

Eixo Temático ET-11-006 - Outros

## **PREVISÃO DE SECA NA BACIA HIDROGRÁFICA DO AÇUDE EPITÁCIO PESSOA/PARAÍBA COM BASE EM REDES NEURAIS ARTIFICIAIS**

Jamille Freire Amorim<sup>1</sup>, Francisco Jácome Sarmento<sup>2</sup>

<sup>1</sup>Engenheira Ambiental - Universidade Federal da Paraíba, Centro de Tecnologia, *Campus* João Pessoa-Paraíba.

<sup>2</sup>Professor Doutor - Universidade Federal da Paraíba, Centro de Tecnologia, *Campus* João Pessoa-Paraíba.

### **RESUMO**

A previsão de eventos de seca desempenha um papel importante na mitigação dos seus impactos, principalmente, sobre os sistemas de recursos hídricos e seus consequentes efeitos socioeconômicos. O presente trabalho foi proposto com o intuito de avaliar a aplicabilidade de redes neurais artificiais (RNAs) na identificação e previsão de secas utilizando o índice de precipitação padronizado (SPI) na bacia hidrográfica do Açude Epitácio Pessoa, localizado no semiárido do estado da Paraíba. A princípio, os valores SPI 24, 12, 6, e 3 foram calculados para as séries históricas de três postos pluviométricos selecionados. Em seguida, foram criadas RNAs onde utilizaram-se diversas arquiteturas buscando a melhor descrição da relação entre as variáveis. O algoritmo *backpropagation* foi utilizado para ajustar os coeficientes envolvidos nas redes neurais como método alternativo ao cálculo do SPI – através da construção de RNAs sem defasagem entre os dados, e sua capacidade de previsão – através do uso de RNAs com defasagem dos dados. Os resultados obtidos mostraram uma boa capacidade de RNAs de 10 neurônios na camada intermediária para o cálculo do SPI em todos os postos pluviométricos estudados. No entanto, a construção das redes com defasagem de dados mostrou-se incapaz de prever secas.

**Palavras-chave:** Índice de Precipitação; Previsão de secas; Redes Neurais.

### **INTRODUÇÃO**

No período entre 1994 e 2013, os eventos de seca afetaram mais de um bilhão de pessoas no mundo (CRED, 2015). No Brasil, a região semiárida nordestina é a que mais reporta ocorrências de seca no país, sofrendo recorrentemente com os efeitos desse evento. O relato de períodos de secas nessa região remonta ao século XVI, sendo uma constante na literatura a abordagem sobre esse fenômeno e a convivência de grande parte do povo nordestino com o mesmo (Pontes e Machado, 2008).

As causas e consequências de tal evento podem ser diversas e estar interconectadas de forma sistêmica. Dessa forma, a seca pode estar associada a diversos fatores climáticos globais, hidrológicos, geológicos e meteorológicos, com efeitos capazes de se manifestar de diferentes formas na sociedade e de gerar uma grande gama de impactos. Assim, o entendimento dos eventos de seca é um processo complexo.

Sob essa perspectiva pesquisadores desenvolveram os índices de seca, dos quais é possível que se investigue e compreenda de forma mais eficaz e prática a seca e seus impactos, contribuindo para sua monitoração, e até certo grau, predição (Rosa, 2011). Existe uma grande variabilidade de índices de seca disponíveis na literatura, dentre eles, o Índice de Precipitação Padronizado - *Standardized Precipitation Index* (SPI), que foi desenvolvido por McKee et al. (1993).

Com o objetivo de identificar os períodos de seca e avaliar a sua severidade, em várias escalas temporais, o SPI baseia-se na distribuição de probabilidades da precipitação e traduz o desvio das condições “normais”, identificando anomalias. Logo, esse índice expressa o afastamento entre a precipitação observada e a média, em unidades de desvio padrão, no mês

considerado. Esta característica permite efetuar, portanto, comparações entre valores de SPI obtidos em diferentes locais ou em períodos diferentes, mesmo que tais regiões apresentem climas bastante distintos (SANTOS; PORTELA, 2010).

É importante destacar que além do monitoramento, a previsão das secas desempenha um papel importante na mitigação dos seus impactos. A possibilidade de previsão de eventos de seca permite que as autoridades competentes possam colocar em prática planos de ação, antes que o problema esteja instalado, reduzindo possíveis impactos. Em décadas recentes, as Redes Neurais Artificiais (RNAs) têm demonstrado uma grande capacidade na modelagem de séries temporais hidrológicas, despontando como uma ferramenta útil na previsão de fenômenos naturais (PARTAL et al., 2014; DAYAL et al., 2017).

Assim, levando em consideração a necessidade do conhecimento, monitoramento e previsão do fenômeno da seca, especialmente na região do semiárido brasileiro, é que essa pesquisa se justifica.

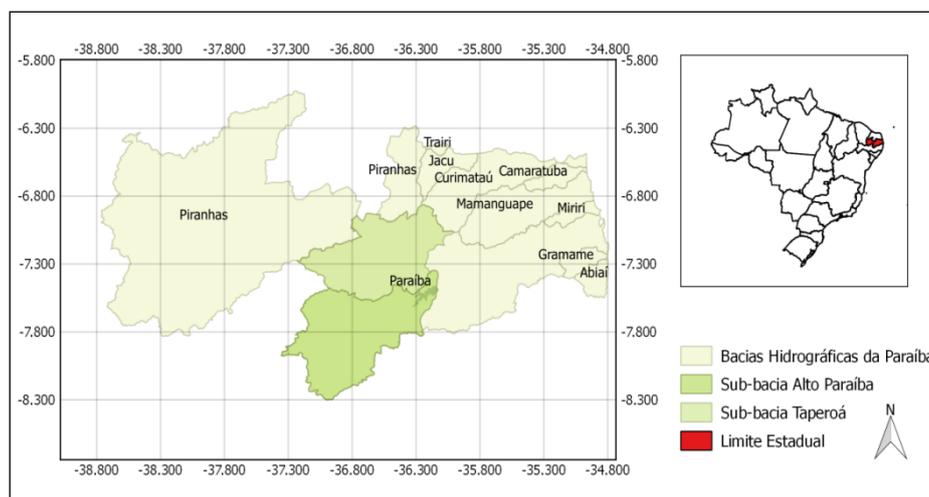
## OBJETIVO

Com base no exposto, este trabalho tem como objetivo avaliar a aplicabilidade de redes neurais artificiais na identificação e previsão de secas utilizando o índice de precipitação padronizado, em diferentes escalas temporais, no âmbito da bacia hidrográfica do açude Epitácio Pessoa.

## METODOLOGIA

### Área de estudo

A pesquisa foi realizada para a bacia hidrográfica do açude Epitácio Pessoa, também conhecido como Açude Boqueirão, situado entre as coordenadas geográficas 07° 28' 4" e 07° 33' 32" de latitude Sul e 36° 08' 23" e 36° 16' 51" de longitude Oeste. A barragem do açude está localizada no município Boqueirão-PB, a 165 km da capital do estado da Paraíba (João Pessoa) e a 44 km de Campina Grande. A bacia hidrográfica do Boqueirão pertence à grande bacia hidrográfica do rio Paraíba, uma das mais importantes do Estado (Figura 1). A contribuição de vazões para o açude vem, principalmente, das sub-bacias do Alto curso do rio Paraíba e do Rio Taperoá.



**Figura 1.** Mapa das bacias e sub-bacias hidrográficas do estado da Paraíba Fonte: elaboração própria, 2017.

Em termos climatológicos, a bacia hidrográfica do açude Epitácio Pessoa está inserida no clima do tipo Bsh, ou seja, semiárido quente, com estação seca. É, considerada a região mais seca do Brasil. As variações de temperatura atingem mínimas mensais de 18 a 22°C entre os meses de julho e agosto, e máximas mensais de 28 a 31°C entre os meses de novembro e

dezembro. O regime pluviométrico apresenta precipitações médias anuais que variam entre 250 e 750 mm, sendo que os totais anuais se concentram em um período de quatro meses, que, geralmente, corresponde aos meses de fevereiro, março, abril e maio. A umidade relativa do ar alcança uma média mensal de 60 a 75%, observando-se que os valores máximos ocorrem, geralmente, no mês de junho e os mínimos no mês de dezembro. Os totais anuais da evaporação, medidos em tanque Classe A, variam entre 2.500 a 3.000 mm, com valores decrescentes de oeste para leste (BRITO, 2008).

### Dados

Neste estudo foram considerados valores de precipitação mensal de três postos pluviométricos pertencentes à bacia hidrográfica do Rio Paraíba: Barra de São Miguel, Salgadinho e Passagem (Tabela 1). Os dados foram adquiridos pela ANA (2017) e a escolha dos postos foi feita baseada na qualidade dos dados, analisando-se a consistência e o tamanho das séries disponíveis.

**Tabela 1.** Postos pluviométricos selecionados para o estudo.

Número do posto	Código do posto	Longitude (°)	Latitude (°)	Relevo (m)	Município/posto	Período de Dados
1	736025	-36,318	-7,752	520	Barra de São Miguel	1963-1991
2	737010	-37,048	-7,136	340	Passagem	1962 - 1989
3	736010	-36,845	-7,102	410	Salgadinho	1939 - 1989

Fonte: adaptado de Guedes (2011).

### Cálculo do SPI

O cálculo do SPI é determinado pelo ajuste de uma função de densidade de probabilidade que descreve séries históricas de precipitação acumulada para uma escala de tempo de interesse (1 mês, 3 meses, 6 meses, etc). Como a precipitação segue uma distribuição assimétrica, a distribuição gama, definida na Equação (1) é utilizada para representar a distribuição teórica para essa variável.

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta}, \quad x > 0 \quad (1)$$

Após a determinação dos parâmetros  $\alpha$  e  $\beta$ , estes são utilizados para determinar a probabilidade acumulada ( $G(x)$ ) de um valor de precipitação observado para um dado mês e escala de tempo. A função de probabilidade acumulada é dada por:

$$G(x) = \int_0^x g(x) dx = \frac{1}{\beta^\alpha \Gamma(\alpha)} \int_0^x x^{\alpha-1} e^{-x/\beta} dx \quad (2)$$

Visto que a função gama é indefinida para  $x = 0$  e uma amostra de dados de precipitação pode conter zeros, a probabilidade acumulada torna-se:

$$H(x) = q + (1 - q)G(x) \quad (3)$$

Onde  $q$  é a probabilidade de ocorrência de precipitação zero. Sendo  $m$  o número de zeros em uma série de precipitações analisada, Thom (1966) afirma que  $q$  pode ser estimado por  $m/n$ .

A probabilidade acumulada  $H(x)$  é então transformada em variável aleatória normal padronizada  $Z$  com média zero e variância um, que é o valor do SPI.

$$Z = SPI = + \left( t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \text{ para } 0 < H(x) \leq 0,5 \quad (4)$$

$$Z = SPI = - \left( t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \text{ para } 0,5 < H(x) < 1,0 \quad (5)$$

Onde:

$$t = \sqrt{\ln\left(\frac{1}{(H(x))^2}\right)} \text{ para } 0 < H(x) \leq 0,5 \quad (6)$$

$$t = \sqrt{\ln\left(\frac{1}{(1-H(x))^2}\right)} \text{ para } 0,5 < H(x) < 1,0 \quad (7)$$

e,  $c_0=2,515517$ ;  $c_1=0,802853$ ;  $c_2=0,010328$ ;  
 $d_1 = 1,432788$ ;  $d_2 = 0,189269$ ;  $d_3 = 0,001308$ .

De acordo com a metodologia do SPI, o evento seca ocorre no período em que o valor do SPI é continuamente negativo. Quando o SPI se torna positivo tal evento cessa. Assim, a análise de uma sequência histórica de valores SPI permite avaliar a frequência de eventos anômalos de secas e chuvas extremas em uma região (Tabela 2).

**Tabela 2.** Classificação da precipitação baseado no valor SPI.

Valores de SPI	Classe
2,00 ou mais	Extremamente Úmido
1,50 a 1,99	Severamente Úmido
1,00 a 1,49	Moderadamente Úmido
0,10 a 0,99	Umidamente Incipiente
0 a -0,99	Seca Incipiente
-1,00 a -1,49	Moderadamente Seco
-1,50 a -1,99	Severamente Seco
-2,00 ou menos	Extremamente Seco

Fonte: Adaptado de McKee (1993).

O cálculo da função de distribuição de probabilidade das precipitações e do SPI desse trabalho foi feito por meio do uso de planilhas do Excel. A função estatística *DISTGAMA* presente no Excel foi utilizada para o cálculo da função de probabilidade acumulada.

Em seguida calculou-se o índice SPI de cada um dos postos pluviométricos para as escalas de tempo de 3 meses, 6 meses, 12 meses e 24 meses. Os valores obtidos foram validados através de comparação com resultados gerados pelo programa computacional *SPI program*, desenvolvido pelo *National drought Mitigation Center* dos Estados Unidos da América. Por fim, foram criadas equações polinomiais baseadas na linha de tendência da relação entre a precipitação e o respectivo SPI de cada posto.

### Concepção da rede neural

As RNAs são conjuntos bem estruturados de unidades de processamento dispostas em camadas interconectadas entre si, que tentam reconhecer regularidades e padrões de entrada para aprender com a experiência e realizar generalizações. Podem, portanto, representar qualquer relação funcional complexa, por meio de funções não lineares entre conjunto de dados (FERNANDES et al., 1995).

As RNAs utilizadas no presente estudo foram do tipo Multilayer Perceptron (MLP) com três camadas. A camada de entrada, não faz processamento, portanto, não se atribui a ela

funções de ativação. Nessa camada há apenas um neurônio onde é inserido o valor normalizado da precipitação que modificado por um peso envia seu dado de entrada para os neurônios da próxima camada. Na camada intermediária adotou-se a função de transferência sigmoide e variou-se o número de neurônios a fim de escolher o modelo que melhor prediz os valores de SPI. Na camada de saída, que possui apenas um neurônio, também foi adotada a função de transferência sigmoide.

Em todas as RNAs, o treinamento foi realizado utilizando o algoritmo de aprendizado *backpropagation*. De acordo com Tayfur (2012), esse método de treinamento é, provavelmente, o mais aplicado e conhecido, além de ser robusto e possuir uma alta capacidade de aprendizagem.

O cálculo de treinamento de uma RNA do tipo *backpropagation* é o feito como se segue.

A conexão dos pesos é ajustada baseada na Equação 8:

$$w_{ij}^{novo} = w_{ij}^{velho} - \eta \frac{\partial E(w_{ij})}{\partial w_{ij}} \quad (8)$$

Onde,  $w_{ij}$  é o valor do peso da conexão entre os neurônios da camada intermediária e de saída,  $\eta$  é o fator de aprendizagem e  $E$  é o erro entre o valor de saída e o valor esperado.

O erro ( $E$ ) é calculado como mostrado abaixo (Equação 9).

$$E = \frac{1}{2} \sum_{k=1}^p \sum_{j=1}^q (t_{kj} - z_{kj})^2 \quad (9)$$

Onde,  $p$  é o número de padrões de treinamento,  $q$  é o número de neurônios de saída;  $t_{kj}$  é o valor de saída que se pretende atingir e  $z_{kj}$  é o valor de saída na camada de saída.

Assim, para esse estudo foram criados dois grupos de RNAs para os valores SPI 24, SPI 12 e SPI6, utilizando o algoritmo acima descrito. As redes neurais desenvolvidas apresentaram um neurônio de entrada referente ao valor de precipitação acumulada e um neurônio de saída referente ao valor SPI observado. Variou-se o número de neurônios na camada intermediária para 5, 10, 15 e 20 neurônios, totalizando 32 RNAs distintas.

O primeiro grupo de RNAs foi criado sem a influência da defasagem temporal, ou seja, os valores de entrada de precipitação acumulada e os valores SPI de saída correspondem ao mesmo período de tempo analisado. O segundo grupo de RNAs foi criado a partir da defasagem temporal da série de dados. Dessa forma, os valores de saída referem-se aos valores de precipitação acumulada do período anterior.

Portanto, neste estudo utilizaram-se diversas arquiteturas de RNA com o algoritmo *backpropagation* a fim de avaliar o uso de redes neurais como método alternativo ao cálculo do SPI – através da construção de RNAs sem defasagem temporal de dados, e sua capacidade de previsão – através do uso de RNAs com defasagem temporal de dados.

### Treinamento da RNA

A fase de treinamento das RNAs foi realizada com os dados do posto pluviométrico Salgadinho. O posto pluviométrico Salgadinho foi utilizado por possuir a maior sequência de observações temporais disponíveis dentre os três postos pluviométricos avaliados no presente estudo.

#### Normalização de dados

Antes do início do treinamento todos os dados de entrada e saída foram normalizados através da Equação 10 proposta por Tayfur (2012), que comprime os dados em um alcance entre (0,1; 0,9) considerando os limites da função sigmoide.

$$z_i = 0,1 + \frac{0,8(x_i - x_{min})}{x_{max} - x_{min}} \quad (10)$$

Onde,  $z_i$  é o valor normalizado,  $x_i$  é o valor não normalizado de entrada,  $x_{min}$  é o valor mínimo dos dados que se pretende normalizar e  $x_{max}$  é o valor máximo dos dados que se pretende normalizar.

A Equação 10 foi adotada para esse estudo, pois, de acordo com Tayfur (2012), pode ser utilizada para a maior parte das aplicações de RNA.

#### Separação dos dados

Os dados foram separados em valores para treinamento, validação e teste, correspondentes a 60, 20 e 20% dos valores disponíveis, respectivamente.

#### Adoção de valores de parâmetros

Para as RNAs 5, 10, 15 e 20 foram estabelecidos valores iniciais de pesos e vieses Além disso, para o fator de aprendizagem ( $\eta$ ), parâmetro pertencente ao algoritmo *backpropagation* que influencia diretamente no ajuste dos pesos, adotou-se um valor fixo de  $\eta = 0,0001$ . O valor foi escolhido a partir de observações do comportamento das redes neurais trabalhadas.

#### Validação cruzada (*K fold*)

A fim de evitar o treinamento excessivo da rede (*overtraining*), os dados de treinamento e validação foram divididos em 10 partições a partir da técnica de validação cruzada (*K fold*). Ao final do treinamento de cada partição, os valores ajustados dos seus respectivos pesos e vieses foram armazenados. Por fim, para a rede treinada os pesos e vieses adotados foram obtidos a partir do cálculo das médias dos valores ajustados das 10 partições treinadas. No final de cada treinamento, com os pesos e vieses ajustados, a RNA foi simulada para gerar resultados.

A rede neural utilizada neste trabalho foi criada no *software R - Toolbox neuralnet*, que através de um processo iterativo aplicando o algoritmo *backpropagation*, treinou redes neurais para os variados números de neurônios na camada intermediária.

#### Índices de Desempenho

Para se avaliar o desempenho de todas as RNAs utilizaram-se duas técnicas estatísticas: Erro Quadrático Médio (EQM) e Coeficiente de Eficiência (CE).

Erro Quadrático Médio:

$$EQM = \sqrt{\frac{\sum_i^N (O_{mi} - O_{pi})^2}{N}} \quad (11)$$

Onde,  $O_{mi}$  é o valor de saída observado;  $O_{pi}$  é o valor previsto pela rede e  $N$  é o número de observações.

Coeficiente de Eficiência:

$$CE = 1,0 - \frac{\sum_i^N (O_{mi} - O_{pi})^2}{\sum_i^N (O_{mi} - \bar{O}_m)^2} \quad (12)$$

Onde,  $\bar{O}_m$  é a média dos valores de saída observados.

## RESULTADOS E DISCUSSÃO

O critério de seleção das melhores arquiteturas das redes neurais foi o de avaliar o desempenho de generalização da RNA por meio de análises estatísticas entre os dados

calculados e os observados para o período de teste. As RNAs treinadas para o posto Salgadinho foram aplicadas para os postos restantes

Observou-se através da análise estatística que para os dados sem defasagem temporal as RNAs com 5 neurônios na camada intermediária apresentaram uma baixa capacidade de modelar os dados. As RNAs 10, 15 e 20 apresentaram valores de coeficiente de eficiência iguais ou próximos.

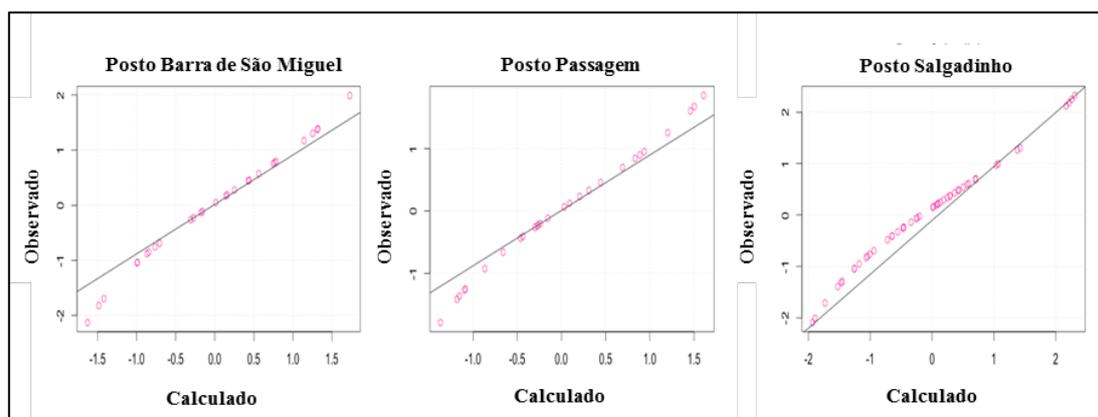
Assim, por meio da análise estatística de eficiência do modelo e considerando a maior simplicidade possível, as RNAs do tipo 10 neurônios na camada intermediária foram escolhidas para representar todos os casos de SPI trabalhados sem defasagem temporal de dados.

A Tabela 3 mostra os resultados estatísticos obtidos através do uso das redes neurais artificiais selecionadas para os três postos pluviométricos do presente estudo.

**Tabela 3.** Resultados estatísticos para as redes neurais artificiais selecionadas sem defasagem de dados.

Índice de Padronizado	Precipitação	Posto Pluviométrico	Erro Quadrático Médio	Coefficiente de Eficiência
Índice de Padronizado - SPI24	Precipitação	Barra de São Miguel	0,14	0,98
		Passagem	0,13	0,98
		Salgadinho	0,15	0,98
Índice de Padronizado - SPI 12	Precipitação	Barra de São Miguel	0,25	0,95
		Passagem	0,31	0,93
		Salgadinho	0,15	0,98
Índice de Padronizado - SPI 6 - Semestre 1	Precipitação	Barra de São Miguel	0,18	0,97
		Passagem	0,16	0,97
		Salgadinho	0,15	0,98
Índice de Padronizado - SPI 6 - Semestre 2	Precipitação	Barra de São Miguel	0,26	0,94
		Passagem	0,23	0,95
		Salgadinho	0,38	0,89

As Figuras 2, 3, 4 e 5 ilustram os resultados do cálculo do SPI sem defasagem obtidos através do uso das redes neurais artificiais selecionadas para os três postos pluviométricos do presente estudo.



**Figura 2.** Resultados obtidos para o SPI 24 sem defasagem de dados.

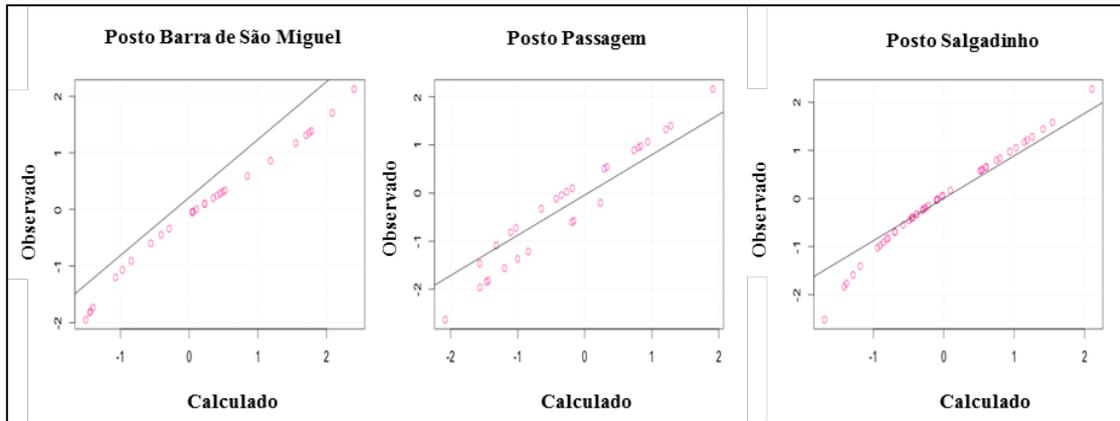


Figura 3. Resultados obtidos para o SPI 12 sem defasagem de dados.

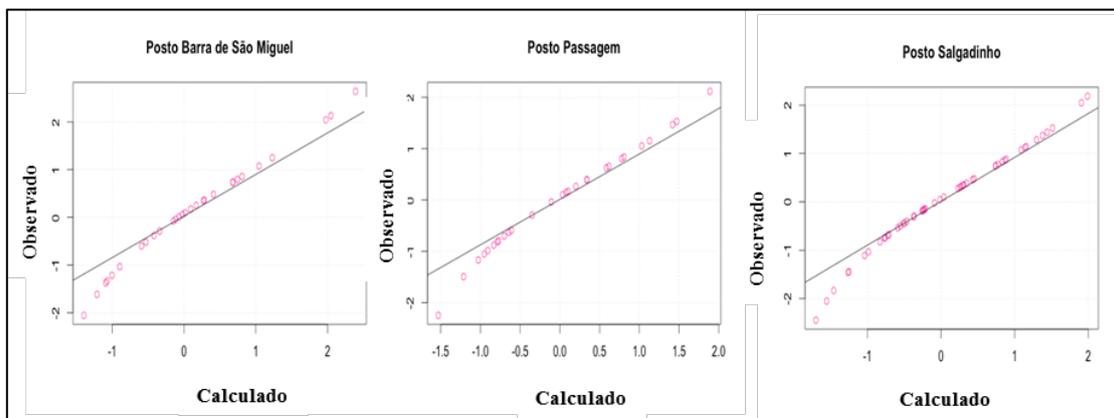


Figura 4. Resultados obtidos para o SPI 6 - Semestre 1 sem defasagem de dados.

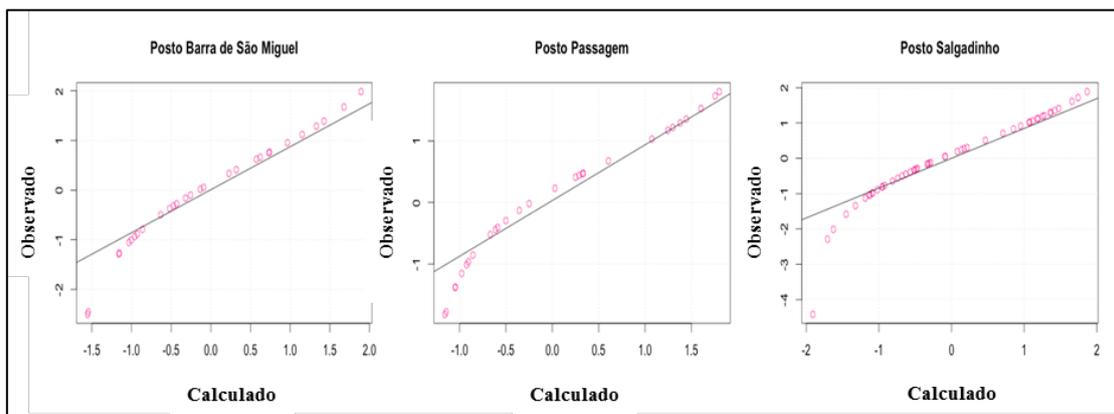


Figura 5. Resultados obtidos para o SPI 6 - Semestre 2 sem defasagem de dados.

Como demonstrado nas figuras acima, o coeficiente de eficiência e o erro quadrático médio apresentaram valores satisfatórios para todos os postos pluviométricos em todas as escalas de tempo adotadas. Dessa forma, as redes neurais se apresentam como uma alternativa eficaz no cálculo do SPI, visto que com o treinamento de um único posto pluviométrico, é possível calcular os valores SPI de outros postos sem a necessidade de seguir os passos metodológicos de adequação a uma probabilidade gama e respectiva normalização. Além disso, o uso da rede neural vence os obstáculos inerentes à variação espaço-temporal que os postos apresentam, já que a rede é treinada para o maior intervalo de precipitação acumulada possível,

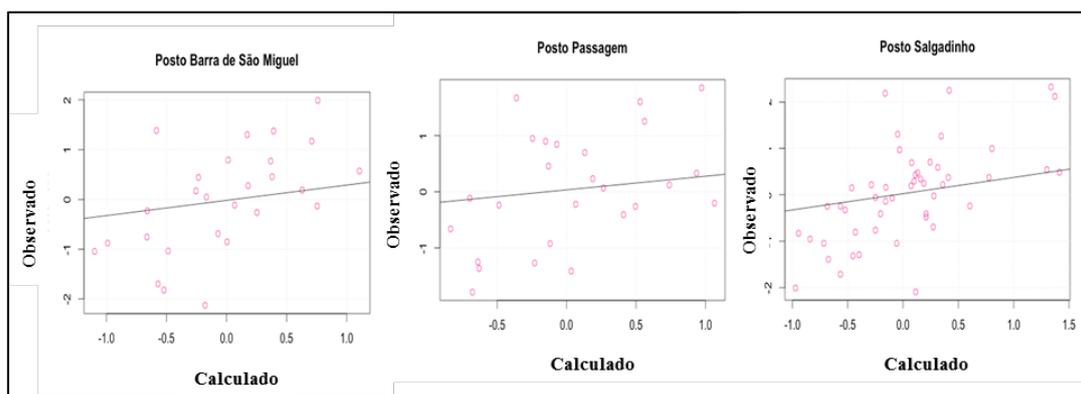
levando em conta a série histórica de dados pluviométricos da região da bacia hidrográfica estudada.

Para os valores encontrados a partir das RNAs treinadas com a defasagem temporal de dados, os resultados estatísticos são apresentados na Tabela 4.

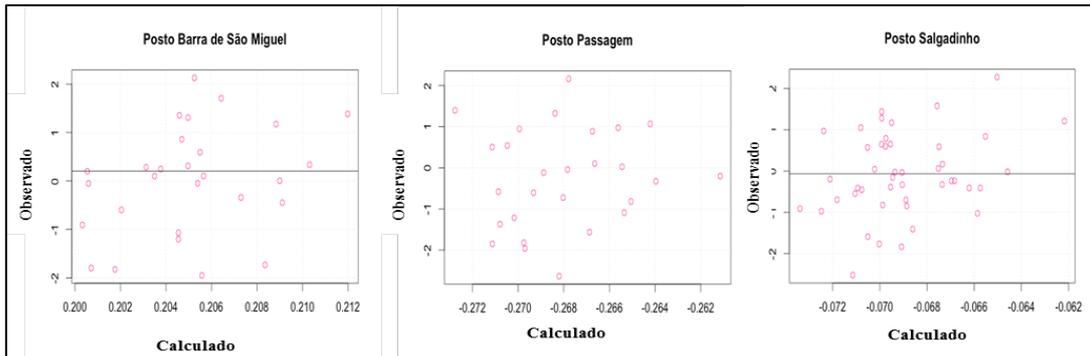
**Tabela 4.** Resultados estatísticos das redes neurais artificiais (RNAs) com defasagem temporal de dados para os índices de precipitação padronizado (SPI).

Escala temporal - SPI	Treinamento e Validação			Teste	
	Número de neurônios na camada intermediária	Erro Quadrático Médio	Coefficiente de Eficiência	Erro Quadrático Médio	Coefficiente de Eficiência
SPI 24	RNA-5	0,97	0	1,24	-0,02
	RNA-10	-0,28	-0,55	1,17	0,09
	RNA-15	-0,18	-0,56	1,17	0,08
	RNA-20	1,24	-0,64	1,17	0,08
SPI 12	RNA-5	0,98	0	1,41	-1,06
	RNA-10	0,98	0	1,41	-1,06
	RNA-15	0,98	0	1,41	-1,06
	RNA-20	0,97	0,02	1,41	-1,05
SPI 6	RNA-5	1,07	0	1,21	-0,16
	RNA-10	1,07	0	1,21	-0,16
	RNA-15	1,08	-0,01	1,21	-0,15
	RNA-20	1,08	-0,01	1,21	-0,15

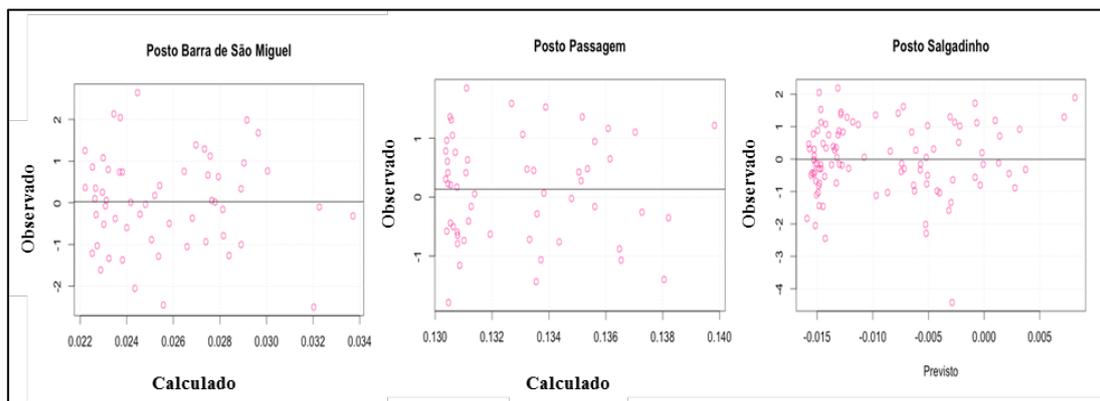
As Figuras 6, 7 e 8 mostram os resultados obtidos através da aplicação das redes neurais artificiais com 10 neurônios com defasagem de dados para os três postos pluviométricos em questão.



**Figura 6.** Resultados obtidos para a previsão do SPI 24 com defasagem de dados.



**Figura 7.** Resultados obtidos para a previsão do SPI 12 com defasagem de dados.



**Figura 8.** Resultados obtidos para a previsão do SPI 6 com defasagem de dados.

Observa-se, através das análises estatísticas e figuras mostradas acima que em todos os casos as RNAs não foram capazes de apresentar uma boa modelagem. Seus baixos coeficientes de eficiência e altos valores de erro quadrático médio indicam que não é possível prever valores de SPI a partir de dados temporais defasados utilizando as arquiteturas e algoritmo apresentados nesse trabalho. Observa-se pouca ou nenhuma diferença nos resultados estatísticos quando da variação de neurônios na camada intermediária.

A grande dispersão entre os valores previstos e observados, e os baixos valores dos coeficientes de eficiência corroboram com o discutido acima: não é possível prever através das redes neurais artificiais adotadas nesse estudo o valor SPI futuro a partir de valores de precipitação acumulada de um período temporal anterior ao mesmo. A grande dispersão entre os valores e a incapacidade de previsão, pode ser observada inclusive no Posto Salgadinho, o mesmo usado para o treinamento das RNAs. Assim, em posse do acumulado de precipitação pluviométrico do primeiro semestre de um ano qualquer, por exemplo, não é possível prever o SPI do próximo semestre. O mesmo ocorre para valores anuais ou bienais. Isso pode ser explicado pelo fato de que não existe correlação natural entre a precipitação acumulada de um período anterior com o seu próximo

## CONCLUSÃO

Com base nos resultados deste trabalho, pode-se concluir que:

- As redes neurais se apresentam como uma alternativa eficaz no cálculo do SPI, visto que com o treinamento de um único posto pluviométrico, é possível calcular os valores SPI de outros postos sem a necessidade de seguir os passos metodológicos de adequação a uma probabilidade gama e respectiva normalização, como descrito por Mckee et al. (1993).
- A construção das RNAs com defasagem temporal de dados mostrou-se incapaz de prever secas. A grande dispersão entre os valores previstos e esperados, associadas aos valores estatísticos que indicam uma baixa previsibilidade do modelo, mostram que a previsão de

secas se torna inadequada com o uso do modelo apresentado. No entanto, vale ressaltar que a imprevisibilidade demonstrada nesse estudo pode ser explicada pelo fato de que não existe correlação natural entre a precipitação acumulada de um período anterior com o seu próximo.

## REFERÊNCIAS

- ANA - Agência Nacional de Águas. **Hidroweb – Sistema de informações hidrológicas**. Disponível em: <<http://hidroweb.ana.gov.br/default.asp>>. Acesso em 10 jan. 2017.
- CRED - Centre for Research on the Epidemiology of Disasters. **The human cost of natural disasters: a global perspective**. Disponível em <[http://emdat.be/human\\_cost\\_natdis](http://emdat.be/human_cost_natdis)>. Acesso em: 04 maio 2017.
- DAYAL, K.; DEO R.; APAN, A.; ARMANDO A. Drought modelling based on artificial intelligence and neural network algorithms: a case study in Queensland, Australia. In: Leal Filho G. (Ed.). **Climate change adaptation in pacific countries**. Springer, 2017. p. 177-198
- FERNANDES, L.G.L.; PORTUGAL, M.S.; NAVAUUX, P.O.A. **Previsão de séries de tempo: redes neurais artificiais e modelos estruturais**. Disponível em: <<http://www.inf.pucrs.br/gmap/files/publications/articles/5afca684be812ed8e2a901173d20e6b6.pdf>> Acesso em: 03 mar. 2017.
- GUEDES, R. V. S. **Previsão de seca na Bacia Hidrográfica do Açude Epitácio Pessoa com base em redes neurais artificiais**. Dissertação de Mestrado - Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, Campina Grande. 2011.
- MCKEE, T.B.; DOESKEN, N.J.; KLEIST, J. The relationship of drought frequency and duration of time scales. Eighth Conference on Applied Climatology, Anaheim CA, 1993. p. 179-186.
- PARTAL, T.; CIGIZOGLU, H.K.; KAHYA, E. Daily precipitation predictions using three different wavelet neural network algorithms by meteorological data. *Stochastic Environmental Research and Risk Assessment Journal*, v. 29, n. 5, p. 1317-1329, 2015.
- PONTES, E.M.; MACHADO, T.A. Desenvolvimento sustentável e convivência com o semi-Árido: o caso do programa de um milhão de cisternas rurais no Nordeste brasileiro. RAS - Rede de Agricultura Sustentável. Disponível em: <<http://www.agrisustentavel.com/doc/p1mc.pdf>>. Acesso em: 07 nov. 2016.
- ROSA, R.G.T.D. **Índices de seca: aplicação ao continente português**. Dissertação de Mestrado. Instituto Superior de Agronomia. Lisboa: ISA, 2011.
- SANTOS, J.F.; PORTELA, M.M. Caracterização de secas em bacias hidrográficas de Portugal Continental: aplicação do índice de precipitação padronizada, SPI, a séries de precipitação e de escoamento. 10º Congresso da Água, Associação Portuguesa dos recursos Hídricos, APRH, Alvor (Portugal). 2010.
- TAYFUR, G. **Soft computing in water resources engineering**. Boston: WIT Press Southampton, 2012.