

Previsão de Vazões Diárias Utilizando Redes Neurais na Bacia do Rio Mundaú/AL

Aline Neves da Silva¹
Mahelvson Bazilio Chaves¹
Filipe Alves Coelho²
Frede de Oliveira Carvalho³

¹Graduandos do curso de Engenharia Ambiental da Universidade Federal de Alagoas – UFAL. Campus A. C. Simões - Av. Lourival Melo Mota, s/n, Tabuleiro do Martins - Maceió - AL, CEP: 57072-970. E-mails: aline.neves10@gmail.com; mbchaves@yahoo.com.br

²Graduando do curso de Engenharia Química da Universidade Federal de Alagoas – UFAL. Campus A. C. Simões - Av. Lourival Melo Mota, s/n, Tabuleiro do Martins - Maceió - AL, CEP: 57072-970. E-mail: filipea_c@hotmail.com

³Professor da Universidade Federal de Alagoas – UFAL. Campus A. C. Simões - Av. Lourival Melo Mota, s/n, Tabuleiro do Martins - Maceió - AL, CEP: 57072-970. E-mail: fredecarvalho@yahoo.com.br

Abstract: Changings in anthropical and natural forcings of the hydrological system at the Mundaú river has been the main reason by the recurrence of extremely hydrological events, wich have harmed so deeply the population of Alagoas and Pernambuco. The understanding and knowledgement of the rainfall-runoff transformation of Mundaú basin river is a relevant tool that may subsidize actions wich reduce this prejudicial events to the riverine population. Thechniques based on Artificial Neural Network (ANR) have been used efficiently to estimate temporal series, due mainly the capacity to modeling non-linearity. Among the ANRs, stands the Multi-Layer Perception type, whose the three-layer structure allows to find any relationship between data, making this network able to perform such predictions. Then, using the MLP network, monitored flows of 1974-2006, was observed the applicability of the intelligent systems for large basins like Mundaú river.

Palavras-chave: rio Mundaú, redes neurais, previsão hidrológica.

1. INTRODUÇÃO

A água é um recurso natural de extrema importância para os seres vivos e está presente em diversas atividades do homem. O estudo da vazão de rios tornou-se de grande importância para muitas dessas atividades, como por exemplo, a geração de energia hidroelétrica, controle de inundações, irrigação, navegação, estudos de impactos ambientais, e de uma maneira geral, para qualquer projeto que necessite da representação de processos hidrológicos. Desta forma, a utilização de métodos de estimativas de vazões a partir de dados históricos na forma de séries temporais parece atraente embora a obtenção desses dados em termos numéricos e qualitativos não seja uma tarefa fácil.

Diversas técnicas de modelagem vêm sendo empregadas para estimar vazões, porém as restrições baseadas em simplificações dos fenômenos hidráulicos e hidrológicos naturais, que se relacionam de forma não-linear, tem sido o principal problema nesta modelagem. A não-linearidade se deve ao fato das variáveis envolvidas nestes processos apresentarem heterogeneidades temporais e espaciais complexas, pois relacionam processos como a precipitação, evaporação, infiltração e escoamento superficiais, que por sua vez dependem de uma grande variedade de fatores físicos e climáticos, relacionados conforme a configuração da bacia.

Diante de tal dificuldade, nos últimos anos vem-se observado o emprego de técnicas baseadas unicamente em observações empíricas, que correlacionam indiretamente todos os processos envolvidos na modelagem hidrológica.

O objetivo deste trabalho é realizar a previsão de vazões a curto prazo (um dia) na bacia hidrográfica do rio Mundaú através de Redes Neurais Artificiais (RNAs), utilizando além de dados de precipitação e de vazão, dados climáticos da região com o objetivo de avaliar a influência da utilização de dados de clima em tal previsão.

1.1 ÁREA DE ESTUDO

A bacia do rio Mundaú possui uma área de 4.126 Km², pertencendo aos estados de Pernambuco (48%) e Alagoas (52%). Sua nascente está localizada no município de Garanhuns – PE e desemboca em Alagoas na Lagoa Mundaú. A bacia é formada territorialmente por 30 municípios, sendo quatro totalmente inseridos na bacia. As cidades ribeirinhas sofreram com severas inundações com as recentes cheias do rio Mundaú e afluentes, mas que não são novidades para os moradores da região. A figura abaixo ilustra a

localização da bacia e a distribuição espacial dos cinco postos fluviométricos utilizados no presente trabalho.

Bacia Hidrográfica do Rio Mundaú

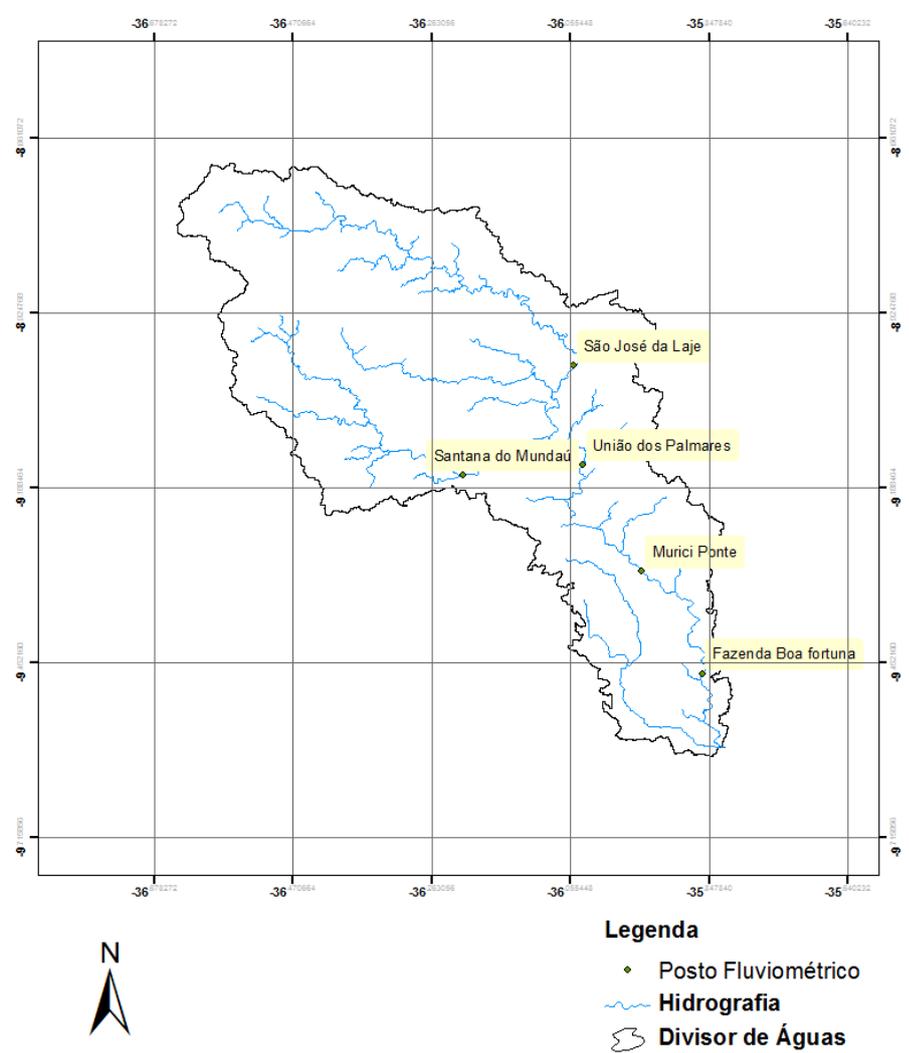


Figura 1 – Bacia Hidrográfica do Rio Mundaú

1.2. REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais (RNAs) são sistemas de processamento criados com base no funcionamento do cérebro humano. São formadas por pequenas unidades de processamento, similares aos neurônios biológicos, chamados neurônios artificiais (Figura 2) organizados em camadas conectadas entre si (Figura 3). Sua arquitetura em camadas produz um fluxo de informações com ou sem realimentação, possuindo uma estrutura de processamento de sinais com grande poder de adaptação e capacidade de representação de processos não-lineares (Silva, 2003, apud Ribeiro, 2009).

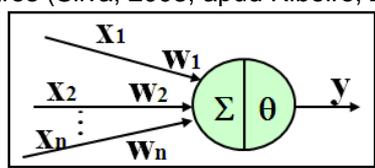


Figura 2 – Neurônio artificial

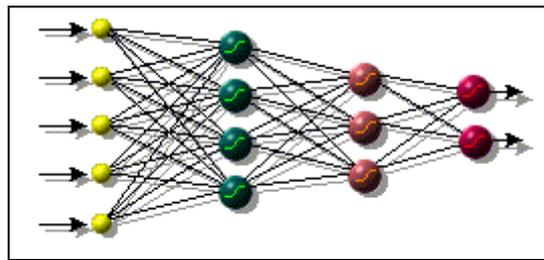


Figura 3 – Exemplo de arquitetura de uma RNA

Há diversos tipos de RNAs, entre eles destaca-se a Multi Layer Perceptron (MLP) (Figura 4), que é caracterizada pela existência de uma ou duas camadas escondidas, em que todos os neurônios de uma camada se ligam a todos da camada seguinte (Andrioli, 2006). As MLPs são uma poderosa técnica de regressão, capaz de modelar funções não lineares e após ser treinada (calibrada), generaliza com precisão, isso é, possui a capacidade de fornecer respostas adequadas para dados de entrada que não foram usados na calibração. (Sarle, 1984, apud Andrioli, 2006).

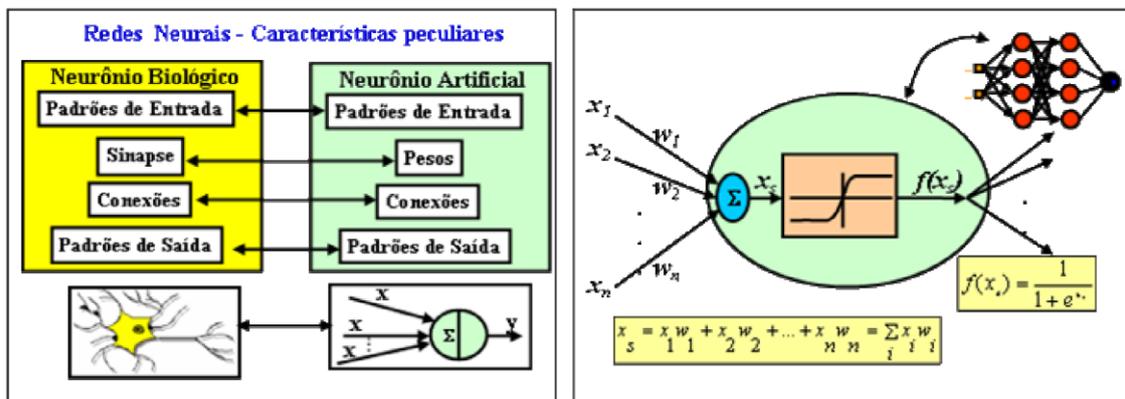


Figura 4 – Rede Neural tipo MLP

As RNA's possuem duas fases de processamento: a de treinamento e a de simulação. O treinamento de uma RNA de forma supervisionada é um processo de ajuste dos pesos das conexões em resposta ao estímulo apresentado à rede neural (histórico de dados), ou seja, a rede possui a propriedade de modificar-se em função da necessidade de aprender a informação que lhe foi apresentada (Figura 5). A simulação consiste na maneira pela qual a rede responde a um estímulo de entrada sem que ocorram modificações em sua estrutura de aprendizagem. (Oliveira Júnior et.al., 2007).

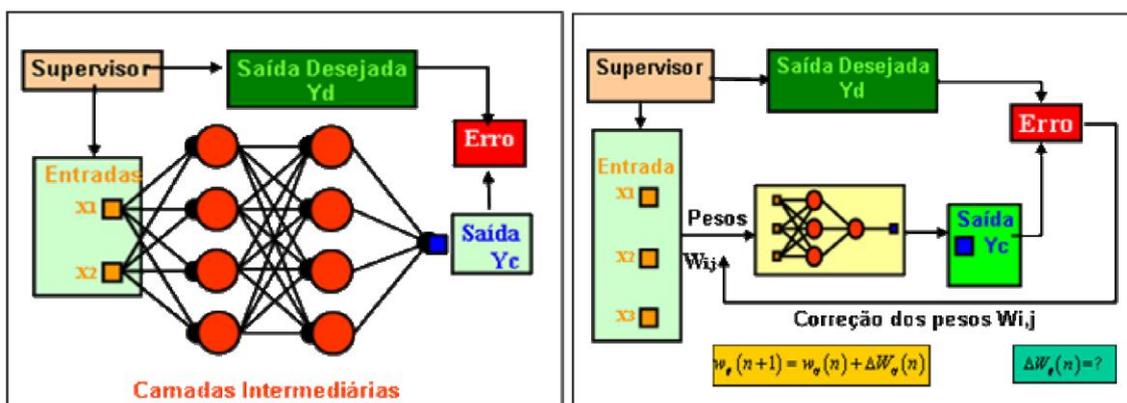


Figura 5 – Treinamento de uma rede neural tipo MLP

As RNAs vêm sendo sugeridas para análise de séries temporais devido à sua capacidade de tratar com relações de entrada-saída de dados não-lineares, destacando sua habilidade de aprendizado e capacidade de generalização, associação e busca paralela. Essas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries, tais como sazonalidade, periodicidade, tendência, entre outras, muitas vezes camufladas por ruídos. (Valença, 2010).

São diversas as aplicações dos modelos de previsão de vazões. Desde dimensionamento e operação de empresas geradoras de energia elétrica, avaliação da disponibilidade hídrica para

abastecimento, análise quantitativa de sedimentos ou até mesmo simulação de mudanças das características físicas das bacias hidrográficas e os reflexos sobre regime hidrológico.

Atualmente os setores usuários dessa tecnologia utilizam (em sua maioria) de modelos determinísticos baseados em conceitos físicos de propagação das vazões, e principalmente modelos-chuva vazão.

Este trabalho tem o objetivo de aprimorar e demonstrar a viabilidade técnica do uso de Redes Neurais como alternativa à aplicação de modelos determinístico atuais. O trabalho também aborda o uso de cenários climáticos distintos numa inclusão progressiva destas variáveis de entrada, além da precipitação, objetivando o melhoramento dos resultados, assim como Cannas et.al. (2003).

2. METODOLOGIA

Foi utilizada uma rede neural do tipo Multi-Layer Perceptron (MLP) para realizar a previsão de vazões diárias na bacia do Rio Mundaú. Para a construção de tal rede, foram utilizados dados de precipitação, obtidos em cinco postos pluviométricos (São José da Laje, União dos Palmares, Murici, Fazenda Boa Fortuna e Santana do Mundaú), dados de vazão e clima (temperatura, pressão, umidade relativa e insolação), de um período de 10 anos, de 1993 a 2002.

Estavam disponíveis séries históricas de vazão do período 1974 – 2006, contudo, devido a grande quantidade de falhas apresentadas no período 1974 – 1992 as mesmas foram descartadas. A série temporal é normalmente dividida em dois conjuntos de elementos: o primeiro é destinado ao método de previsão para a obtenção do aprendizado (conjunto de treino) e o segundo é usado para verificação de seu desempenho na previsão de valores futuros (conjunto teste). (Ribeiro, 2009). De posse desses dados, construiu-se uma rede neural do tipo MLP.

Cannas et.al. (2003), utilizou modelos tradicionais de redes neurais para modelagem de séries temporais, como ARMAX, e o modelo MLP para prever vazões diárias em bacias da Sardenha, ilha do Mar Mediterrâneo, situada a oeste da Península Itálica. Os modelos neurais aplicados ao problema da transformação chuva-vazão constituem uma ferramenta útil para predição de escoamento. A rede MLP obteve desempenho numérico superior ao da rede ARMAX, incentivando assim a utilização deste modelo de rede para problemas dessa natureza.

Valença (2010) analisou dados pluviométricos e fluviométricos da área a montante do reservatório de Três Marias, no rio São Francisco, bem como a calibração de um modelo baseado na técnica de redes neurais para a previsão de vazões naturais afluentes. Foram utilizadas as redes MLP (Multi-Layer Perceptrons) e NSRBN (Non-linear Sigmoidal Regression Blocks Networks) para realizar a previsão, obtendo-se, nestas, resultados bem próximos, tendo a segunda um desempenho melhor para as previsões semanais e um pouco pior para as previsões diárias.

Durante a etapa de treinamento das redes neurais será obtido o número de camadas da rede, de neurônios nesta camada, assim como as funções de transferência das mesmas, que permitirão mapear a não-linearidade entre os dados.

O algoritmo de treinamento utilizado na rede foi o de Regularização Bayesiana o qual caracteriza-se por fornecer uma medida de quantos parâmetros de rede (pesos e vieses) estão sendo efetivamente utilizados pela rede. Este número efetivo de parâmetros deve ser o mesmo, não importa quão grande seja o número total de parâmetros da rede. (Demuth, 2008)

No treinamento das redes foram utilizadas cinco configurações distintas, diferindo entre si pelas entradas utilizadas no treinamento (Tabela 1).

Tabela 1 – Configurações de treinamento

Configuração	Entradas
1	Precipitações (p) + vazões anteriores (v)
2	Precipitações (p) + temperatura (T) + vazões anteriores (v)
3	Precipitações (p) + temperatura (T) + umidade relativa (UR) + vazões anteriores (v)
4	Precipitações (p) + temperatura (T) + umidade relativa (UR) + insolação (i) + vazões anteriores (v)
5	Precipitações (p) + temperatura (T) + umidade relativa (UR) + insolação (i) + pressão (P) + vazões anteriores (v)

A vazão $v(t)$ prevista pela rede será inferenciada através dos dados descritos na Tabela 1 nos tempos t , $t-1$ e $t-2$ (Tabela 2).

Configuração	Entradas
1	$p(t-1) + p(t) + v(t-2) + v(t-1)$
2	$p(t-1) + p(t) + T(t-1) + T(t) + v(t-2) + v(t-1)$
3	$p(t-1) + p(t) + T(t-1) + T(t) + UR(t-1) + UR(t) + v(t-2) + v(t-1)$
4	$p(t-1) + p(t) + T(t-1) + T(t) + UR(t-1) + UR(t) + i(t-1) + i(t) + v(t-2) + v(t-1)$
5	$p(t-1) + p(t) + T(t-1) + T(t) + UR(t-1) + UR(t) + i(t-1) + i(t) + P(t-1) + P(t) + v(t-2) + v(t-1)$

A Figura 6 mostra um esquema representativo da utilização das redes neurais no tratamento de séries temporais. Na Figura 7 exemplifica-se a representação da serie temporal como entrada das redes neurais.



Figura 6 – Exemplo de uma janela de previsão com cinco entradas e horizonte de previsão igual a um (Ribeiro,2009)

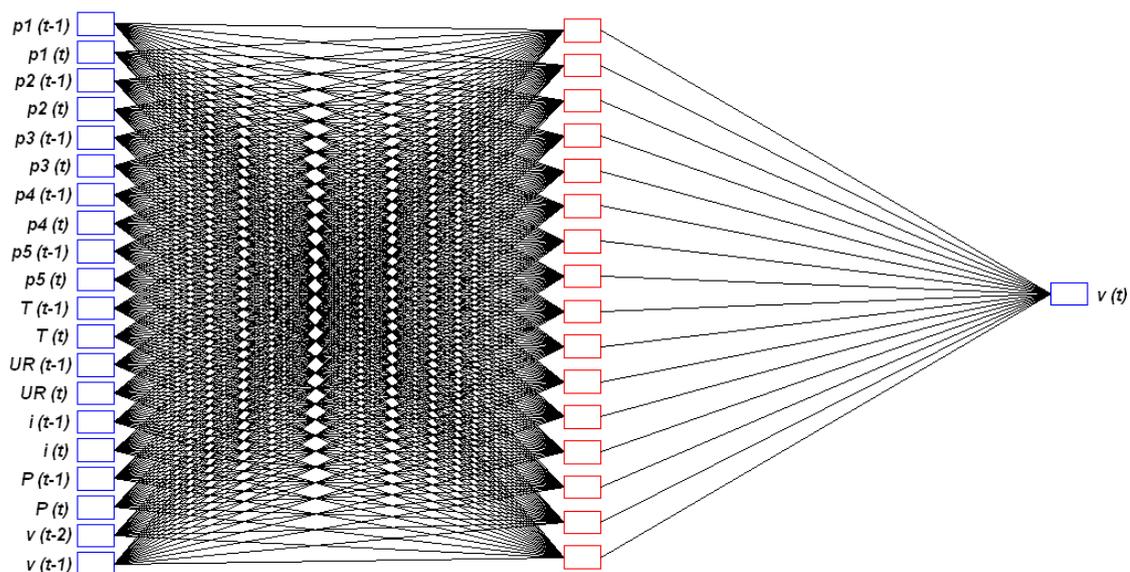


Figura 7 – Representação da arquitetura da Configuração 5.

Dos dez anos de dados disponíveis, oito foram utilizados para o treinamento da rede e dois para posterior validação.

Em todas essas configurações foi utilizada a mesma arquitetura da rede neural, a fim de verificar, além da aplicabilidade da rede na previsão de vazões, a influência dos dados climáticos nessa previsão.

A análise comparativa dos dados simulados com os reais foi realizada através de três medidas de erros: Erro Médio Absoluto (EMA) (Eq.1), Erro Médio Absoluto Percentual (EMAP) e Erro Padrão de Predição (Eq.2).

$$EMA = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t| \quad (1)$$

$$EMAP = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| \quad (2)$$

$$EP = \left[\frac{1}{n} \sum_{t=1}^n (F_t - Y_t)^2 \right]^{0,5} \quad (3)$$

Nas quais: n = número de dados;
 Y_i = valor real;
 F_i = valor simulado.

3. RESULTADOS E DISCUSSÕES

Após treinada e escolhida a arquitetura ideal das redes, foi feita a simulação das vazões, utilizando dois anos de dados que não tinham sido utilizados no treinamento.

O resultado das simulações podem ser vistos nas Figuras 8, 9, 10, 11 e 12, que mostram uma comparação dos valores obtidos com a simulação, nas configurações de treinamento 1, 2, 3, 4 e 5, respectivamente, descritas na Tabela 1, com os valores reais.

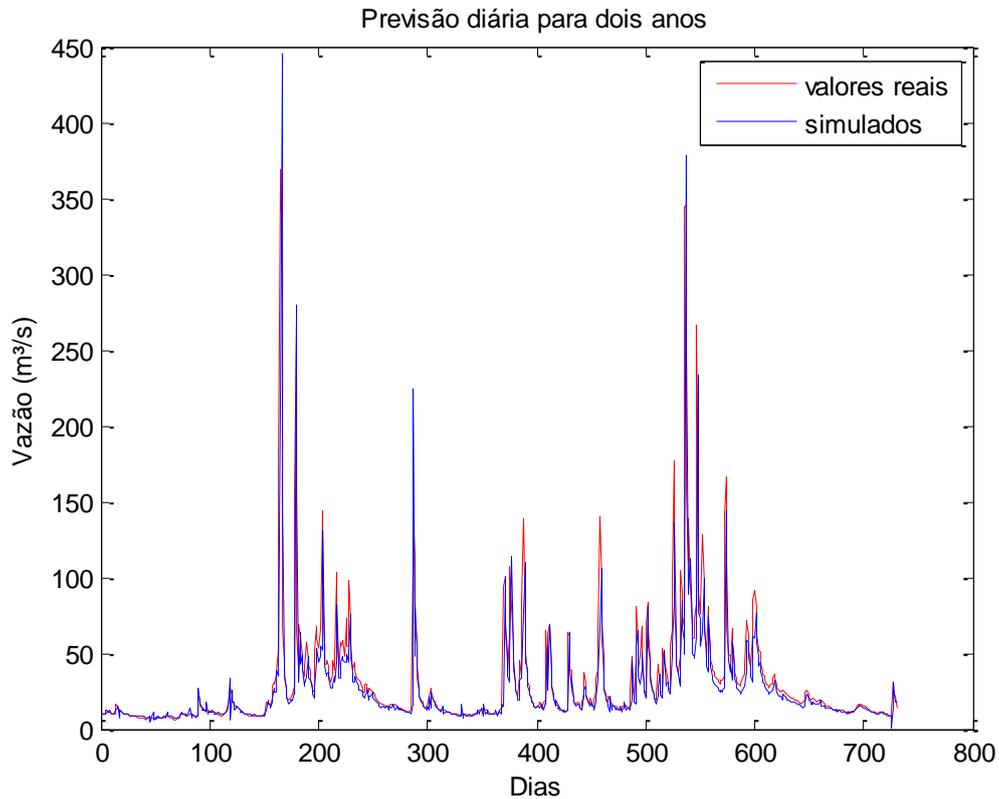


Figura 8 - Comparação das vazões reais com as vazões simuladas: Configuração 1

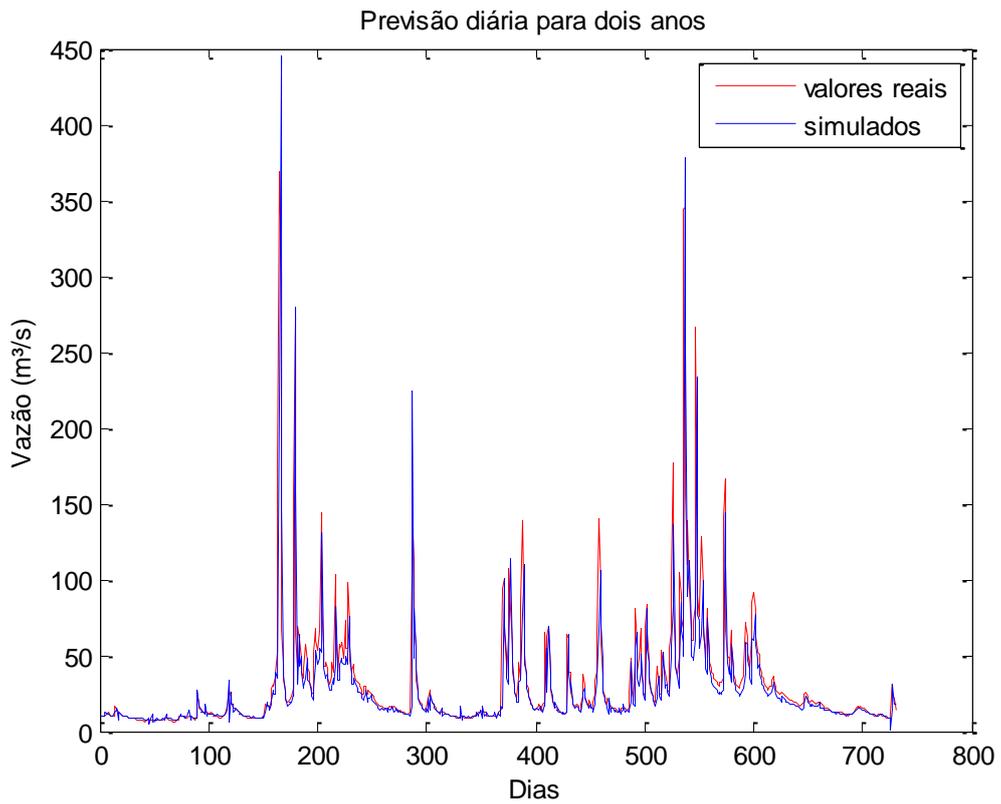


Figura 9 - Comparação das vazões reais com as vazões simuladas: Configuração 2

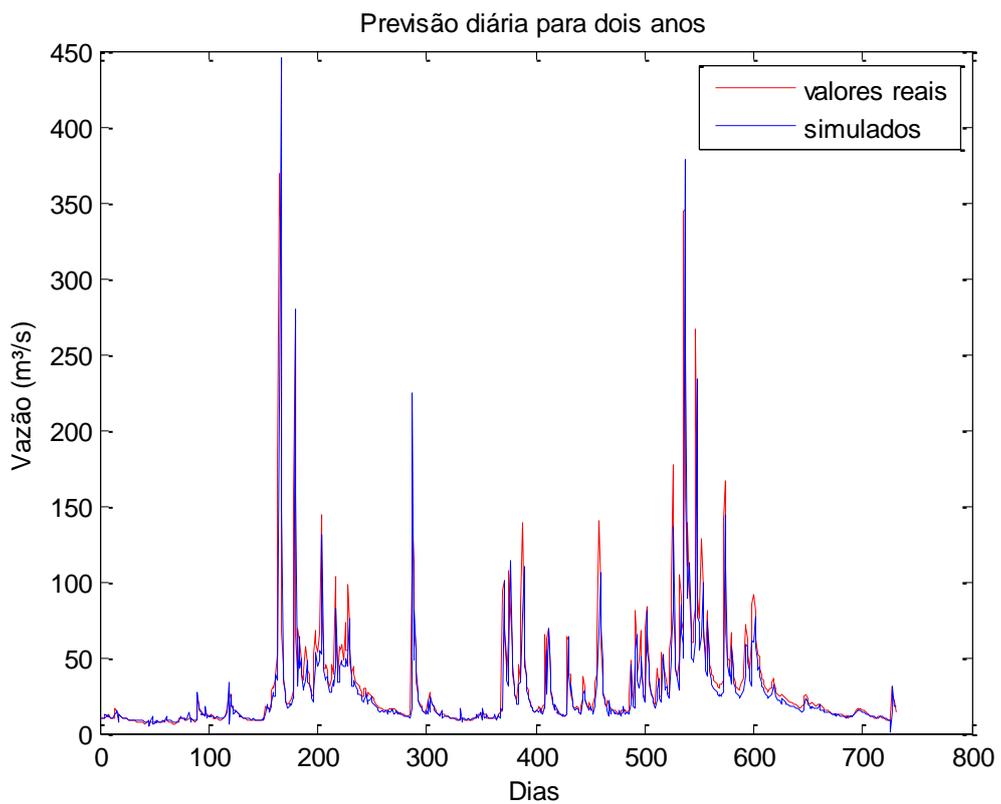


Figura 10 - Comparação das vazões reais com as vazões simuladas: Configuração 3

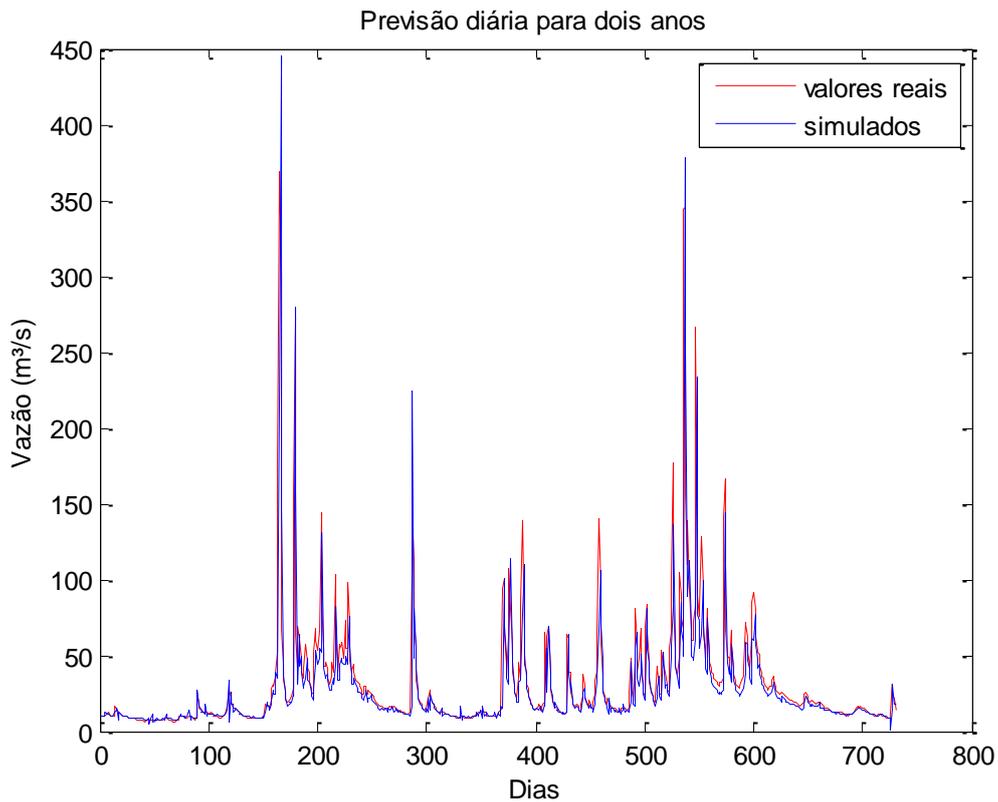


Figura 11 - Comparação das vazões reais com as vazões simuladas: Configuração 4

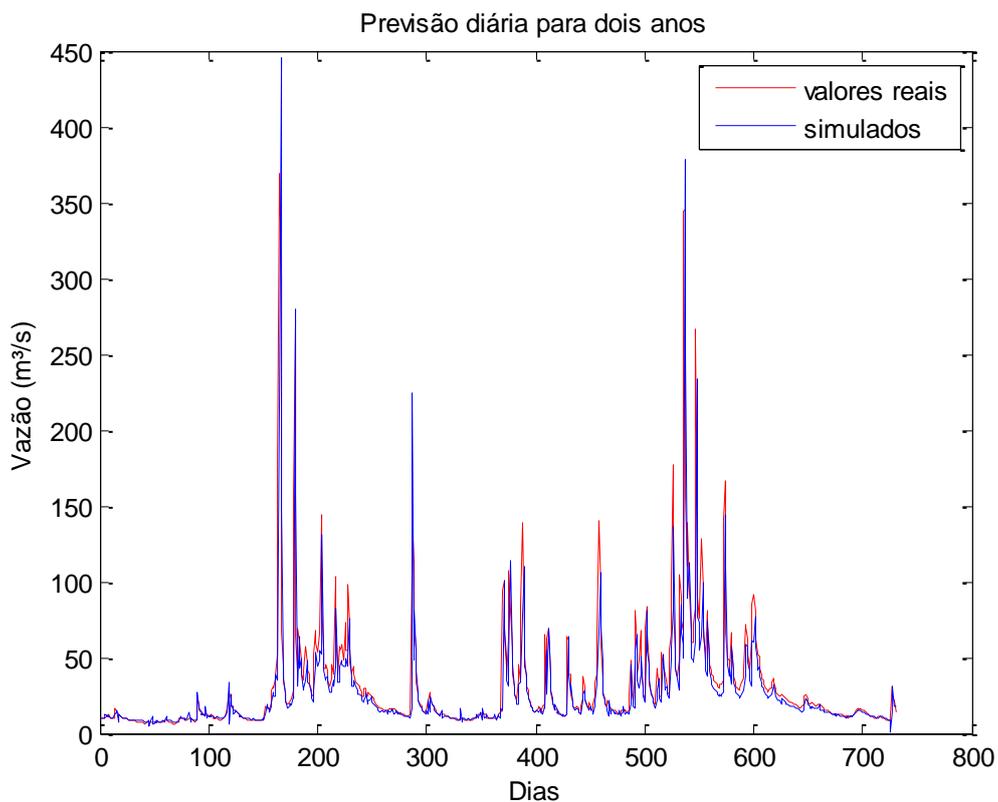


Figura 12 - Comparação das vazões reais com as vazões simuladas: Configuração 5

A Tabela 3 mostra os valores do EMA e EMAP obtidos em cada situação de treinamento. O EMA mostra a diferença entre os dados estimados na rede e os dados reais, já o EMAP, expressa essa diferença em porcentagem.

Tabela 3 – Erro Médio Absoluto e Erro Médio Absoluto Percentual

Configuração	EMA	EMAP (%)	EP
1	7,818437	15,39342	22,76013
2	8,350234	18,34887	23,05947
3	8,159467	20,07733	22,85978
4	8,104454	18,59041	22,47292
5	8,853056	20,15773	23,33011

Pode-se verificar que a Configuração 1, na qual a previsão das vazões foi realizada utilizando apenas dados de precipitação, obteve os menores EMA e EMAP. Não se pode afirmar com precisão que a utilização de dados climáticos na previsão de vazões seja dispensável, pois a diferença entre os erros obtidos com as outras situações é relativamente pequena. Porém, isso pode ser um indicativo que a utilização de outras variáveis de entrada relacionadas às vazões, não seja tão significativa na inferência de valores de vazões diárias.

Cannas et al. (2003) utilizou em seu trabalho, dados de precipitação de 30 estações pluviométricas e informações sobre o clima a partir de 2 estações de temperatura a fim de estimar os valores de escoamento na bacia Tirso. Os experimentos foram realizados considerando-se apenas as chuvas, e acrescentando, a seguir, escoamento, temperatura e informações sobre o clima na camada de entrada. Verificou-se que nenhuma vantagem na previsão dos dados de vazão foi obtida em função da utilização da temperatura ou evapotranspiração como entrada da rede, assim como foi verificado no presente trabalho.

4. CONCLUSÃO

A partir dos resultados obtidos, é possível verificar que a rede foi capaz de acompanhar a tendência dos dados de vazão observados, sendo considerada eficaz para modelar o processo de transformação chuva-vazão na Bacia do Rio Mundaú.

Observou-se que a utilização de dados de clima aparentemente não foi relevante na simulação do processo, pois, os valores de vazão simulados utilizando um maior número de variáveis climáticas, quando comparados com os valores observados de vazão, obtiveram erros superiores aos obtidos com os dados gerados apenas com a variável precipitação. Este resultado, no entanto, não inviabiliza a utilização de dados climáticos na previsão de vazão, pois os resultados pouco representativos podem ter sido consequência da qualidade dos dados utilizados. Deve-se salientar que quando da disponibilidade de dados climáticos, sempre se verificar a utilidade de sua consideração no modelo, visto que para a rede neural trata-se apenas de aumentar as entradas.

Uma vez que a obtenção de dados conjuntos de precipitação, vazão e de clima sincronizados é difícil, a previsão de vazões a curto prazo, utilizando unicamente um histórico de vazão e precipitação, não é totalmente comprometida. Tal fato pode ser considerado uma vantagem na utilização de redes neurais artificiais na previsão de vazões em comparação aos modelos fenomenológicos utilizados para esse fim, pois utilizando apenas duas variáveis (precipitação e vazão), a rede foi capaz de encontrar as relações necessárias para simular o processo de forma relativamente precisa e segura.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ANDRIOLI, C.P., BARROS, M.T.L. **Implementação de um modelo de previsão de vazão em tempo real com redes neurais**. XIV Congresso Brasileiro de Meteorologia. Florianópolis, 2006.
- CANNAS, B., BARATTI, R., FANNI, A. PINTUS, M., SECHI, G.M., TORENO, N. **River flow forecast for reservoir management through neural networks**. Neurocomputing, 2003.
- DEMUTH, H., BEALE, M. **Neural Network Toolbox for use with MATLAB**, 1998.
- OLIVEIRA JUNIOR, H. A., CALDEIRA, A. M., MACHADO, M. A., SOUZA, R. C. e TANSCHKEIT, R., **Inteligência Computacional aplicada à Administração, Economia e Engenharia em Matlab**. São Paulo: Thomson Learning, 2007

RIBEIRO, C.V., GOLDSCHMIDT, R.R, CHOREN,R. **Métodos para previsão de séries temporais e suas técnicas de desenvolvimento**. Monografia. Instituto Militar de Engenharia. Rio de Janeiro, 2009.

VALENÇA. M.J.S., GOMES, L.F.C, MONTENEGRO, S.N.G.L. **Modelo Baseado na Técnica de Redes Neurais para Previsão de Vazões na Bacia do Rio São Francisco**. RBRH — Revista Brasileira de Recursos Hídricos Volume 15 n.1, 2010.