTOS, E.H.M. **Comportamento hídrico na bacia hidrográfica do ribeirão João Leite - Goiás**. 2009. 98f. Tese (Doutorado em Agronomia: solo e água) – Universidade Federal de Goiás, Goiânia, 2009.