

## PREVISÃO DE VAZÕES UTILIZANDO REDES NEURAIIS PARA SOBRADINHO

Kaio Martins Ramos<sup>1</sup> \*; Antonio Alisson Pessoa Guimarães<sup>2</sup>; Cleiton da Silva Silveira<sup>3</sup>; Antonio Robsson de Sousa Teixeira Filho<sup>4</sup>; Francisco Wellington Martins da Silva<sup>5</sup>; Katerine da Silva Moreira<sup>6</sup>

**Resumo** – Redes Neurais Artificiais são modelos computacionais baseadas no sistema nervoso de seres vivos, possuindo assim capacidade de aprendizado por meio da busca de padrões. Com base nessa temática, o presente trabalho tem por objetivo utilizar Redes Neurais Artificiais para previsão de vazões do reservatório de Sobradinho, localizado no Rio São Francisco no Estado da Bahia. Utilizou-se dados de vazões naturais e variáveis climáticas disponibilizadas, respectivamente, pelo Operador Nacional de Sistemas (ONS) e *International Research Institute for Climate and Society* (IRI). Desenvolveu-se uma rede com quatro entradas, duas camadas ocultas e três neurônios em cada e uma saída, sendo esta a vazão. Foram obtidos resultados satisfatórios e uma boa performance nas previsões. Após análises, observou-se que emprego de Redes Neurais Artificiais é uma boa ferramenta para previsão, oferecendo assim informações preciosa para a tomada de decisões importantes.

**Palavras-Chave** – previsão, redes neurais.

## FLOW FORECASTS USING NEURAL NETWORKS FOR SOBRADINHO

**Abstract** – Artificial Neural Networks are computational models based on the nervous system of living beings, thus possessing learning ability through the search of patterns. This paper aims to use artificial neural networks to flow forecasting of the Sobradinho reservoir, located in the São Francisco River at Bahia State. Using data natural flow and climatic variables provided by the National System Operator (NSO) and International Research Institute for Climate and Society (IRI), respectively. Artificial Neural networks was developed with four inputs, two hidden layers with three neurons and output natural flow variable. Satisfactory results and good performance were obtained in the forecasts. Artificial Neural Networks use is a good tool for forecasting, thus providing valuable information for making important decisions.

**Keywords** – prevision, neural network.

<sup>1</sup> Universidade da Integração Internacional da Lusofonia Afro-Brasileira, [kayomartyns@hotmail.com](mailto:kayomartyns@hotmail.com) \*

<sup>2</sup> Universidade da Integração Internacional da Lusofonia Afro-Brasileira, [alisson@unilab.edu.br](mailto:alisson@unilab.edu.br)

<sup>3</sup> Universidade da Integração Internacional da Lusofonia Afro-Brasileira, [cleitonsilveira@unilab.edu.br](mailto:cleitonsilveira@unilab.edu.br)

<sup>4</sup> Universidade da Integração Internacional da Lusofonia Afro-Brasileira, [robssonset@gmail.com](mailto:robssonset@gmail.com)

<sup>5</sup> Universidade da Integração Internacional da Lusofonia Afro-Brasileira, [martinswellington29@yahoo.com.br](mailto:martinswellington29@yahoo.com.br)

<sup>6</sup> Universidade da Integração Internacional da Lusofonia Afro-Brasileira, [katerinegce@hotmail.com](mailto:katerinegce@hotmail.com)

## **INTRODUÇÃO**

As previsões climáticas de precipitação e vazão fornecem informações importantes para diversos setores da sociedade, principalmente para aquelas sensíveis a essa variável atmosférica, como a agricultura, recursos hídricos, transporte, energia hidráulica etc. Além disso, a possibilidade de prever eventos extremos permite que decisões possam ser tomadas para que os impactos de tais eventos sejam minimizados, reduzindo assim o grau de vulnerabilidade de uma determinada região.

Em geral, a qualidade das previsões hidrológica afeta o desempenho da operação do sistema. Dessa forma, os aperfeiçoamentos metodológicos para a obtenção dos cenários hidrológicos de previsão ou geração de aflúências contribuem para a melhoria do processo de planejamento e programação da operação hidrossistemas.

As abordagens para a previsão de vazões predominantemente na literatura dividem-se em duas categorias: estatísticas ou dinâmicas (integração dos modelos climático e hidrológico). Abordagens estatísticas são baseadas no registro histórico de observações dos preditandos (ex: precipitação, vazão e temperatura) e preditores relevantes (ex: temperatura da superfície do mar e pressão atmosférica) ou um índice relacionado diretamente com a estimativa de vazões por meio de técnicas estatísticas. (SOUZA FILHO & LALL, 2003). Já as abordagens dinâmicas procuram os pares de processos climáticos e hidrológicos passando as informações em uma escala reduzida (redimensionada) iterativa (online) ou no modo estático (offline).

Nas últimas décadas, as diferentes tecnologias de modelagem de fenômenos naturais têm evoluído rapidamente, propiciando a oportunidade de se ampliar seus conhecimentos sobre a natureza e compreender seus processos físicos e biológicos. Considerando estes avanços, torna-se necessária a busca pelo desenvolvimento de novos sistemas de previsão de vazões incluindo informações climáticas para melhorar a qualidade da previsão. Isto possibilita um maior entendimento das incertezas relacionadas com as condições hidrológicas futuras de uma dada bacia.

Alguns autores destacam o uso de modelos estatísticos aliados a informações climáticas, alguns baseados em Redes Neurais Artificiais (RNA's). Nos últimos anos, diversos trabalhos na área mostraram-se eficientes para a previsão de vazão utilizando RNA's para intervalos diários, semanais e mensais.

Redes neurais são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem capacidade de aquisição e manutenção do conhecimento (baseado em informações) e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais), sendo as mesmas representadas por vetores/matrizes sinápticos (Da Silva; Spatti D. et al., 2010). Suas principais características podem ser enumeradas, como adaptação por experiência, capacidade de aprendizado, habilidade de generalização, organização de dados, tolerância a falhas, armazenamento distribuído e facilidade de falhas.

O presente trabalho tem por objetivo a utilização de redes neurais artificiais para previsão de vazões de Sobradinho, localizado no estado da Bahia, sendo o reservatório alimentado pelo Rio São Francisco.

## **METODOLOGIA**

### **Região de Estudo**

O reservatório de Sobradinho foi o escolhido para a análise. Segundo a CHESF, ele tem cerca de 320 km de extensão, com uma superfície de olho d'água de 4214 km<sup>2</sup> e uma capacidade de armazenamento de 34.1 bilhões de metros cúbicos, possui uma cota de 392.50 m e uma vazão

regularizada de 2060 m<sup>3</sup>/s nos períodos de estiagem. Os dados de vazão estão no mesmo modelo que se encontram as variáveis climáticas (do ano de 1951 a 2005).

## Dados Utilizados

O conjunto dos dados de entradas foram variáveis climáticas exógenas. As variáveis escolhidas foram: Oscilação Atlântica Multidecadal (AMO), Confluência Atlântico Sul das Correntes Brasil-Malvinas – Anomalia TSM (ASBM), TSM LESTE do Pacífico Tropical na região 5N-5S;150W-90W (NINO3) e TSM na região 5S-20S,90W-130W (SST1). Estas variáveis são mensais a partir do ano de 1951 a 2005 e foram coletados junto ao IRI. As vazões naturalizadas de Sobradinho foram obtidas a partir do ONS.

## Redes Neurais

Abaixo é mostrado uma figura representativa de uma rede neural.

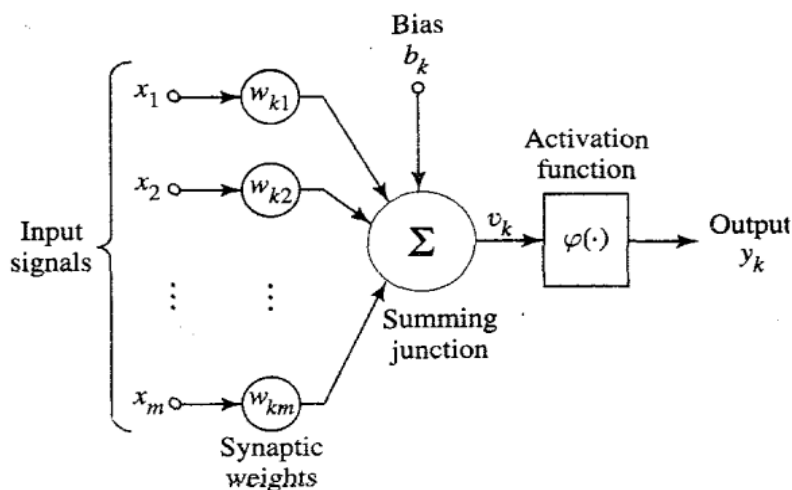


Figura 1 – Representação de uma rede neural (Haykin,2005)

A rede é basicamente composta pelas partes descritas na Figura 1. Tem-se sinais de entradas (*inputs signals*) onde estas são sinais advindas do meio externo, enumeradas, como adaptação por experiência por exemplo dados, series temporais, pesos sinápticos (*synaptic weights*) responsáveis por ponderar cada variável de entrada, combinador linear ( $\Sigma$ ) cuja a função é agregar todos os valores de entradas que foram ponderados, *bias* uma variável específica o qual será a ideal para que os resultados no combinador linear possam gerar um valor de disparo em direção a saída do neurônio, potencial de ativação ( $v_k$ ), cujo o seu valor é a diferença entre o valor de saída do combinador linear e o limiar de ativação e por último função de ativação (*activation function*), tendo como objetivo limitar a saída do neurônio em relação a um determinado conjunto de sinais de entradas.

Com relação a sua arquitetura, a rede pode ser classificada basicamente em quatro tipos distintos. Primeiro, tem-se a mais simples, a *feedforward single layer*. Ela é construída por uma camada de entrada e uma de neurônio, sendo essa a própria saída. A *feedforward single multilayer* é mais complexa que a citada anteriormente, onde apresenta múltiplos neurônios e saída. As redes recorrentes, diferentes das duas citadas, apresenta realimentação da saída para as entradas dos neurônios. Por último, tem-se a arquitetura reticulada, onde esta leva em consideração a disposição que se encontram os neurônios, ou seja, a organização o qual os neurônios estão dispostos.

Para que ocorra o aprendizado da rede, é necessário treiná-la. Esse processo é de grande importância, uma vez que este processo está atrelado ao seu desempenho. Basicamente, existem quatro tipos de treinamento: supervisionada, não supervisionada, online e offline. O treinamento

supervisionado consiste em considerar o sinal de saída em relação a entrada, ou seja, adicionada a rede tem-se já os sinais desejados e assim trabalha-se com erro com o propósito de se obter um sinal de saída suficientemente próximo ao sinal de entrada original. Já o não supervisionado não ocorre a entrada dos valores desejados. A rede deve se auto organizar na busca de padrões existentes no conjunto de entrada, não trabalhando com erro. No treinamento offline, os ajustes necessários nos pesos e limiares só é ajustado após a apresentação de todo conjunto de treinamento. Diferentemente, tem-se o online que os ajustes nos limiares e pesos são feitos após a apresentação de cada amostra na fase de treinamento.

O software escolhido para o desenvolvimento da rede foi o GNU Octave. Este é um software grátis e de fácil acesso. A rede construída foi uma Madaline. Sua arquitetura é *feedforward single multilayer* com aprendizado supervisionado, a partir do algoritmo *backpropagation*. Ela tem uma configuração com quatro entradas, duas camadas ocultas com três neurônios em cada e uma saída.

A normalização dos dados para alimentação da rede é de grande importância. Valores com grandes diferenças entre eles não dará uma boa performance a rede. Por isso, os valores de alimentação foram colocados na faixa de 0 a 1. A equação utilizada está mostrada abaixo:

$$x_{novo} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad 1$$

Onde:

x = valor a ser normalizado;

$x_{\min}$  = menor valor da sequência;

$x_{\max}$  = maior valor da sequência;

$x_{novo}$  = valor normalizado.

Para o cálculo do erro quadrático médio utilizou-se a seguinte equação:

$$EQ_m = \sum_i \frac{(x_i - x_f)^2}{n} \quad 2$$

Em que:

$x_i$  = valor estimado;

$x_j$  = valor real;

n = número de termos;

$EQ_m$  = erro quadrático médio.

A divisão dos dados foi feita da seguinte forma: 70 % para o treinamento, 15% para validação e 15% para testes. Todos os dados foram devidamente escolhidos de forma aleatória. Essa escolha aleatória é de grande importância, uma vez que o intuito é generalizar o aprendizado da rede.

## RESULTADOS E DISCUSSÕES

Primeiramente averiguou-se se as variáveis escolhidas para a alimentação eram significantes para estimativa da vazão. Esta análise foi feita através dos pesos, sendo estes gerados de forma aleatória na primeira vez a partir de uma distribuição uniforme no intervalo -1 a 1 e em seguida atualizados conforme o algoritmo de aprendizagem *backpropagation*. Ao analisar os referidos pesos, observou-se que nenhum deles tende a zero, concluindo-se que todas as variáveis de entrada da rede têm significância na aprendizagem e consequentemente na performance do algoritmo de estimação

Foram gerados gráficos para a fase de treinamento, validação e para ambos juntos. Primeiramente abaixo tem-se o gráfico para o treinamento.




Figura 3 – Gráfico gerado para treinamento (Autores)

Ao se analisar o gráfico, observar-se que o erro quadrático vai decrescendo com o aumento do número de épocas. Número épocas significa a quantidade de vezes que os dados serão processados até chegar ao erro desejado. No caso da figura acima, o número de épocas tem o valor de 35. Isso quer dizer que o erro desejado foi atingido. O formato do gráfico mostra também que ocorreu o aprendizado, começando com um erro maior e reduzindo com o passar das épocas até estabilizar. Abaixo tem o gráfico gerado para validação.

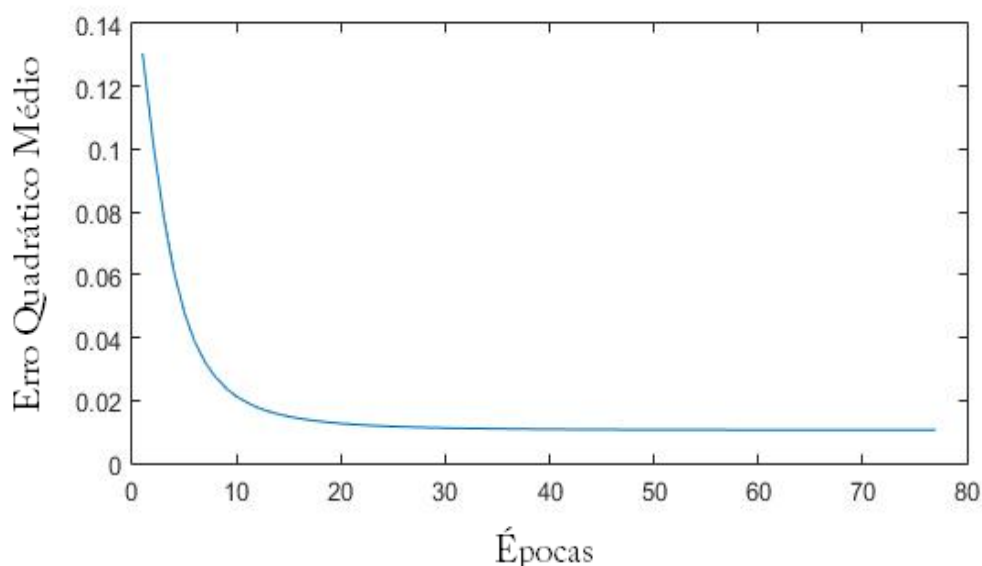


Figura 4 – Gráfico gerado para validação (Autores)

O gráfico de validação apresenta o mesmo comportamento apresentado pelo treinamento. Ele apresenta mais épocas, pois a quantidade de dados para validação é bem menor que os utilizados por o treinamento. Observa-se também que ocorreu o aprendizado, analisando a forma do gráfico.

Por sua vez analisando-se os dois juntos (figura abaixo), observar-se que a validação tem um erro maior que o treinamento. Como mencionado, a quantidade de dados é diferente, causando diferenças também no número de épocas. Contudo, observar-se o mesmo comportamento de aprendizagem.

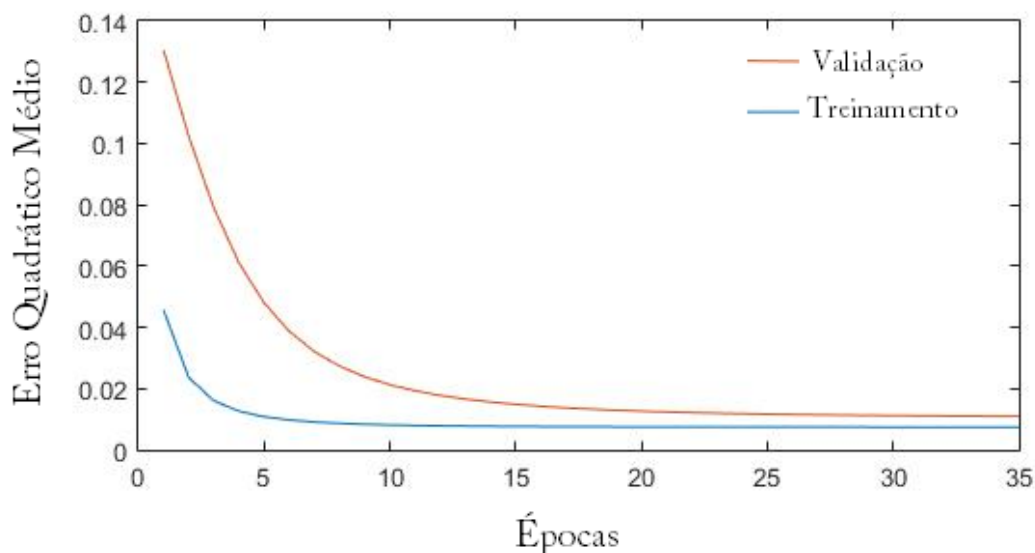


Figura 5 – Gráfico gerado para validação e treinamento (Autores)

O erro quadrático médio mede a variação dos valores previstos pela rede em relação as variações de seu indicador referencial. O valor encontrado para a análise foi de 0,0088. Isso indica que a rede apresentou uma boa performance.

Foi construído também um gráfico de regressão linear. Para rede, foram utilizados 15% dos dados para a validação. Em suma, 15% dos dados brutos (antes de passar pela rede) foram utilizados para a comparação com os 15% de saída da validação. Isto está mostrado na figura abaixo.

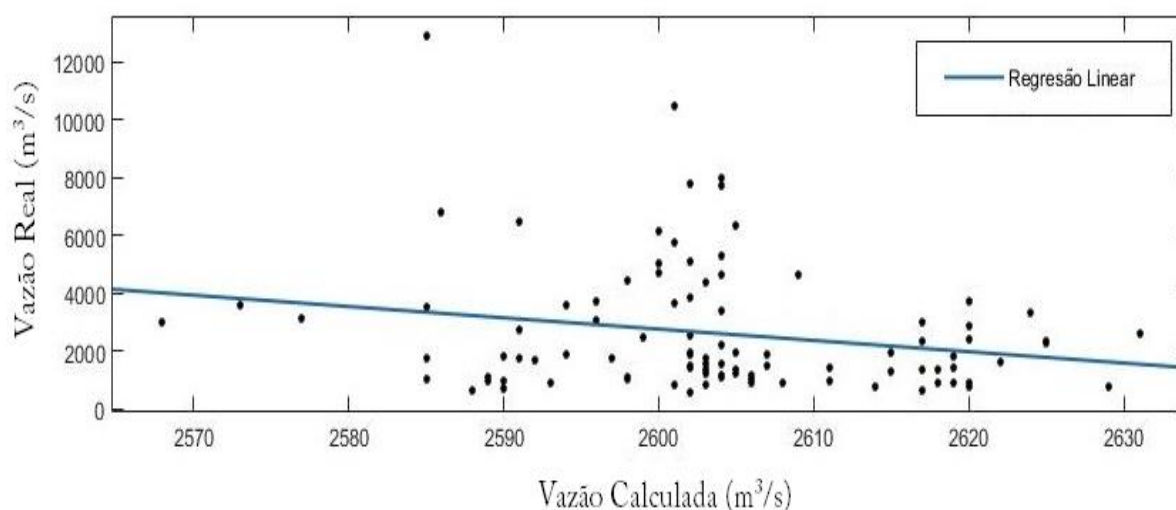


Figura 6 – Gráfico de regressão linear (Autores)

Ao observar o gráfico, nota-se que a maioria dos valores calculados encontram-se próximos a linha de tendência. Tem-se pontos distantes, uma vez que a vazão real tem valores bem discrepantes. Contudo, o gráfico mostra que a previsão é considerada boa.

## CONCLUSÕES

Com o presente trabalho, pode-se concluir que a previsão de vazão para o reservatório de Sobradinho, utilizando Redes Neurais Artificiais se mostra eficiente. Pelas curvas analisadas, observou-se o aprendizado da rede, reduzindo o erro quadrático médio com o passar das épocas. Com relação ao gráfico de regressão, observou-se que mesmo alguns pontos distantes da reta, a previsão se mostrou satisfatória, mostrando mais uma vez que é possível ter uma boa eficiência. Alguns pontos podem ser melhorados como por exemplo, a utilização de novas variáveis, aumentar o número de camadas e neurônios, utilização de novos reservatórios, dentre outros. Tais melhorias estão sendo estudados para futuros trabalhos.

## REFERÊNCIAS

- CATALDI, M. Estudo Numérico da Influência das Anomalias da TSM do Atlântico Sul Extratropical e do Pacífico Equatorial no Regime Hidrometeorológico das Regiões Sul e Sudeste do Brasil. 2008. 255f. Tese (Doutorado em Engenharia Civil – COPPE), Universidade Federal do Rio de Janeiro – UFRJ, Rio de Janeiro, 2008.
- Da Silva, I.N., Spatti D., e Flauzino, R. (2010). Redes neurais artificiais para engenharia e ciências aplicadas: curso prático, Artliber Editora Ltda, São Paulo, SP, Brasil.
- Haykin, Simon O. Neural Networks: A Comprehensive Foundation, 2nd Edition, McMaster University, Ontario Canada
- SOUZA FILHO, F.A. & U. LALL. Seasonal to Interannual Ensemble Streamflow Forecasts for Ceara, Brazil: Applications of a Multivariate, Semiparametric Algorithm. Water Resources Research 39(11):1307, doi: 10.1029/2002WR001373, 2003.
- SIQUEIRA, H.V. Previsão de séries de vazões com redes neurais artificiais em modelos lineares ajustados por algoritmos bio-inspirados. 2009. 175f. Dissertação (Mestrado - Faculdade de Engenharia Elétrica e de Computação) - Universidade Estadual de Campinas – UNICAMP. 2009.