

PREVISÃO DE VAZÕES PARA O AÇUDE ORÓS/CE A PARTIR DE DADOS HIDROMETEOROLÓGICOS UTILIZANDO PERCEPTRONS

CARLA BEATRIZ COSTA DE ARAÚJO, SILVRANO ADONIAS DANTAS NETO, FRANCISCO
DE ASSIS SOUZA FILHO

Universidade Federal do Ceará, Departamento de Engenharia Hidráulica e Ambiental, Fortaleza, CE,
Brasil,

carlabeatriz7@gmail.com, silvrano@ufc.br, assis@ufc.br

Recebido Março de 2014 - Aceito Julho de 2014

RESUMO

A modelagem da previsão de vazões sazonais e interanuais no nordeste brasileiro representa um problema de grande relevância para o uso e gestão dos recursos hídricos; demandando-se dos modelos maior habilidade de previsão. Este ainda é um problema de difícil solução dada à variabilidade sazonal e interanual do clima semiárido. Neste trabalho é apresentada uma forma alternativa para modelagem da previsão climática sazonal a interanual, as redes neurais artificiais (RNA). Para o desenvolvimento do trabalho foi escolhida a bacia hidrográfica do açude Orós, devido a sua importância para os recursos hídricos no Estado do Ceará. Segundo estudos recentes, as temperaturas dos oceanos Atlântico Norte, Atlântico Sul e Pacífico Equatorial podem ser utilizados como preditores climáticos para a região Nordeste de forma satisfatória. O modelo proposto realiza em julho a previsão do regime de vazões do período chuvoso do ano seguinte (janeiro a junho). Este horizonte temporal é de grande relevância para a alocação de água. Dentre os modelos estudados, o que utilizou como entrada a média das anomalias de temperaturas dos meses de abril, maio e junho do ano anterior ao período previsto foi o que apresentou maior eficiência Nash-Sutcliffe (0,80).

Palavras-chave: Redes neurais artificiais; Previsão de vazões; Açude Orós.

ABSTRACT: STREAMFLOW FORECASTING FOR THE DAM ORÓS/CE FROM HYDROMETEOROLOGICAL DATA USING PERCEPTRONS

The modeling of seasonal and interannual streamflow forecasting at northeastern Brazil represents a great relevance problem to the use and management of water resources; which demands greater prediction ability models. This is still a difficult task to solve due to the seasonal and interannual climate variability at the semi-arid region. This work presents the artificial neural networks (ANN) as an alternative for modeling the seasonal to interannual climate prediction. For the development of this task the hydrographic Oros weir Basin was chosen due to its importance as water resources in the State of Ceara. According to recent studies, the temperatures of the North Atlantic, South Atlantic and equatorial Pacific can be satisfactorily as predictors for the Northeast climate. The proposed model predicts, in July, the next rainy season (January to June) river flow regime. This time frame is of great relevance for the allocation of water resources. Among the studied models, those using the average temperature anomalies of April, May and June preceding the predicted year as input data showed the highest Nash-Sutcliffe efficiency (0.80).

Keyword: Artificial neural network; Streamflow forecasting; Oros reservoir.

1. INTRODUÇÃO

O nordeste brasileiro encontra-se em uma região de clima semiárido, caracterizada principalmente por apresentar índices pluviométricos baixos, irregulares e mal distribuídos ao longo do ano, e ainda altas taxas de evaporação. Neste contexto insere-se o Estado do Ceará, onde a previsão dos fenômenos hidrometeorológicos torna-se altamente complexa, dada a alta variabilidade sazonal e interanual do clima semiárido.

De acordo com Souza Filho e Lall (2003), as regiões semiáridas são vulneráveis às flutuações climáticas e sofrem impacto nas reservas de água. Modelos de previsão de vazões em rios para perspectiva de alguns meses, ou até um ano, são muito importantes para a operação mais eficaz e eficiente dos recursos hídricos e o processo de alocação da água entre usos que são conflitantes. Desta forma, a previsão de vazões e a sua confiabilidade está relacionada ao eficiente gerenciamento dos recursos hídricos, que por sua vez, afeta diretamente o desenvolvimento econômico da região.

Considerando a importância e a dificuldade de estimação das vazões afluentes nos reservatórios na Região Nordeste do Brasil, as redes neurais artificiais (RNA) surgem como uma alternativa para o desenvolvimento de modelos que possam prever com grau de precisão adequado as vazões a partir do conhecimento de informações hidrometeorológicas.

As RNA são reconhecidamente ferramentas poderosas e eficientes utilizadas na modelagem de fenômenos complexos, multivariados e não lineares, uma vez que, baseadas nos princípios de funcionamento do cérebro humano, têm grande capacidade de aprender quando sujeitas aos estímulos existentes em um determinado ambiente. Vários são os exemplos de estudos de modelagem em engenharia utilizando as redes neurais artificiais, podendo-se citar, os trabalhos de Ruffier et al. (1998), Farias et al. (2003), Dantas Neto (2004), Santos (2010), dentre outros.

Assim, este artigo tem por objetivo apresentar um modelo para a previsão de vazões na bacia hidrográfica do açude Orós, situado no Estado do Ceará, a partir de dados hidrometeorológicos de um dado ano e fazendo a previsão para o ano seguinte utilizando-se como ferramenta de modelagem as redes neurais artificiais.

2. REDES NEURAS ARTIFICIAIS

As redes neurais artificiais são processadores maciçamente paralelos distribuídos e constituídos de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (Haykin, 2001). Do ponto de vista matemático uma rede neural artificial pode ser entendida como um conjunto de nós, ou

neurônios, organizados em camadas sucessivas, de forma análoga à rede neural mais poderosa conhecida, o cérebro humano.

Segundo Haykin (2001), um neurônio é uma unidade de processamento de informação que é fundamental para o funcionamento de uma rede neural. A Figura 1 mostra uma representação do neurônio artificial, como uma analogia ao neurônio biológico, com a apresentação de todos os seus elementos.

Em termos matemáticos, o neurônio k pode ser representado pelas seguintes equações:

$$u_k = \sum w_{ki} x_i = \{w\}^T \{x\} \quad (1)$$

$$v_k = u_k + b_k = \sum w_{ki} x_i + b_k = \{w\}^T \{x\} + b_k \quad (2)$$

$$y_k = f(v_k) = f\left(\sum w_{ki} x_i + b_k\right) = f(\{w\}^T \{x\} + b_k) \quad (3)$$

onde: u_k é a saída do combinador linear; v_k o campo local induzido; y_k o sinal de saída ou resposta do neurônio; b_k o viés ou limiar; $f(\cdot)$ a função de ativação do neurônio; $\{x\} = [x_1, x_2, x_3, \dots, x_m]^T$ o vetor dos sinais de entrada; e $\{w\} = [w_{k1} w_{k2} w_{k3} \dots w_{km}]^T$ o vetor dos pesos sinápticos que ligam o neurônio k ao vetor de entrada $\{x\}$.

Dentre os tipos de redes neurais utilizados para a modelagem de fenômenos em engenharia, destacam-se os perceptrons multicamada. O perceptron multicamada é uma rede neural multicamada alimentada adiante, constituído por três camadas: a camada de entrada, cuja função é a de receber os estímulos externos; uma ou mais camadas intermediárias, também denominadas ocultas, responsáveis pelo aumento da capacidade da rede neural artificial em extrair o comportamento mais complexo do ambiente, no qual a rede está inserida; e a camada de saída, cuja função é a de dar as respostas para os estímulos apresentados à rede neural.

Uma das mais importantes propriedades de uma rede neural é a sua habilidade de aprender a partir do ambiente na qual está inserida e melhorar seu desempenho através de um processo contínuo de treinamento. O treinamento de uma rede neural artificial consiste na alteração de todos os pesos sinápticos (w_{kj}) e limiares existentes (b_k), a partir da experiência conhecida sobre o fenômeno estudado, normalmente disponível em um conjunto de dados do tipo entrada-saída conhecida disponíveis.

O desempenho de uma rede neural pode ser avaliado por meio de uma função de custo média definida no conjunto de treinamento como:

$$E_{med}(n) = \frac{1}{2L} \sum_{i=1}^L \sum_{k \in c} e_k^2(i) = \frac{1}{2L} \sum_{i=1}^L \sum_{k \in c} [d_k(i) - y_k(i)]^2 \quad (4)$$

onde: c é o conjunto de todos os neurônios da camada de saída no exemplo i do conjunto de treinamento; $d_k(i)$ a saída desejada

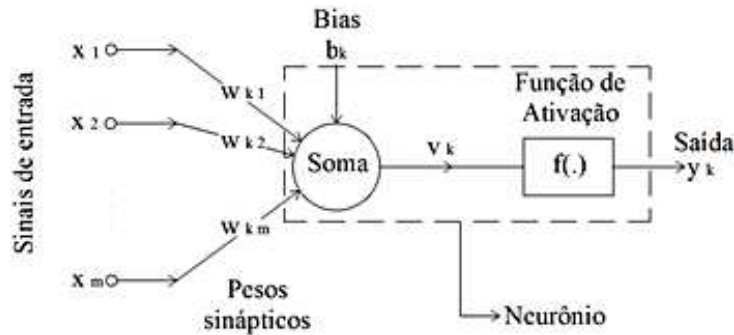


Figura 1 - Representação de um neurônio artificial.

(conhecida) para o neurônio k , no exemplo i ; $y_k(i)$ a resposta calculada pelo neurônio k , para os estímulos conhecidos no exemplo i ; $e_k(i)$ o sinal de erro do neurônio k , no exemplo i ; e n o passo de tempo discreto (época), correspondente a cada alteração do conjunto de pesos sinápticos no conjunto de treinamento.

O processo de treinamento de uma rede neural consiste nos ajustes sucessivos dos seus pesos sinápticos de forma a minimizar o valor da função de custo média em todo o conjunto de treinamento disponível. Para um neurônio pertencente à camada de saída $y_k(n)$, o ajuste do vetor dos pesos sinápticos que o liga aos neurônios, ou nós, da camada anterior $\{y_j(i)\}$ é dado pela minimização da função de custo média de forma iterativa percorrendo-se todo o conjunto de treinamento (época). Esta regra de alteração dos pesos sinápticos, conhecida como Regra Delta, é descrita pela seguinte expressão:

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} - \eta \nabla E_{med}(n) = \{w_{kj}(n)\} + \frac{\eta}{L} \sum_{i=1}^L \sum_{k \in C} \delta_j(i) \{y_j(i)\} \quad (5)$$

onde: $\{w_{kj}(n+1)\}$ é o vetor de pesos sinápticos entre os neurônios k e j na iteração (época) $n + 1$; $\{w_{kj}(n)\}$ o vetor de pesos sinápticos entre os neurônios k e j na iteração (época) n ; $\nabla E_{med}(n)$ o gradiente da função de custo média; η a taxa de aprendizagem; $\{y_j(i)\}$ o vetor de entrada do neurônio $y_k(n)$ no i -ésimo exemplo do conjunto de treinamento e $d_k(i)$ o gradiente local do neurônio $y_k(n)$, definido como:

$$\delta_k(i) = e_k(i) f'(v_k(i)) \quad (6)$$

onde: $e_k(i)$ é o sinal de erro do neurônio $y_k(i)$ no i -ésimo exemplo do conjunto de treinamento e $v_k(i)$ o campo local induzido do neurônio $y_k(i)$ no i -ésimo exemplo do conjunto de treinamento.

No caso de um neurônio da camada oculta, o cálculo direto do gradiente local não é possível, uma vez, que o sinal produzido no mesmo propagando-se até a camada seguinte,

não pode ser comparado a um valor conhecido, e portanto, não pode gerar nenhum sinal de erro. Neste caso, o gradiente local do neurônio da camada oculta é determinado por meio da retropropagação do sinal de erro produzido nos neurônios da camada de saída $y_k(i)$. Tal procedimento é conhecido como algoritmo de retropropagação do erro (*error back-propagation*), e foi desenvolvido por Rumelhart et al. (1986). Aplicando-se o algoritmo de retropropagação do erro, o gradiente local do neurônio $y_k(i)$ pertencente a uma camada oculta é determinado a partir da seguinte expressão:

$$\delta_j(i) = -\frac{1}{L} f'(v_j(i)) \cdot \sum_{i=1}^L \sum_{k \in C} \delta_k(i) \{w_{kj}(n)\} \quad (7)$$

onde: $d_j(i)$ é o gradiente local do neurônio $y_j(i)$, pertencente a uma camada oculta no i -ésimo exemplo do conjunto de treinamento; Com o objetivo de se aumentar a estabilidade do processo de ajustes dos pesos sinápticos, foi feita a inclusão na Regra Delta de um parâmetro α (momentum), que controla o laço de realimentação em torno do vetor de ajuste de $\{Dw_{kj}(n)\}$, conforme demonstrado por Rumelhart et al. (1986) citado por Raykin (2001). Desta forma, a alteração dos vetores dos pesos sinápticos, conhecida como Regra Delta Generalizada, é dada por:

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} + \frac{\eta}{L} \sum_{i=1}^L \sum_{k \in C} \delta_j(i) \{y_j(i)\} + \alpha \{\Delta w_{kj}(n-1)\} \quad (8)$$

3. PREVISÃO DE VAZÕES

A previsão de vazões, no Estado do Ceará, é um problema complexo e multivariado. Sua resolução está ligada principalmente ao conhecimento das variáveis climáticas que modelam o problema e de que forma estas se comportam, sendo necessário compreender o clima da região e os principais fatores que o influenciam.

A sazonalidade das chuvas na porção norte da região Nordeste e, portanto, a vazão é regida em grande parte pela

migração norte/sul da zona de convergência intertropical (ZCIT) (Uvo et al., 1998; Xavier e Xavier, 1998).

As precipitações nos meses de Janeiro e Fevereiro são afetadas por frentes frias e vórtices ciclônicos (Kousky, 1979). Porém a estação chuvosa principal é iniciada entre os meses de Fevereiro e Março, quando a ZCIT sobre o Oceano Atlântico Tropical alcança sua posição mais ao sul (Hastenrath e Lamb, 1977). O que determina o fim do período chuvoso é o retorno da ZCIT para o norte (Souza Filho e Lall, 2003). Em um ano chuvoso, a ZCIT permanece muitas vezes ao sul do equador até o início de Maio, porém em anos secos, a ZCIT pode ou não chegar a posições ao sul do equador ou retornar ao norte mais cedo, muitas vezes durante Março (Uvo et al., 1998).

As variações interanuais das precipitações na porção norte da região Nordeste, que ocasionam extremos climáticos caracterizando anos de secas gravíssimas ou enchentes, estão relacionadas com as variações de temperatura da superfície do mar (TSM) (Nobre, 2012).

Uvo et al. (1998) desenvolveram um trabalho de análise da precipitação no Nordeste e sua relação com a TSM. Os resultados indicam que anomalias quentes de TSM no Atlântico Sul Equatorial associam-se a uma migração mais cedo para o sul, que provocam chuvas abundantes em partes do Nordeste, incluindo o Ceará. De acordo com estudos anteriores eles encontram que a posição da ZCIT em abril e maio e, portanto, o fim da estação chuvosa do Nordeste é determinada, em grande parte por um gradiente norte-sul no Oceano Atlântico Tropical (Souza Filho e Lall, 2003). Modelo de previsão de precipitações para o Estado do Ceará foi desenvolvido por Xavier et al (2000).

Outro aspecto importante na circulação geral da atmosfera global, que também está associado com a variabilidade interanual das precipitações no Nordeste, é a ocorrência do fenômeno El Niño-Oscilação Sul (ENOS) sobre o Pacífico Equatorial. Quando ocorre a fase quente do ENOS, ou seja, o aquecimento das TSM no Pacífico Equatorial Leste, na maioria das vezes associada ao deslocamento das células convectivas atmosféricas da Indonésia para o Pacífico Central e Leste, o que acarreta o aumento do ramo descendente sobre o leste da região da Amazônia e a região Nordeste do Brasil. Com isto, há inibição do processo de formação de nebulosidade local, a ZCIT desloca-se para o norte, ocasionando seca na região Nordeste e leste da Amazônia. Já na ocorrência da fase fria do ENOS, também denominada La Niña, ou seja, o resfriamento das TSM no Pacífico Equatorial Leste, provoca efeito contrário ao El Niño favorecendo o aumento da precipitação na região Nordeste e leste da região da Amazônia (Nobre, 2012; Andreoli et. al, 2004). Andreoli e Kayano (2007) também identificaram em seus trabalhos que há uma tendência de aumento (diminuição) de precipitação na parte norte da região de estudo durante eventos de La Niña (El Niño).

Rajagopalan et al.(2002) identificaram o Nordeste brasileiro como uma das poucas regiões do mundo onde há maior habilidade de previsão consistente e estatisticamente significativa durante a estação chuvosa primária (Janeiro-Maio). Esta previsibilidade sazonal das precipitações no Nordeste é resultado das condições oceânicas globais (Nobre, 2012). Porém a sua variabilidade interanual, mesmo comprovadamente também ligada às condições oceânicas globais, é um problema complexo de previsão.

É conhecida a relação entre as temperaturas dos oceanos Atlântico Tropical e Pacífico Equatorial e a previsão climática na porção norte do Nordeste brasileiro, neste sentido, Souza Filho e Lall (2003) realizaram uma investigação da dependência da vazão com relação a TSM com as diferentes defasagens na região de interesse. Este estudo utilizou como preditores duas séries temporais: NINO3 (definida com a média da anomalia de temperatura da superfície do mar na região do Pacífico Equatorial entre 150 graus W e 90 graus W e 5 graus S e 5 graus N) e gradiente da TSM do Atlântico (EAD), série definida como a diferença na média mensal da anomalia de TSM do Atlântico Norte (5 graus N e 20 graus N, 60 graus W e 30 graus W) e a na média mensal da anomalia de TSM do Atlântico Sul (0 grau e 20 graus S, 30 graus W e 10 graus E). São consideradas as previsões no meio do ano anterior ao que se deseja prever.

4. MATERIAIS E MÉTODOS

Para o desenvolvimento do modelo inicialmente foram obtidos os dados de entrada e saída desejadas para a montagem do conjunto de treinamento e validação do modelo.

Os dados de entrada, que consistiram nas anomalias de temperaturas nas superfícies do mar dos oceanos Atlântico Norte, Atlântico Sul e Pacífico, foram derivados da malha de dados de TSM desenvolvidos por Kaplan et al. (1998) e encontram-se disponíveis em: <http://iridl.ldeo.columbia.edu/SOURCES/KAPLAN/EXTENDED>. As saídas desejadas para o modelo, que correspondem aos valores das vazões anuais medidas afluentes à bacia do Açude Orós, foram obtidas a partir das informações existentes nos postos fluviométricos da região (disponível em: <http://hidroweb.ana.gov.br/>), e através da modelagem chuva-vazão. A série histórica utilizada possui 88 anos, dados estes colhidos entre os anos de 1913 e 2000.

Para o desenvolvimento dos modelos com as RNA foi necessária a normalização dos dados utilizados. Esta normalização é necessária uma vez que a função de ativação (função sigmoide) utilizada para os cálculos dos sinais dos neurônios da camada de saída fornece resultados no intervalo (0, 1), devendo-se, portanto, os dados referentes às saídas desejadas encontrarem-se na mesma faixa de variação para que os sinais de erro possam ser avaliados corretamente. Além da

normalização das vazões, procedeu-se também à normalização dos dados de entrada.

Os valores dos dados de entrada e saída foram normalizados entre 0,15 e 0,85, considerando-se uma relação linear entre os valores de máximos e mínimos de cada uma das variáveis envolvidas (anomalias de temperaturas e vazões), conforme apresentado na Tabela 1.

O estabelecimento do modelo neuronal que melhor representa certo fenômeno consiste na definição da arquitetura da rede (definição do número de camadas de neurônios e do número de neurônios em cada camada), da escolha da função de ativação dos neurônios, e definição dos ajustes dos pesos sinápticos que melhor represente o comportamento do fenômeno estudado. Tal processo de modelagem envolve duas etapas: etapa de treinamento e etapa de validação.

Na etapa de treinamento os pesos sinápticos são alterados de forma a minimizar a função de custo com base nas informações existentes no conjunto de treinamento (Dantas Neto, 2004). É esperada que a rede se torne bem treinada de modo que aprenda suficientemente o comportamento do fenômeno estudado, representado pelas informações contidas no conjunto de treinamento.

Na etapa de validação do modelo é testada a capacidade de generalização da rede neural artificial após treinamento. Esta etapa é de fundamental importância, pois determina a qualidade do modelo, no qual o mesmo tem sua eficiência testada quando submetido a um conjunto de entrada não incluído no processo de treinamento.

No presente artigo foram testadas inúmeras arquiteturas de rede, sendo apresentados adiante, apenas os resultados do modelo que apresentou melhor desempenho nas fases de treinamento e validação. Em todas as arquiteturas consideradas foi utilizada a função sigmoide para a ativação dos neurônios, devido à comprovada eficiência desta função para a modelagem de fenômenos complexos com as redes neurais artificiais (Dantas Neto, 2004).

Na fase de treinamento foi adotado o valor de 0,8 para o fator α e foi permitida a variação da taxa de aprendizagem η entre 0,01 e 0,15, de forma a se ter uma maior rapidez e estabilidade no processo de ajuste dos pesos sinápticos e na convergência do algoritmo de retropropagação do erro.

Tabela 1 - Valores máximos e mínimos das variáveis envolvidas na modelagem da previsão de vazões com utilização das redes neurais artificiais.

Variável/ Valor	Entrada	Saída
	Anomalia de temperatura da superfície do mar (°C)	Vazão(m³/s)
Máximo	3,52	219,7
Mínimo	-1,61	0

Dos dados entrada-saída disponíveis, foram separados aleatoriamente um percentual de 89% para o treinamento da rede, e apenas 11% para a fase de validação. A quantidade de dados utilizada na fase de validação pode ser considerada pequena, entretanto, foi aquela utilizada neste trabalho em função da pequena quantidade de dados disponíveis para uma modelagem de um fenômeno tão complexo com o que se apresenta.

No desenvolvimento do modelo de previsão de vazões, para a bacia do açude Orós, foi considerado que a vazão afluente em um determinado ano é função dos valores das anomalias de temperatura da superfície do mar (Oceano Atlântico Sul, Oceano Atlântico Norte e Oceano Pacífico) do ano anterior. Os valores das anomalias em cada ano disponível foram considerados para 4 grupos diferentes: DJFM (dezembro, janeiro, fevereiro e março), AMJ (abril, maio e junho), JAS (julho agosto e setembro), e OND (outubro, novembro e dezembro).

Foram testadas diversas arquiteturas de rede considerando as seguintes variáveis de entradas:

- Nó 1 (SATL): média da anomalia de temperatura da superfície do mar na região do Atlântico Sul definida entre 0 e 20 graus S, 30 graus W e 10 graus E;
- Nó 2 (NATL): média da anomalia de temperatura da superfície do mar na região do Atlântico Norte definida entre 5 e 20 graus N, 60 e 30 graus W;
- Nó 3 (NINO3): média da anomalia de temperatura da superfície do mar na região do Pacífico Equatorial definida entre 150 e 90 graus W, 5 graus S e 5 graus N.

A camada de saída do modelo é composta apenas por um único neurônio, definida como a vazão (Q) anual afluente ao açude Orós.

Após o estabelecimento do modelo foi realizada a análise dos resíduos com objetivo de verificar se os resíduos do modelo se comportam segundo alguma distribuição de probabilidade. A adequação dos resíduos a um modelo distributivo pode significar o desenvolvimento de um modelo que permita a predição de desempenho do fenômeno, considerando sua variabilidade e confiabilidade através dos níveis e intervalos de confiança do modelo.

Para a determinação do intervalo de confiança dos resultados calculados pelo modelo de previsão foi feita a hipótese de que os resíduos apresentados por este modelo, calculados segundo a Equação 9, distribuíam-se segundo a Distribuição de Probabilidades Normal. Esta hipótese foi confirmada por meio de testes de aderência. Foi empregada a estatística χ^2 (“qui-quadrado”) para se verificar a normalidade ou não dos resíduos entre os valores reais e os valores calculados pelo modelo de previsão das vazões no açude Orós.

$$d = V_{real} - V_{cal} \quad (9)$$

Onde: d é o resíduo entre o valor medido e o valor calculado pelo modelo de previsão; V_{real} o valor real e V_{cal} o valor calculado pelo modelo de previsão.

Dadas as condições de normalidade das curvas de distribuição dos resíduos, determinou-se os intervalos de confiança para as médias dos resíduos, considerando-se um nível de confiança de $(1 - \alpha)$, calculado como (Triola, 1999):

$$\bar{d} - z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \leq V_{real} - V_{cal} \leq \bar{d} + z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \quad (10)$$

onde: \bar{d} é a média aritmética dos desvios calculados para o modelo; $z_{\alpha/2}$ a variável aleatória da distribuição Normal, para qual a probabilidade de ocorrência de um valor $d \leq (1 - \alpha)$; σ o desvio-padrão da amostra e n o tamanho da amostra.

Adicionalmente, nas fases de treinamento e validação foi determinado o coeficiente de eficiência Nash-Sutcliffe para avaliar o poder preditivo do modelo, o qual é definido como (Nash e Sutcliffe, 1970):

$$E = \frac{\sum (Q_o - Q_m)^2}{\sum (Q_o - \bar{Q}_o)^2} \quad (11)$$

onde: Q_o é a vazão observada, \bar{Q}_o a vazão média observada e Q_m a vazão calculada pelo modelo.

5. RESULTADOS E DISCUSSÃO

O modelo apresentado neste trabalho tem por objetivo fazer a previsão da vazão anual afluente ao açude Orós utilizando as anomalias de temperatura das superfícies do Oceano Atlântico Sul, Oceano Atlântico Norte e Oceano Pacífico do ano anterior ao da previsão, podendo ser, de forma simplificada, representado como:

$$Q = f(SATL, NATL, NINO3) \quad (12)$$

O modelo que forneceu os melhores resultados foi o que utiliza como dados de entrada a média das anomalias de temperatura dos meses de abril, maio e junho (AMJ) do ano anterior ao da previsão com uma arquitetura com 3 nós de entrada, 6 neurônios na camada intermediária e 1 neurônio na camada de saída (A:3-6-1), conforme mostrado na Figura 2. A avaliação da eficiência do modelo foi feita em função do coeficiente de determinação (R^2) obtido durante a fase de validação.

Os resultados da Figura 3 mostram a evolução do coeficiente de determinação em função do número de iterações, para a alteração dos pesos sinápticos da rede, obtido nas fases de treinamento e validação. De acordo com estes resultados, pode-se observar que o modelo apresenta um desempenho satisfatório na fase de validação apenas com os pesos sinápticos obtidos após 1.000.000 de iterações. Os baixos valores de R^2 obtidos nas




Figura 2 - Arquitetura do modelo de previsão de vazão para o açude Orós.

outras situações podem indicar a ocorrência de “*over-fitting*”, ou treinamento excessivo, que é o processo no qual a rede consegue entender completamente o comportamento do conjunto de treinamento, mas não apresenta capacidade de generalização satisfatória a respeito do entendimento do processo que rege a previsão de vazões a partir dos dados de entrada fornecidos.

Para o modelo escolhido, conjunto de anomalias de temperatura dos meses AMJ e arquitetura A:3-6-1, o coeficiente de determinação (R^2) obtido na fase de treinamento, após 1.000.000 de iterações, e na fase de validação foi de 0,80. As Figuras 4 e 5 mostram a correlação entre os valores das vazões calculados pela rede e os valores reais disponíveis nos conjuntos utilizados para treinamento e validação do modelo.

De acordo com os resultados apresentados na Figura 4, observa-se que além de apresentar, uma correlação satisfatória entre os valores calculados pela rede e os valores desejados, o modelo apresenta um bom desempenho, quando da previsão das máximas cheias ocorridas no período analisado, podendo vir a ser uma ferramenta útil na previsão de cheias na bacia do açude Orós.

A Tabela 2 apresenta os valores percentuais da contribuição de cada uma das variáveis de entrada na resposta da rede para o modelo neuronal. Estes resultados mostram que as anomalias de temperatura da superfície do mar do Oceano Atlântico são as que mais influenciam (63,84%) no processo de previsão das vazões afluentes ao açude Orós.

A Tabela 3 apresenta os valores dos pesos sinápticos (w_{kj}) e dos limiares (b_k) obtidos após o treinamento do modelo adotado para a previsão das vazões no açude Orós após 1.000.000 de iterações. O conhecimento destes valores, juntamente com a utilização das equações apresentadas anteriormente permitem a implementação do modelo de previsão proposto em uma

Tabela 2 - Contribuição das variáveis estudadas na previsão de vazões no açude Orós calculada pelo programa QNET.

Entrada	1- SATL	2 - NATL	3- NINO 3
Contribuição (%)	39,25	24,59	36,16

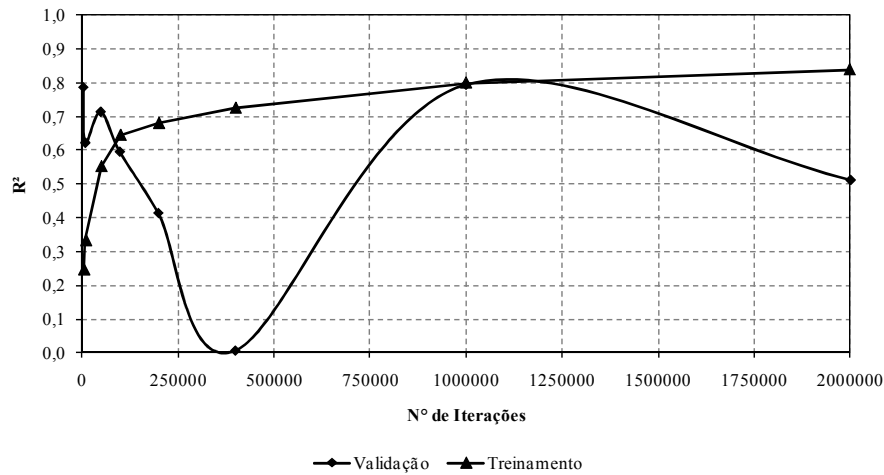


Figura 3 - Variação do coeficiente de determinação (R^2) com o número de iterações.

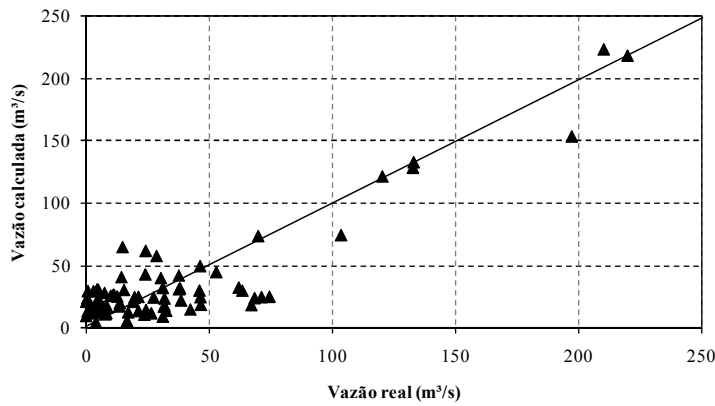


Figura 4 - Correlação entre os valores calculados pela rede e os valores reais da vazão para o açude Orós na fase de treinamento.

Tabela 3 - Valores dos pesos sinápticos (w_{kj}) e dos limiares (b_k) entre as camadas constituintes do modelo de previsão das vazões no açude Orós obtidos após o treinamento da rede.

		Camada de entrada				Camada de saída	
		SATL	NATL	NINO3	b_k	Q	b_k
Camada intermediária	1	-6,48622	78,86013	34,05352	-36,17426	-13,0418	7,1478
	2	-2,8697	57,1893	26,4281	-27,2542	19,9466	7,1478
	3	-110,7340	-58,6530	-57,3314	67,1025	35,9444	7,1478
	4	-27,6513	-162,2770	32,1444	36,0985	46,1233	7,1478
	5	-137,9530	56,0111	19,7534	37,0341	-2,5995	7,1478
	6	-0,5017	22,8163	12,5457	-10,5445	-12,9615	7,1478

planilha de cálculo qualquer, sem a necessidade do software no qual o modelo foi desenvolvido, sendo uma das grandes vantagens da modelagem com as redes neurais artificiais.

Após a definição e estabelecimento do modelo de previsão de vazões, se procedeu à análise dos resíduos, com o objetivo de se determinar uma distribuição de probabilidade

para os mesmos, e em seguida se definir o nível de confiança para os valores obtidos pelo modelo de previsão de vazões do açude Orós. A partir da realização de testes de aderência, observou-se que os resíduos do modelo se adequavam à Distribuição de Probabilidade Normal, e que considerando um nível de confiança de 95%, o valor real da vazão (Q_{real}) afluente




Figura 5 - Correlação entre os valores calculados pela rede (modelo e intervalos de confiança) e os valores reais da vazão para o açude Orós na fase de validação.

ao açude Orós pode ser dada em função do valor calculado pela rede (Q_{cal}) de acordo com a seguinte expressão:

$$Q_{cal} - 23,63 \leq Q_{real} \leq Q_{cal} - 12,39 \quad (13)$$

Considerando a eficiência Nash-Stutcliffe do modelo na fase de treinamento, obteve-se o valor de 0,80. Para os dados utilizados na fase de validação, a eficiência para o modelo considerando os valores calculados pela rede foi de 0,30, a qual é considerada baixa. Entretanto, considerando-se os valores obtidos pelo modelo dentro do intervalo de confiança representado pela Equação 13, também mostrados na Figura 5, a eficiência do modelo situou-se entre 0,80 e 0,86, indicando que o modelo apresenta boa eficiência mesmo com os dados da validação.

Para constatar também a eficiência para os anos secos foram separados um terço dos menores valores de vazão da série histórica, e para estes dados foi determinada uma eficiência Nash-Stutcliffe de 0,65, demonstrando assim que o modelo também apresenta resultados satisfatórios para os anos mais secos.

As Figuras 6 e 7 apresentam as distribuições dos dados modelados e observados. Verifica-se que para os menores valores de vazões ocorrem diferenças maiores entre os valores calculados pelo modelo e os valores reais. Nesta situação, observa-se que os valores fornecidos pelo modelo são superiores aos valores reais, especificamente, no primeiro quartil. Para maiores vazões, observa-se uma maior proximidade entre os valores fornecidos pela rede e os valores reais.

6. CONCLUSÕES

Este trabalho apresentou um modelo para previsão de vazões na bacia hidrográfica do açude Orós no Estado do Ceará utilizando redes neurais artificiais a partir de uma série

histórica de 87 anos de dados hidrometeorológicos (anomalias de temperatura da superfície do mar e vazões).

O modelo desenvolvido utiliza como variáveis de entrada a média das anomalias de temperatura da superfície do mar dos meses de abril, maio e junho; tem como função de ativação a função sigmóide; e uma arquitetura com três nós na camada de entrada, seis neurônios na camada oculta e um neurônio na camada de saída (A:3-6-1), apresentando o maior coeficiente de determinação ($R^2=0,80$) na etapa de validação, entre todas as arquiteturas testadas.

Considerando o tamanho da série histórica utilizada, e mesmo o modelo tendo superestimado as vazões na etapa de validação, os resultados podem ser considerados satisfatórios e representam um aumento na confiança da previsão de vazões. Porém, é necessária a comparação dos resultados obtidos com o modelo utilizando RNA com outros modelos correntes (métodos estatísticos ou dinâmicos), para constatação da eficiência do modelo apresentado neste trabalho.

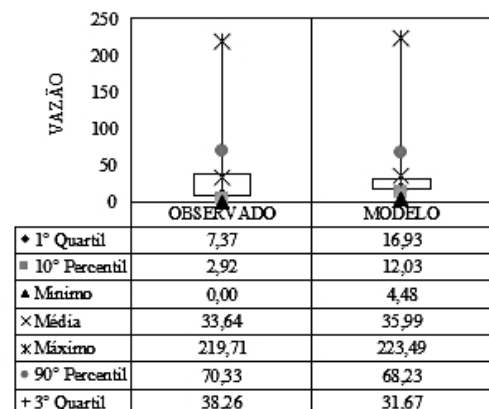


Figura 6 - Distribuição dos dados observados e modelados.

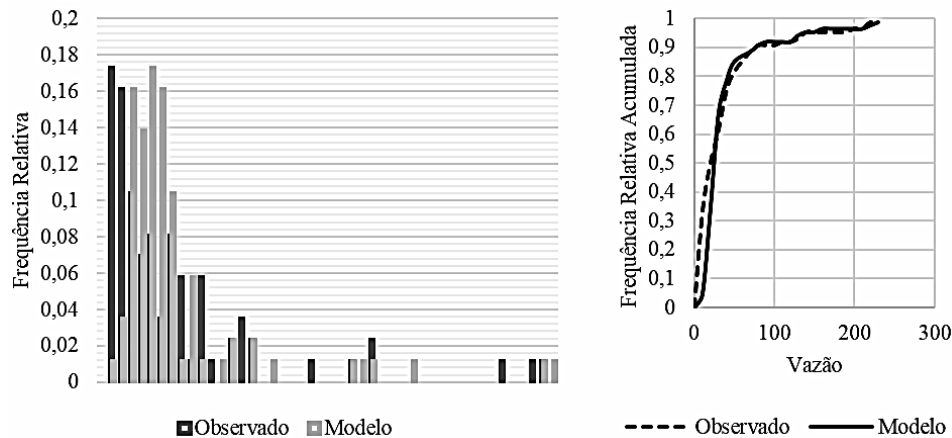


Figura 7 - Frequência relativa e frequência relativa acumulada.

O modelo encontrado representa uma contribuição para a melhor gestão dos recursos hídricos no Estado do Ceará, pois a previsão de vazões para um ano, realizada dada ao final de junho do anterior ao da previsão, quando são feitas as decisões de alocação dos recursos hídricos para o período seco do ano (julho-dezembro), representa uma consideração menos conservadora que a feita hoje pela COGERH (Companhia de Gestão de Recursos Hídricos do Ceará), que considera aporte hídrico nulo para a estação chuvosa do ano da previsão.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- ANDREOLI, R. V.; KAYANO, M. T.; GUEDES, R. L.; OYAMA, M.D.; ALVES M. A. S.; A influência da temperatura da superfície do mar dos Oceanos Pacífico e Atlântico na variabilidade de precipitação em Fortaleza. **Revista Brasileira de Meteorologia**, v. 19, n.2, p.113-122, 2004.
- ANDREOLI, R. V.; KAYANO, M. T.; A importância relativa do Atlântico Tropical Sul e Pacífico Leste na variabilidade de precipitação do nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 22, n.1, p.63-74, 2007.
- DANTAS NETO, S. A. **Avaliação das Propriedades dos Ligantes e das Misturas Asfálticas Modificadas com Borracha Granulada de Pneus Usados**. Tese de Doutorado, publicação G.TD – 024/04, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 2004, 265p.
- FARIAS, M.M.; DANTAS NETO, S.A.; e SOUSA, R.O. Prediction of Longitudinal Roughness Using Neural Network. **Third International Symposium on Maintenance and Rehabilitation of Pavements and Technological Control**, Guimarães, Portugal, 2004, p.87-97.
- HASTENRATH, S.; LAMB P. J. **Climatic Atlas of the Tropical Atlantic and Eastern Pacific Ocean**. University of Wisconsin Press, 1977.
- HAYKIN, S. **Redes Neurais Artificiais: Princípios e práticas**. 2ª edição, Editora Bookman, Porto Alegre, 2001.
- KAPLAN, A.; CANE, M.; KUSHNIR, Y.; CLEMENT, A.; BLUMENTHAL, M.; RAJAGOPALAN, B. Analyses of global sea surface temperature. 1856 – 1991, **Journal of Geophysical Research**, v. 103, n. C9, p. 18,567–18,589, 1998.
- KOUSKY, V. E., Frontal influences on northeast Brazil, **Monthly Weather Review**, v. 107, p. 1140 – 1153, 1979.
- NASH J. E.; SUTCLIFFE J. V. River flow forecasting through conceptual models part I — A discussion of principles. **Journal of Hydrology**, v. 10, 3 ed., p. 282-290, 1970.
- NOBRE, P.; **As origens das águas no Nordeste. A questão da água no nordeste**. Centro de Gestão e Estudos Estratégicos, Agência Nacional de Águas. – Brasília, DF: CGEE, 2012. ISBN 978-85-60755-45-5
- RAJAGOPALAN, B.; LALL U.; ZEBIAK S. E. Categorical climate forecasts through regularization and optimal combination of multiple GCM ensembles. **Monthly Weather Review**, v.130(7), p. 1792 - 1811, 2002.
- RUFFIER, R.P.; LISBOA, E.F.A.; DANZIGER, F.A.B. Aplicação de Redes Neurais ao Estudo da Capacidade de Carga de Fundações à Tração. **Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica**. Curitiba, Paraná, Brasil, 1998.
- RUMELHART, D.E; HINTON, G.E.; and WILLIAMS, R.J. Learning Internal Representations of Back-Propagation Error. **Nature**, v.. 323, p. 533-536, 1986.
- SANTOS, F.P. **Aplicação de redes neurais artificiais para predição da tensão de flambagem distorcional em perfis formados a frio**. Monografia de graduação. Universidade Federal de Feira de Santana. Bahia, Brasil, 2010.

- SOUZA FILHO, F. A.; LALL, U. Seasonal to interannual ensemble streamflow forecasts for Ceara, Brazil: Application of multivariate, semiparametric algorithm. **Water Resources Research**, v. 39, n. 11, p. SWC1-SWC13, 2003.
- TRIOLA, M. F. **Introdução a Estatística**. 7ª edição, Editora LTC, Rio de Janeiro, 1999.
- UVO, C. B.; REPELLI, C. A.; ZEBIAK, S. E.; KUSHNIR, Y.; The relationship between tropical Pacific and Atlantic SST and northeast Brazil monthly precipitation, **Journal of Climate**, 11(4), p. 551– 562, 1998.
- XAVIER, T. de Ma. B. S.; XAVIER, A. F. S. **Quantis para séries pluviométricas do Estado do Ceará e caracterização de períodos secos ou excepcionalmente chuvosos: 1964-1998**. Fundação Cearense de Meteorologia e Recursos Hídricos. Fortaleza. Ceará, p. 33. 1998.
- XAVIER, T. M. B. S. et al. Previsão regional de chuva para o Estado do Ceará através do projeto “Tempo de Chuva”: 1964-1999. **Revista Brasileira de Recursos Hídricos**, v.5, p.69-92. 2000.