



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE CIÊNCIAS E TECNOLOGIA AGROALIMENTAR  
UNIDADE ACADÊMICA DE CIÊNCIAS E TECNOLOGIA AMBIENTAL  
CURSO DE ENGENHARIA AMBIENTAL**

**JOSÉ ADALBERTO DA SILVA FILHO**

**MODELAGEM ESTOCÁSTICA DE VAZÕES MENSIS VIA MAPAS DE  
KOHONEN**

**POMBAL-PB**

**2016**

**JOSÉ ADALBERTO DA SILVA FILHO**

**MODELAGEM ESTOCÁSTICA DE VAZÕES MENSAIS VIA MAPAS DE  
KOHONEN**

Trabalho de Conclusão de Curso apresentado ao Centro de Ciências e Tecnologia Agroalimentar, da Universidade Federal de Campina Grande, como parte dos requisitos para obtenção do título de Bacharel em Engenharia Ambiental.

Orientador: Prof. Dr. CAMILO ALLYSON SIMÕES DE FARIAS

**POMBAL-PB**

**2016**

**JOSÉ ADALBERTO DA SILVA FILHO**

**MODELAGEM ESTOCÁSTICA DE VAZÕES MENSAS VIA MAPAS DE  
KOHONEN**

Trabalho de Conclusão de Curso apresentado ao Centro de Ciências e Tecnologia Agroalimentar, da Universidade Federal de Campina Grande, como parte dos requisitos para obtenção do título de Bacharel em Engenharia Ambiental.

Orientador: Prof. Dr. CAMILO ALLYSON SIMÕES DE FARIAS

Aprovado em 13 de maio de 2016:

**BANCA EXAMINADORA**

---

Prof. Dr. Camilo Allyson Simões de Farias  
(CCTA/UFCG - Orientador)

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Virgínia de Fátima Bezerra Nogueira  
(CCTA/UFCG - Examinadora Interna)

---

Prof.<sup>a</sup> M.Sc. Cristiane Queiroz Reis  
(CCJS/UFCG - Examinadora Externa)

**POMBAL-PB  
2016**

*Dedico este trabalho aos meus queridos pais,  
José Adalberto da Silva e Maria Izabel  
Bernardino da Silva, por todo amor e por  
possibilitarem minha formação.*

## **AGRADECIMENTOS**

Primeiramente a Deus, por me confortar nos momentos mais difíceis da minha caminhada, me dar força interior para vencer todos os obstáculos decorrentes de minhas escolhas, mostrar o caminho nas horas incertas e me suprir de todas as necessidades.

Aos meus pais, José Adalberto da Silva e Maria Izabel Bernardino da Silva, berço de todas as minhas qualidades, pelo amor, carinho, confiança, incentivo, orações e zelo. E aos demais membros da minha família pelo apoio ao longo da minha graduação.

À Sayonara Costa de Araújo, mulher a qual tenho enorme admiração e que tem cativado minha amizade ao longo dos cinco árduos anos de graduação, por todas as horas de estudo, apoio em momentos difíceis, ânimo, companheirismo, afeto em todos os momentos, confiança e, sobretudo, por ter sido uma peça fundamental para o meu desenvolvimento acadêmico e pessoal.

Ao meu orientador, Camilo Allyson Simões de Farias, pela dedicação, disponibilidade, ensinamentos, paciência e orientação ao longo de toda pesquisa.

A todos os professores da Unidade Acadêmica de Ciências e Tecnologia Ambiental, em especial a Andréa Maria Brandão Mendes de Oliveira, Érica Cristine Medeiros Nobre Machado, José Cleidimário Araújo Leite e Virgínia de Fátima Bezerra Nogueira.

À Yasmim Dias, Kassioppeya Felix, Louise Medeiros, Jéssica Andrade, Carlos Eduardo, Wanessa Alves, Laíza Gomes, Kaio Vinícius, Aretha Cabral, Jéfitha Kalyne, Alisson Meneses, Rodrigo Queiroga, Lucas Nunes, Andreza Maiara e aos demais amigos que estiveram comigo e me apoiaram durante a graduação.

Aos meus colegas de curso pelo incentivo durante os cinco anos de convívio.

Aos técnicos e funcionários do Centro de Ciências e Tecnologia Agroalimentar, em especial a Gerusia Trigueiro e Luiz Fernando.

Ao CNPq pelo financiamento do projeto intitulado “Modelagem estocástica de vazões mensais via mapas auto-organizáveis”, que foi fundamental para o desenvolvimento desta pesquisa.

A todos que direta ou indiretamente contribuíram para esse momento.

## LISTA DE FIGURAS

<b>Figura 1</b> - Distâncias entre neurônios de um modelo SOM para determinação da vizinhança .....	19
<b>Figura 2</b> - Localização dos postos na bacia hidrográfica do rio Piancó .....	21
<b>Figura 3</b> - Fluxograma do método dos fragmentos.....	23
<b>Figura 4</b> - Exemplo de uma arquitetura SOM .....	25
<b>Figura 5</b> - Distribuição dos dados de calibração do modelo SOM #6 no posto fluviométrico Piancó .....	29
<b>Figura 6</b> - Distribuição dos dados de calibração do modelo SOM #9 no posto fluviométrico Emas .....	30
<b>Figura 7</b> - Comparação das propriedades estatísticas entre vazões sintéticas (modelos SOM #6 e MF) e históricas no posto fluviométrico Piancó .....	35
<b>Figura 8</b> - Comparação das propriedades estatísticas entre vazões sintéticas (modelos SOM #9 e MF) e históricas no posto fluviométrico Emas .....	36
<b>Figura 9</b> - Comparação de cenários sintéticos (modelo SOM #6) com valores observados no período de 1999 – 2000 no posto fluviométrico Piancó .....	37
<b>Figura 10</b> - Comparação de cenários sintéticos (modelo SOM #9) com valores observados no período de 1964 - 1965 no posto fluviométrico Emas.....	37
<b>Figura 11</b> - Mapas de componentes derivados da calibração do modelo SOM #6 para o posto fluviométrico Piancó .....	38
<b>Figura 12</b> - Mapas de componentes derivados da calibração do modelo SOM #9 para o posto fluviométrico Emas .....	39

## LISTA DE TABELAS

<b>Tabela 1</b> - Comparação das estatísticas dos modelos SOM e do MF com aquelas dos dados históricos para o posto fluviométrico Piancó.....	31
<b>Tabela 2</b> - Comparação das estatísticas dos modelos SOM e do MF com aquelas dos dados históricos para o posto fluviométrico Emas.....	32

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	11
<b>2</b>	<b>OBJETIVOS</b> .....	13
<b>2.1</b>	<b>GERAL</b> .....	13
<b>2.2</b>	<b>ESPECÍFICOS</b> .....	13
<b>3</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	14
<b>3.1</b>	<b>MODELAGEM ESTOCÁSTICA DE SÉRIES DE ESCOAMENTO</b> .....	14
<b>3.2</b>	<b>REDES NEURAS ARTIFICIAIS</b> .....	15
<b>3.3</b>	<b>MAPAS AUTO-ORGANIZÁVEIS</b> .....	17
<b>4</b>	<b>MATERIAL E MÉTODOS</b> .....	20
<b>4.1</b>	<b>ÁREA DE ESTUDO</b> .....	20
<b>4.2</b>	<b>MODELAGEM VIA MÉTODO DOS FRAGMENTOS</b> .....	21
<b>4.3</b>	<b>MODELAGEM VIA MAPAS AUTO-ORGANIZÁVEIS</b> .....	23
<b>4.4</b>	<b>AVALIAÇÃO DE DESEMPENHO DOS MODELOS</b> .....	26
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	28
<b>6</b>	<b>CONCLUSÃO</b> .....	40
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	41
	<b>APÊNDICE A – SÉRIE FLUVIOMÉTRICA DO POSTO PIANCÓ</b> .....	47
	<b>APÊNDICE B – SÉRIE FLUVIOMÉTRICA DO POSTO EMAS</b> .....	48

## RESUMO

As condições hidrológicas extremas e as crescentes demandas hídricas observadas no semiárido brasileiro têm gerado conflitos quanto ao melhor uso dos recursos hídricos existentes. Modelos de geração sintética de vazões são frequentemente utilizados como suporte na definição de regras de operação de sistemas hídricos, o que permite o estabelecimento de normas de racionamento antes que os usuários se deparem com a efetiva escassez de água. Neste trabalho verificou-se a aplicabilidade de modelos baseados em mapas auto-organizáveis (do inglês, *Self Organizing Maps* - SOM) para modelagem estocástica de vazões. O princípio básico do estudo consistiu em usar modelos SOM para determinar a componente determinística da série de vazões e uma função de densidade de probabilidade (componente estocástica) para modelar a série residual resultante. Os resultados mostraram-se promissores, indicando que os modelos testados são capazes de produzir séries sintéticas de afluências com excelente desempenho.

**Palavras-chave:** Método dos fragmentos, recursos hídricos, redes neurais artificiais.

## **ABSTRACT**

The extreme hydrological conditions and increasing water demands observed in Brazil semiarid have generated conflicts regarding the best use of existing water resources. Synthetic generation models of river flows are often used as support for the definition of water system operating rules, which allow the establishment of rationing rules before water scarcity spells. This work aims at verifying the applicability of models based on self-organizing maps (SOM) for stochastic modeling of monthly river flows. The basic principle of the study consisted of using SOM models in order to determine the deterministic component of river flow series and a density probability function (stochastic component) to represent the resulting residuals. The results were promising, indicating that the tested models are capable of producing synthetic series of inflows with excellent performance.

**Keywords:** Method of fragments, water resources, artificial neural networks.

# 1 INTRODUÇÃO

O desenvolvimento social e econômico de uma região está diretamente ligado à disponibilidade de água. Este fator, juntamente com o crescimento das demandas, tem propiciado o surgimento de conflitos entre os vários usuários e setores de recursos hídricos (CARNEIRO e FARIAS, 2013). Desta forma, o adequado gerenciamento dos sistemas de abastecimento de água, além de promover a sustentabilidade, tende a reduzir a problemática da crise hídrica e auxiliar no manejo de obras ligadas a este recurso.

Desde o planejamento até a finalização de projetos em engenharia, torna-se necessário seguir um conjunto de exigências técnicas e operacionais, que levam em consideração o prazo, o custo, a segurança, o escopo e outras variáveis que influenciam na qualidade do projeto (BERSSANETI, 2011).

No que diz respeito à segurança, por exemplo, a disponibilidade de dados de vazões com elevada amplitude permite um melhor dimensionamento de obras ligadas a construções de barragens, pontes, diques ou qualquer sistema hidráulico. Diante desta exigência, muitas localidades não apresentam medições longas e regulares de afluências, o que pode comprometer o projeto e aumentar os riscos de falhas.

A utilização de processos de modelagem que visem estender as séries de afluências com excelente performance, ou seja, o desenvolvimento de modelos que sejam capazes de produzir novos dados de vazão, mantendo as propriedades estatísticas observadas na série histórica, constitui um importante mecanismo para a engenharia. Associado a esta exigência, a disponibilidade de dados de vazão permite um melhor planejamento do recurso em questão, uma vez que os corpos hídricos admitem multiplicidade em seus usos.

Mediante a esse contexto, as técnicas de otimização estocástica são ferramentas importantes na definição de regras operacionais de sistemas de recursos hídricos, uma vez que tentam incorporar as incertezas hidrológicas da região e, com isso, minimizar os impactos advindos da falta de água (LOUCKS et al., 1981).

Os métodos estocásticos, comparados aos determinísticos e empíricos, ganham destaque nesse cenário, uma vez que possibilitam um acréscimo

considerável de informações necessárias à modelagem. Essas abordagens admitem que os deflúvios seguem leis probabilísticas de formação, gerando séries sintéticas de vazões baseadas em parâmetros estatísticos como média, desvio padrão, assimetria, correlação etc. (FARIAS, 2003). Estes modelos de geração sintética de vazões são frequentemente utilizados como suporte na definição de regras de operação, permitindo o estabelecimento de normas de racionamento antes que os usuários se deparem com a efetiva escassez de água.

Nas últimas décadas, o aparecimento das técnicas de inteligência artificial, a exemplo das redes neurais artificiais (RNA), algoritmos genéticos e a lógica difusa, favoreceram o desenvolvimento de modelos cada vez mais promissores (EMCH e YEH, 1998; PULIDO-VELÁZQUEZ, ANDREU e SAHUQUILLO, 2006; FARIAS, 2009; CHANG et al., 2010; FARIAS et al., 2011; CELESTE e BILLIB, 2012; KUMAR et al., 2013).

Os mapas de Kohonen ou mapas auto-organizáveis, do inglês *Self Organizing Maps* (SOM), são redes neurais artificiais não supervisionadas que agrupam dados de entrada em classes de acordo com suas semelhanças, por meio de métodos de treinamento competitivo (KOHONEN, 1982; HAYKIN, 1999; SILVA, SPATTI e FLAUZINO, 2010). A estrutura simples, assim como a sua dinâmica de treinamento diferenciada, faz dos mapas auto-organizáveis uma boa ferramenta para o estudo em questão.

As redes SOM foram propostas por Kohonen (1982) e têm sido predominantemente aplicadas no agrupamento de dados e classificação de padrões. Além da capacidade de modelar relações não lineares, as redes SOM são capazes de reduzir um conjunto de dados multidimensionais a uma matriz bidimensional, que pode ser utilizada para fins de análise e de previsão.

Logo, nesta pesquisa, buscou-se verificar a aplicabilidade de mapas auto-organizáveis para a modelagem estocástica de vazões mensais. Para isso, foram utilizadas duas séries históricas de postos fluviométricos localizados no semiárido paraibano.

## **2 OBJETIVOS**

### **2.1 GERAL**

Desenvolver modelos baseados em mapas auto-organizáveis para geração estocástica de vazões mensais.

### **2.2 ESPECÍFICOS**

- Formular modelos híbridos para geração sintética de vazões baseados no método dos fragmentos (MF) e em redes SOM;
- Calibrar e validar os modelos propostos considerando dois estudos de caso;
- Comparar os resultados obtidos com aqueles gerados pela aplicação do MF tradicional.

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 MODELAGEM ESTOCÁSTICA DE SÉRIES DE ESCOAMENTO

A modelagem estocástica de séries de escoamentos é uma alternativa bastante atrativa para a extensão de registros históricos (RICHARDSON, 1981; CARNEIRO e FARIAS, 2013). A geração destas séries é normalmente conduzida por meio de modelos capazes de produzir dados cujas propriedades estatísticas sejam similares às dos dados observados (FARIAS et al., 2011).

De forma geral, os processos necessários para a modelagem de aflúências baseiam-se em modelos determinísticos chuva-vazão e em modelos estocásticos. Os primeiros procuram representar os processos físicos responsáveis por transformar chuva em vazão, enquanto os modelos estocásticos baseiam-se na análise da estrutura de dependência temporal das séries de vazões (LUCAS et al., 2009).

Os modelos de geração sintética de vazões são basicamente compostos por duas componentes: uma determinística e outra estocástica. Em geral, a componente determinística pode ser obtida por meio de um modelo de previsão e a estocástica via modelagem estatística da série de resíduos resultantes (SALAS, 1993).

Além das várias opções de modelos tradicionais de séries temporais encontrados na literatura, a exemplo dos mostrados nos trabalhos de Salas (1993) e Hamilton (1994), o método dos fragmentos tem sido vastamente utilizado para simulação estocástica de escoamentos. Este método consiste basicamente em desagregar vazões anuais, normalmente geradas por meio de um modelo estatístico, em vazões mensais, segundo uma forma padronizada (SVANIDZE, 1980; ARAÚJO e CAMPOS, 1991; CELESTE, CURI e CURI, 2007).

Modelos baseados em inteligência artificial para a componente determinística dos modelos de geração sintética também têm sido relatados na literatura, como, por exemplo, o trabalho de Farias et al. (2007), que utilizou um modelo de redes neurais artificiais para determinação de vazão mensal do rio Ishitegawa, Japão, com base nos dois valores anteriores de vazões.

### 3.2 REDES NEURAIS ARTIFICIAIS

Segundo Machado (2005), as redes neurais artificiais (RNA) têm como inspiração o sistema neural biológico. Elas são constituídas por vários elementos de processamento (neurônios) conectados entre si, em que cada unidade recebe e envia informações com performance semelhante a uma célula neural biológica. As RNA conseguem aprender, executar operações não lógicas, realizar transformações e comparações, descobrir relações ou regras e testar situações em paralelo mediante a um problema específico (TAFNER, XEREZ e RODRIGUES FILHO, 1996).

De acordo com Braga, Carvalho e Ludermir (2000), as RNA são modelos matemáticos que têm capacidade computacional adquirida por meio de aprendizado e generalização. O aprendizado desse sistema é um processo pelo qual seus parâmetros livres são adaptados pelo mecanismo de estimulação no ambiente onde a rede está implantada (HAYKIN, 2001).

A etapa de aprendizado pode ser entendida como uma forma de adaptação da rede às características intrínsecas de um problema, em que se busca cobrir uma grande quantidade de valores associados às variáveis pertinentes. Isso é feito para que a RNA adquira, através de uma melhora gradativa, uma boa aptidão de resposta para o maior número de situações possíveis. Por sua vez, a generalização de uma RNA está associada à sua capacidade de dar respostas coerentes para dados não apresentados a ela durante o treinamento. Espera-se que uma RNA treinada tenha uma boa competência para generalização, independentemente de ter sido utilizado o aprendizado supervisionado ou não supervisionado (SOARES e SILVA, 2011).

Silva, Spatti e Flauzino (2010) definem as RNA como sendo modelos computacionais que apresentam um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são unidos através de um grande número de interconexões (sinapses artificiais), sendo as mesmas representadas por vetores ou matrizes de pesos sinápticos.

A arquitetura de uma rede neural artificial define o arranjo de seus neurônios, que são essencialmente estruturados através do direcionamento das conexões sinápticas dos mesmos. Essa estrutura é constituída de três partes: camada de entrada, camada oculta e camada de saída, sendo responsáveis, respectivamente,

pela captação dos dados de entrada, pelo processamento destes dados e pela apresentação dos resultados da rede (MACHADO, 2005; DINIZ, 2008; SILVA, SPATTI e FLAUZINO, 2010; MUNICCI, 2014).

De acordo com Silva, Spatti e Flauzino (2010), a topologia de uma rede neural, considerando determinada arquitetura, pode ser definida como sendo as várias formas de composições estruturais que esta poderá assumir. Por exemplo, pode-se ter duas topologias pertencentes a uma mesma arquitetura, sendo que uma é composta de 10 neurônios e a outra é de 20 neurônios; ou ainda, uma constituída de neurônios com função de ativação logística, ao passo que os neurônios da outra assumem a tangente hiperbólica como função de ativação.

Já o treinamento de uma arquitetura específica consiste na aplicação de um conjunto de procedimentos ordenados com a finalidade de ajustar os pesos e os limiares de seus neurônios. Dessa forma, tal processo de ajuste, também conhecido como algoritmo de aprendizagem, visa sintonizar a rede para que as suas respostas estejam próximas dos valores desejados (SILVA, SPATTI e FLAUZINO, 2010).

Favoreto, Rohn e Mine (2001) mencionam que uma das áreas promissoras de grande aplicabilidade das RNA é a previsão de séries hidrológicas. Várias pesquisas têm sido realizadas na modelagem desses processos (FLOOD e KARTAM, 1994; ELSHORBAGY, SIMONOVIC e PANU, 2000; RAMOS e GALVÃO, 2001; SOUSA e SOUSA, 2006; SOUSA e SOUSA, 2010; LOURENÇO, 2012; BRASILIANO, 2014; SOUSA, 2015), em que se obtiveram excelentes desempenhos, inclusive melhores que os obtidos com outros modelos mais simples.

Sousa e Sousa (2010) realizaram um estudo no semiárido paraibano com o objetivo de propor um modelo baseado em técnicas de RNA do tipo *Multi-Layer Perceptron*, que servisse para simular e prever vazões médias mensais em uma estação fluviométrica localizada na cidade de Piancó. Os resultados obtidos através da arquitetura, divididos em treinamento, validação e teste, indicam que o modelo proposto foi capaz de prever as aflúências com ótima performance.

### 3.3 MAPAS AUTO-ORGANIZÁVEIS

Os mapas auto-organizáveis de Kohonen são caracterizados por apresentarem estrutura reticulada, aprendizado não supervisionado (sem saída desejada) e um sistema competitivo. O processo de aprendizado competitivo se baseia na concorrência entre os neurônios, no qual um é escolhido como vitorioso. Seu prêmio será o ajuste dos pesos, proporcionalmente aos valores do padrão de entrada apresentado, visando assim aperfeiçoar o sistema para os próximos padrões a serem apresentados (SILVA, SPATTI e FLAUZINO, 2010).

O principal objetivo dos mapas auto-organizáveis consiste no agrupamento de vetores com características semelhantes em uma mesma classe (neurônio vencedor) ou em classes semelhantes (neurônios vizinhos) (FARIAS, CARNEIRO e LOURENÇO, 2012).

De acordo com Farias, Silva Filho e Bezerra (2014), as arquiteturas das redes neurais SOM contêm uma camada de entrada multidimensional e uma camada de saída que normalmente é unidimensional ou bidimensional. Na camada de saída, também conhecida como camada competitiva, os neurônios concorrem entre si e apenas um deles é considerado o vencedor ou, de forma simplificada, a classe mais adequada para um determinado vetor de entrada  $\mathbf{x}$ . Nessas redes, cada elemento do vetor de entrada está conectado a todos os elementos da camada de saída. A força das conexões é medida por meio de pesos  $w_{ij}$  entre os neurônios de entrada  $j$  e os neurônios da camada de saída  $i$  (BEALE, HAGAN e DEMUTH, 2012).

Durante o treinamento do modelo SOM, são calculadas as distâncias Euclidianas  $D_i$  entre o vetor de entrada e os pesos ligados a cada um dos neurônios de saída, conforme mostra a Equação (1):

$$D_i = \sqrt{\sum_{j=1}^J (x_j - w_{ij})^2}; \text{ para } i = 1, 2, \dots, M. \quad (1)$$

em que  $x_j$  é o  $j$ -ésimo componente do vetor de entrada  $\mathbf{x}$ ;  $J$  é a dimensão do vetor de entrada  $\mathbf{x}$ ; e  $M$  é o número total de neurônios na camada de saída.

O neurônio de saída  $i$  que possuir a menor distância Euclidiana ao vetor de entrada é considerado o neurônio vencedor. Os pesos conectados a este neurônio  $i^*$  e aos neurônios dentro de um certo raio de vizinhança  $V_i^*$  são então atualizados pela regra de Kohonen (BEALE, HAGAN e DEMUTH, 2012), conforme apresenta a Equação (2):

$$w_{ij}(n) = w_{ij}(n - 1) + \alpha \cdot [x_j(n) - w_{ij}(n - 1)]; \text{ para } i \in V_i \text{ e } j = 1, 2, \dots, J \quad (2)$$

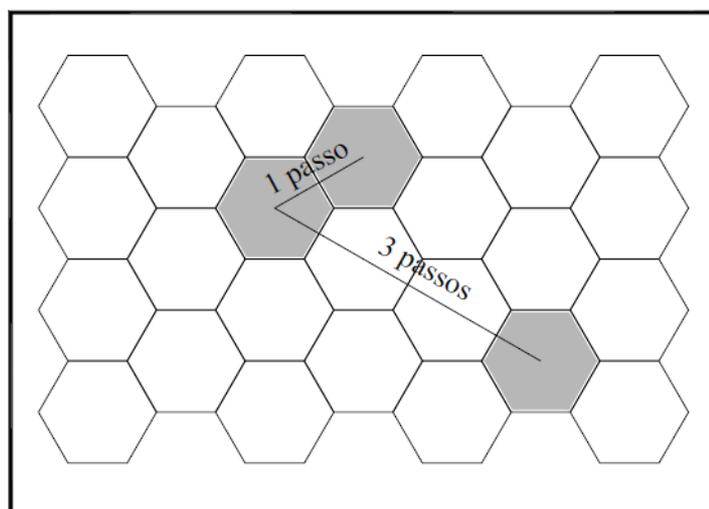
em que  $\alpha$  é a taxa de aprendizagem e  $n$  é um índice que representa a sequência de apresentação das amostras a rede.

A regra de Kohonen força os pesos ligados ao neurônio vencedor e seus vizinhos a se deslocarem na direção do vetor de entrada apresentado à rede, fazendo com que a distância Euclidiana se torne cada vez menor e com que estes neurônios aprendam a classificar vetores similares.

A apresentação dos vetores de entrada a rede também pode ser feita utilizando-se todo o conjunto de dados antes de qualquer atualização de pesos. Esta forma de apresentação é conhecida como modo de lote. Neste caso, a busca pelo neurônio vencedor é efetuada para cada vetor de entrada, e então o vetor peso é movido para uma posição específica calculada pela média dos vetores de entrada para qual o neurônio foi o vencedor ou vizinho do vencedor (BEALE, HAGAN e DEMUTH, 2012; FARIAS et al., 2013; FARIAS e SANTOS, 2014). Os pesos tendem a se estabilizar após várias apresentações do conjunto de dados de entrada. É importante ressaltar que o treinamento desta rede neural é do tipo não supervisionado, pois não existem saídas desejadas.

Para fins de determinação da vizinhança, as distâncias entre os neurônios da camada de saída podem ser definidas de várias maneiras (BEALE, HAGAN e DEMUTH, 2012). Comumente, em uma camada de saída bidimensional, esses neurônios são imaginados como formas retangulares ou hexagonais e as distâncias são estabelecidas pelo número de passos entre eles. A Figura 1 mostra como as distâncias entre neurônios hexagonais são obtidas para fins de determinação da vizinhança.

**Figura 1** - Distâncias entre neurônios de um modelo SOM para determinação da vizinhança.



Fonte: Adaptado de Farias e Santos (2014).

O treinamento de uma rede SOM normalmente ocorre em duas fases: fase de ordenação e fase de ajustes. Na primeira fase, o treinamento é limitado por um determinado número de apresentações do conjunto de dados e o raio da vizinhança é iniciado com uma dada distância que decresce até o valor unitário. Esta medida permite que os pesos dos neurônios se organizem no espaço de entrada de forma consistente com as suas posições. A fase de ajustes dura o restante do número de apresentações definido para o treinamento. Nesta fase, o raio da vizinhança fica abaixo da unidade, fazendo com que haja atualização somente no peso do neurônio vencedor. Durante a fase de ajustes, espera-se que os pesos se modifiquem de forma relativamente uniforme no espaço de entrada, mantendo a topologia definida na fase de ordenação (BEALE, HAGAN e DEMUTH, 2012).

## 4 MATERIAL E MÉTODOS

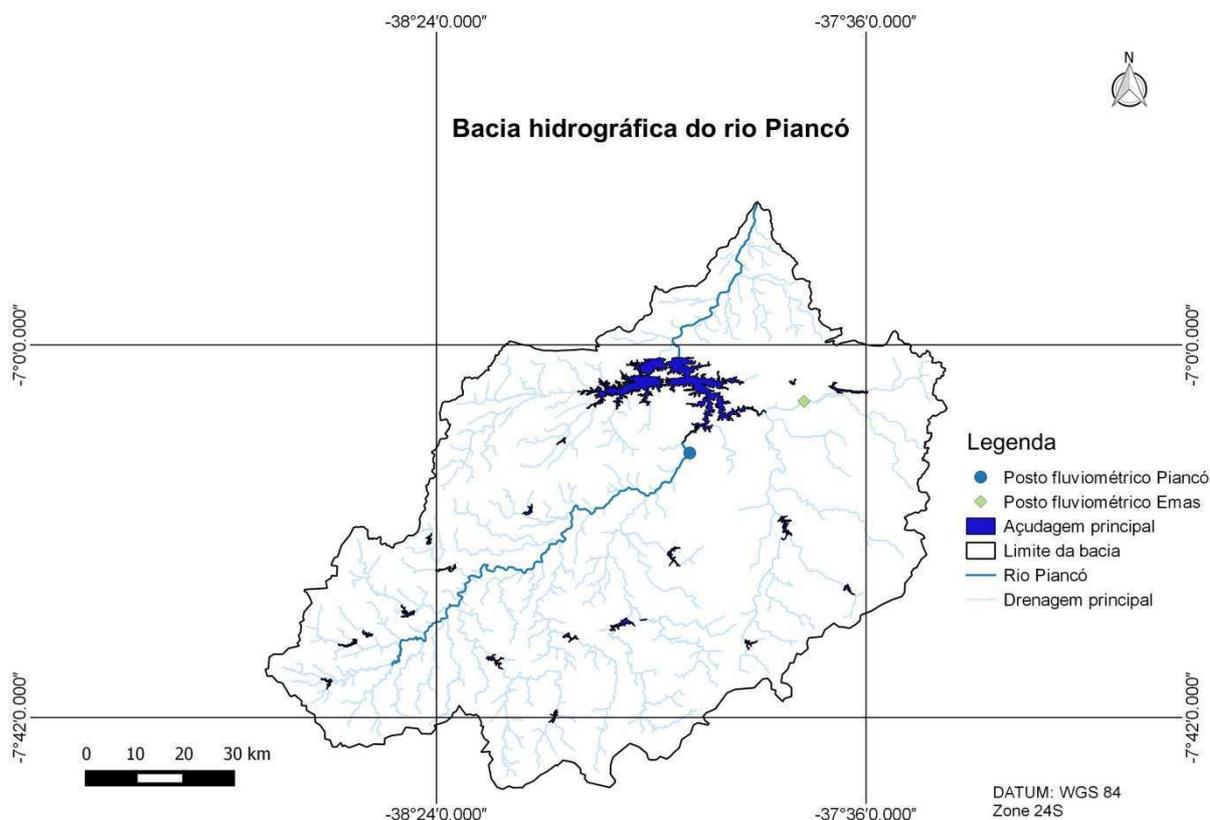
### 4.1 ÁREA DE ESTUDO

As duas séries de dados foram provenientes da Agência Nacional de Águas (ANA, 2016), referentes às estações fluviométricas Piancó e Emas, ambas localizadas na bacia hidrográfica do rio Piancó, que compõe juntamente com outras sub-bacias, a Bacia do rio Piranhas - Açu. Ela está localizada no extremo sudoeste do estado da Paraíba, Brasil. Limita-se com as bacias hidrográficas do Alto e Médio Piranhas ao norte, com o estado de Pernambuco ao sul, com a bacia hidrográfica do rio Espinharas a leste e com o estado do Ceará a oeste. A bacia possui uma área de 9.228 km<sup>2</sup> e um perímetro de 540 km. O comprimento do rio Piancó, principal curso d'água, tem um total de 208 km, considerando a sua nascente na Serra do Umbuzeiro, município de Santa Inês - PB, até o exutório da bacia no município de Pombal - PB (RODRIGUES et al., 2007).

Em relação à geologia, a bacia é essencialmente formada de rochas do complexo cristalino. Com respeito ao relevo, observa-se que apenas 5% da área da bacia encontra-se em altitudes bastante elevadas, o restante corresponde a altitudes que variam de 260 a 790 m, caracterizando um relevo de moderado a forte. Apresenta uma altitude mediana igual a 461 m e uma altitude média igual a 485 m. A vegetação natural é do tipo xerófita, pertencente ao bioma *caatinga* (LIMA, 2004).

A precipitação média anual é de 821 mm. Nos meses de fevereiro, março e abril, a precipitação representa cerca de 60% deste valor, apresentando um coeficiente de variação anual em torno de 40%. A temperatura média anual é superior a 24°C e a amplitude térmica anual menor do que 4°C. As temperaturas mais altas ocorrem nos meses mais secos, ou seja, de outubro a janeiro. As mais baixas, entre abril e julho. A evaporação potencial anual é de 2993,4 mm, com as maiores taxas entre setembro e dezembro (SCIENTEC, 1997; LIMA, 2004). Os postos fluviométricos adotados e informações referentes à bacia hidrográfica em estudo podem ser visualizados na Figura 2.

**Figura 2** – Localização dos postos fluviométricos na bacia hidrográfica do rio Piancó.



Fonte: Autoria própria.

Para a calibração dos modelos no posto fluviométrico Piancó foram utilizadas vazões mensais entre 1965 e 2012. Os anos 1969, 1974, 1975, 1983, 1985, 1988, 1989, 1990, 1991, 1992, 1995, 1998, 2002, 2005, 2008 e 2009 foram excluídos por apresentarem algum tipo de falha, resultando em uma amostra com 32 anos de dados (Apêndice A).

Já para o posto fluviométrico Emas foram utilizados dados entre 1964 e 2012. Os anos 1966, 1973, 1974, 1975, 1976, 1977, 1978, 1979, 1980, 1981, 1982, 1983, 1984, 1993, 2002, 2003, 2004 e 2008 foram excluídos pelo mesmo motivo descrito anteriormente, o que resultou em uma série de 31 anos de dados (Apêndice B).

#### 4.2 MODELAGEM VIA MÉTODO DOS FRAGMENTOS

O método dos fragmentos (MF) foi inicialmente proposto por Svanidze (1980) e vem sendo muito utilizado na literatura para geração sintética de aflúências

(CELESTE, CURI e CURI, 2007; CARNEIRO e FARIAS, 2013; SILVA FILHO et al., 2015). O MF se caracteriza por ser um modelo de desagregação de vazões anuais em vazões mensais. Desta forma, a primeira etapa é calcular os fragmentos dividindo-se as vazões de cada mês pela soma de todas as vazões mensais do respectivo ano, como exemplificado na Equação (3):

$$f(a, m) = \frac{Q(a, m)}{\sum_{j=1}^{12} Q(a, m)} \quad (3)$$

em que  $f(a, m)$  e  $Q(a, m)$  são, respectivamente, o fragmento correspondente e a vazão observada do mês  $m$  do ano  $a$ .

Segundo Carneiro e Farias (2013), a próxima etapa consiste em avaliar as vazões anuais históricas quanto à dependência linear. Caso sejam serialmente dependentes, utiliza-se modelos estatísticos para produzir uma série de resíduos independente. Após esta etapa, os resíduos da série de vazões anuais históricas são modelados a uma função de densidade de probabilidade (FDP) adequada.

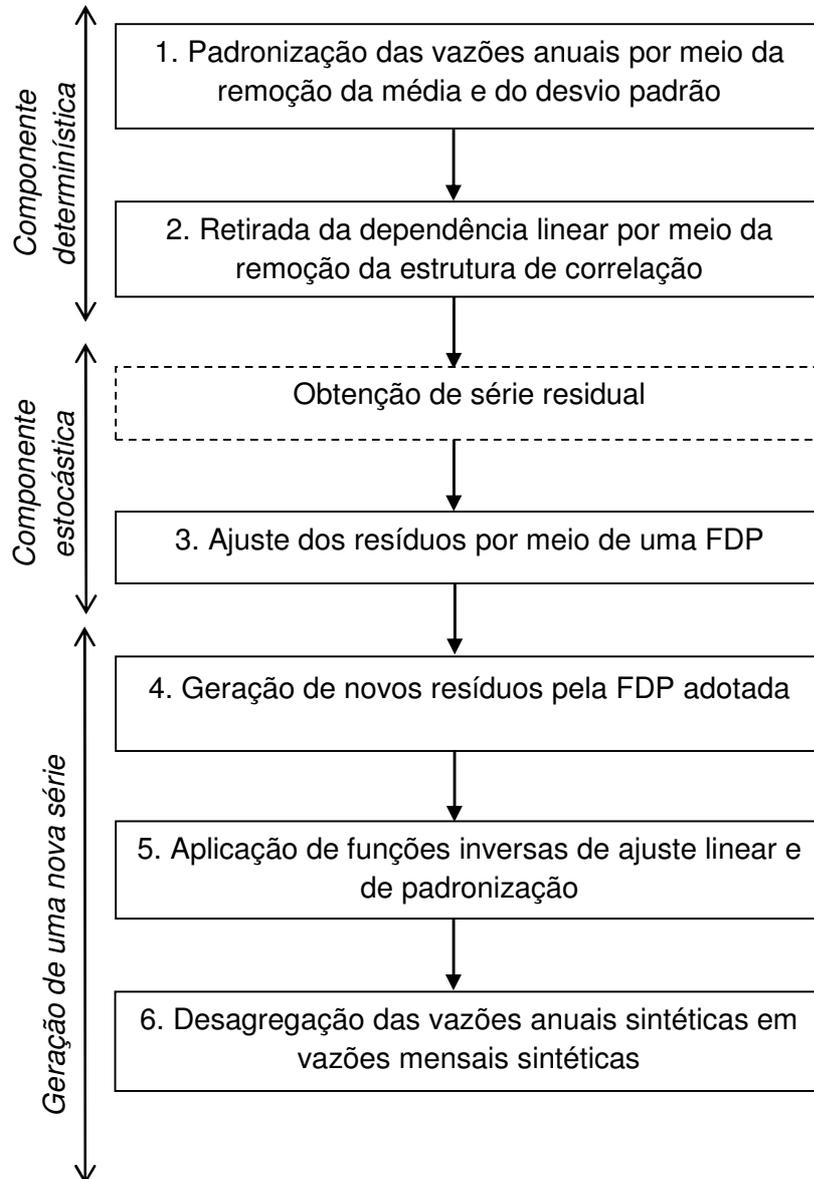
A nova geração estocástica de vazões anuais se procede através da simulação aleatória de números pela FDP modelada e pela posterior aplicação da função inversa do modelo estatístico responsável pela retirada das dependências lineares (CARNEIRO e FARIAS, 2013).

Em seguida, as vazões anuais geradas são desagregadas seguindo os seguintes procedimentos apresentados em Celeste, Curi e Curi (2007); Carneiro e Farias (2013); e Brasiliano (2014):

- (a) as vazões anuais dos dados históricos são dispostas em ordem crescente para o estabelecimento de classes;
- (b) a primeira classe tem limite inferior igual a zero e a última classe não tem limite superior, ou seja, tem limite igual a infinito;
- (c) as classes intermediárias, neste caso, são definidas pelas médias de duas vazões sucessivas;
- (d) após a definição destes limites, cada vazão anual sintética gerada pertencerá a uma classe correspondente e as vazões mensais são obtidas por meio do produto dos fragmentos daquela classe pelo valor anual sintético.

O fluxograma do processo pode ser observado na Figura 3.

**Figura 3** - Fluxograma do método dos fragmentos.



Fonte: Autoria própria.

### 4.3 MODELAGEM VIA MAPAS AUTO-ORGANIZÁVEIS

A modelagem por meio de mapas auto-organizáveis consiste em representar vetores de entrada de um espaço multidimensional em espaços unidimensionais ou bidimensionais, mantendo-se a relação de vizinhança dos dados (SILVA, SPATTI e

FLAUZINO, 2010).

Nessa pesquisa, os vetores da camada de entrada possuem treze componentes, sendo eles os doze fragmentos oriundos de cada mês do ano, obtidos pela Equação (3) e a vazão anual ( $m^3/s$ ). Na camada de saída foram utilizados neurônios hexagonais, cujos pesos também possuem treze componentes, referentes à dimensão dos vetores de entrada. As arquiteturas a serem testadas foram formuladas com base no número de neurônios ( $M$ ), conforme proposto em García e González (2004), através da heurística mostrada na Equação (4):

$$M = 5\sqrt{N} \quad (4)$$

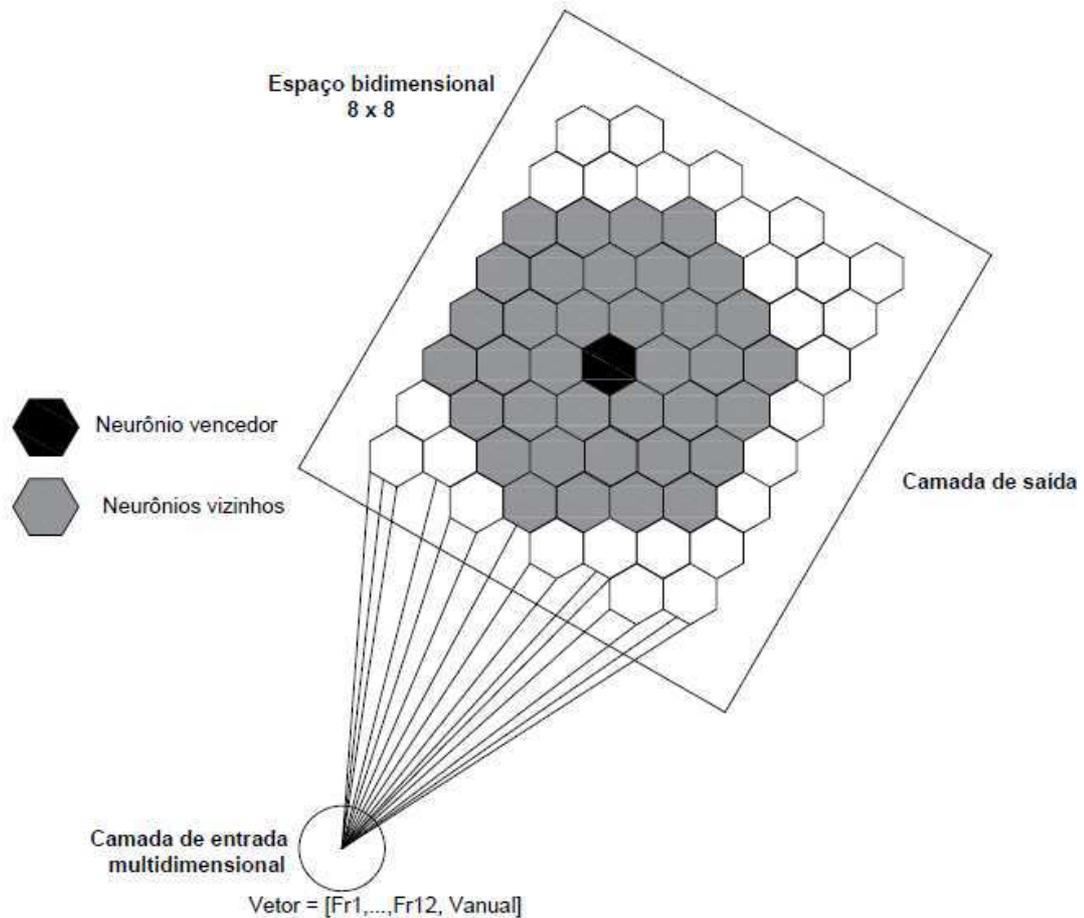
em que  $N$  é o número de dados da série adotada.

O processo de competição entre os neurônios e o ajuste de pesos ocorreram segundo as Equações (1) e (2), respectivamente, conforme descrito anteriormente. A taxa de aprendizagem adotada foi 0,9 e 0,02, durante a fase de ordenação e de ajuste fino, respectivamente.

Na fase de ordenação, optou-se por utilizar 100 apresentações do conjunto de dados de calibração, com o raio da vizinhança inicial igual a três passos e valor final igual a um. Na fase de ajustes, em que o raio da vizinhança fica abaixo da unidade e, portanto, há atualização somente no peso do neurônio vencedor, utilizou-se mais 900 apresentações (FARIAS, SILVA FILHO e BEZERRA, 2014). Para aumentar as chances de encontrar o ótimo global durante a calibração dos modelos, as redes foram treinadas 10 vezes, escolhendo-se aquela com maior coeficiente de eficiência de Nash e Sutcliffe (NASH e SUTCLIFFE, 1970).

Detalhes sobre as fases de ordenação e ajustes podem ser vistos em Beale, Hagan e Demuth (2012). Um exemplo de arquitetura SOM com o vetor de entrada da rede pode ser visualizado na Figura 4.

**Figura 4** - Exemplo de uma arquitetura SOM.



Fonte: Adaptado de Farias e Santos (2014).

Depois de treinadas, as redes SOM podem ser utilizadas para determinação dos fragmentos considerando-se uma dada vazão anual sintética. Dessa forma, os novos cenários foram gerados de acordo com os procedimentos descritos em Farias, Silva Filho e Bezerra (2014) e Farias, Bezerra e Silva Filho (2015):

- (a) calcular as distâncias Euclidianas entre o vetor de entrada e todos os neurônios do modelo SOM, considerando os componentes dos fragmentos como inexistentes;
- (b) determinar o neurônio vencedor com base na menor distância Euclidiana;
- (c) usar o peso do neurônio vencedor ligado a vazão anual correspondente com os fragmentos; e
- (d) obter as vazões mensais sintéticas pela multiplicação da vazão anual sintética com os fragmentos.

#### 4.4 AVALIAÇÃO DE DESEMPENHO DOS MODELOS

O desempenho de modelos hidrológicos é comumente mensurado através de índices estatísticos como correlação ( $r$ ), viés relativo ( $VR$ ) e coeficiente de eficiência de Nash e Sutcliffe ( $NASH$ ) (NASH e SUTCLIFFE, 1970). Aplicações destes índices também são encontradas em Lourenço (2012) e Sousa (2015). As respectivas equações matemáticas estão descritas abaixo:

$$r = \frac{n \sum Q_{obs}(t)Q_{cal}(t) - (\sum Q_{obs}(t))(\sum Q_{cal}(t))}{\sqrt{n(\sum Q_{obs}^2(t)) - (\sum Q_{obs}(t))^2} \sqrt{n(\sum Q_{cal}^2(t)) - (\sum Q_{cal}(t))^2}} \quad (5)$$

$$VR = \frac{\overline{Q_{cal}} - \overline{Q_{obs}}}{\overline{Q_{obs}}} \cdot 100\% \quad (6)$$

$$NASH = 1 - \frac{\sum (Q_{obs}(t) - Q_{cal}(t))^2}{\sum (Q_{obs}(t) - \overline{Q_{obs}})^2} \quad (7)$$

em que  $Q_{obs}(t)$  é a vazão observada no tempo  $t$ ;  $Q_{cal}(t)$  é a vazão calculada no tempo  $t$ ;  $n$  é o número de intervalos de tempo; e  $\sum$  indica o somatório entre  $t = 1$  e  $t = n$ .

O índice de correlação refere-se ao grau de dependência linear entre os cenários gerados e os valores históricos de vazão, expressando na realidade um valor potencial de bom ajuste. O viés relativo, por sua vez, tem a capacidade de determinar se o modelo de previsão tende a subestimar ou superestimar as vazões observadas. O índice de eficiência  $NASH$ , que pode variar entre  $-\infty$  e 1, é tradicionalmente utilizado para expressar aderência entre vazões históricas e sintéticas. Esse índice considera os erros sistemáticos e randômicos, indicando que o ajuste é cada vez melhor à medida que o seu valor se aproxima de 1 (ASCE, 1993; FARIAS, CARNEIRO e LOURENÇO, 2012).

Para verificar a eficiência dos modelos SOM e MF, quanto à capacidade de gerar uma nova série sintética de afluências, foram analisados parâmetros estatísticos relevantes, dentre eles: média, desvio padrão, distorção e curtose. A comparação tem como fundamento básico verificar a relação existente entre dados calculados e observados.

A média indica o valor mais representativo da série em questão, ou seja, é um número em que a maioria dos elementos do conjunto estão mais próximos. O desvio padrão diz respeito ao grau de confiabilidade dos elementos da série com a média, um valor baixo indica que os dados tendem a se aproximar da média. Já a distorção e a curtose medem, respectivamente, o grau de assimetria da série e o grau de dispersão observado na curva de função de distribuição de probabilidade.

Não é esperado que os valores gerados pelo modelo sejam idênticos aos da série histórica adotada. No entanto, em alguns casos, é desejável que os momentos estatísticos apresentem certa similaridade e proximidade. Dependendo destas propriedades, têm-se uma fraca ou uma forte estacionariedade. O termo implica no potencial das funções da média e da autocovariância em não variar no decorrer da série em análise (WILKS, 2006).

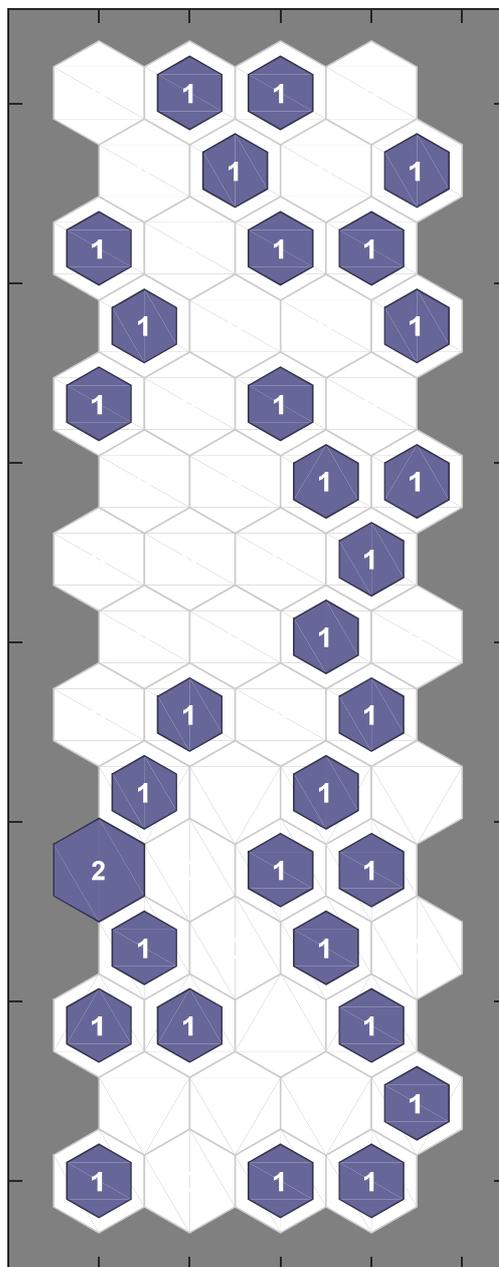
## 5 RESULTADOS E DISCUSSÃO

Os modelos e procedimentos desenvolvidos neste estudo foram programados com a capacidade de gerar séries sintéticas de 5.000 anos de dados, sendo implementados na linguagem de programação Matlab, versão R2012a.

A função de distribuição de probabilidade adotada no ajuste da série residual foi a do tipo Gama, uma vez que esta se adequa melhor ao comportamento hidrológico da região (CELESTE, CURI e CURI, 2007).

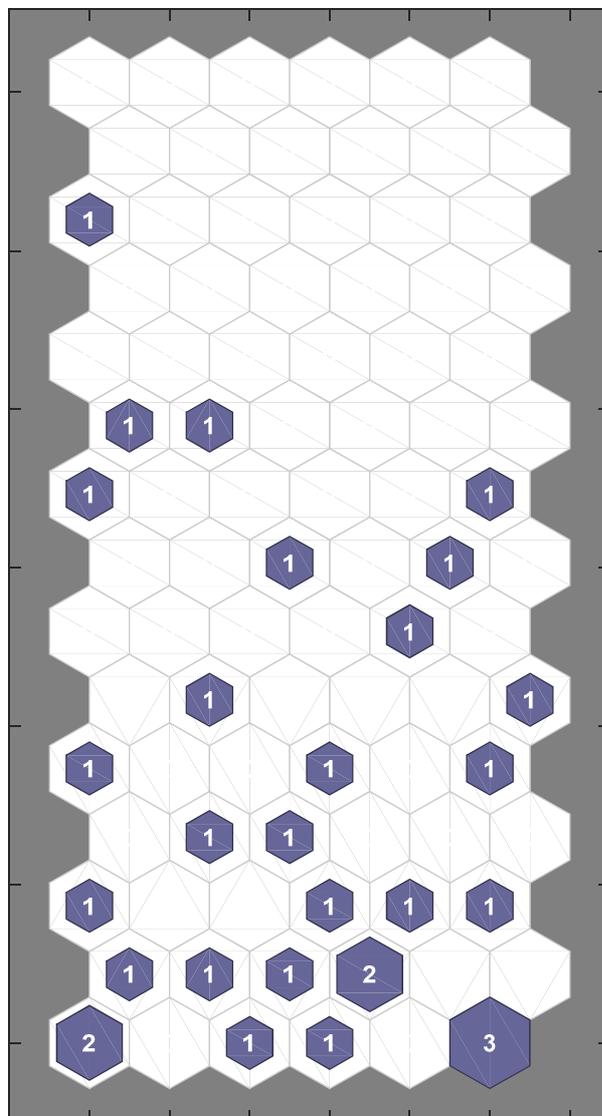
Para determinação das arquiteturas, foram utilizadas malhas que resultassem em um arranjo com 30 neurônios, conforme García e González (2004). Além destas arquiteturas, foram utilizadas outras redes com 60 e 90 neurônios para fins de comparação. Como os tamanhos das séries históricas são similares, as estruturas testadas na pesquisa para as duas aplicações foram iguais. Seus desempenhos podem ser observados nas Tabelas 1 e 2, respectivamente. As alocações dos dados de calibração no mapa topológico, referentes à melhor arquitetura de cada estudo de caso, ocorreram conforme mostrado nas Figuras 5 e 6, sendo identificado que os dados de entrada se distribuíram bem na aplicação para o posto fluviométrico Piancó, e concentraram-se na parte inferior do mapa para a aplicação no posto fluviométrico Emas.

**Figura 5** - Distribuição dos dados de calibração do modelo SOM #6 no posto fluviométrico Piancó.



Fonte: Autoria própria.

**Figura 6** - Distribuição dos dados de calibração do modelo SOM #9 no posto fluviométrico Emas.



Fonte: Autoria própria.

**Tabela 1** - Comparação das estatísticas mensais dos modelos SOM e do MF com aquelas dos dados históricos para o posto fluviométrico Piancó.

Modelo / Estrutura		CORRELAÇÃO				VIÉS RELATIVO				NASH			
		Média	Desvio padrão	Distorção	Curtose	Média	Desvio padrão	Distorção	Curtose	Média	Desvio padrão	Distorção	Curtose
Método dos fragmentos		0,9912	0,9948	0,9868	0,9813	1,40%	2,68%	18,18%	50,86%	0,9801	0,9852	0,7324	0,3244
SOM #1	1x30	0,9974	0,9921	0,9701	0,9654	1,40%	0,62%	18,02%	55,24%	0,9945	0,9834	0,6429	0,2009
SOM #2	2x15	0,9969	0,9902	0,9742	0,9794	1,40%	4,61%	18,16%	60,35%	0,9936	0,9788	0,6306	0,1827
SOM #3	3x10	0,9948	0,9768	0,9648	0,9554	1,40%	4,51%	6,33%	34,50%	0,9895	0,9525	0,8113	0,4668
SOM #4	5x6	0,9929	0,9952	0,9609	0,9513	1,40%	2,22%	16,29%	49,39%	0,9843	0,9879	0,6553	0,1652
SOM #5	2x30	0,9921	0,9928	0,9611	0,9510	1,40%	0,31%	20,79%	60,56%	0,9827	0,9838	0,5917	0,1477
<b>SOM #6</b>	<b>4x15</b>	<b>0,9919</b>	<b>0,9720</b>	<b>0,9700</b>	<b>0,9622</b>	<b>1,40%</b>	<b>6,19%</b>	<b>6,85%</b>	<b>34,76%</b>	<b>0,9836</b>	<b>0,9419</b>	<b>0,8349</b>	<b>0,5231</b>
SOM #7	6x10	0,9960	0,9944	0,9315	0,9324	1,40%	0,07%	19,75%	57,79%	0,9914	0,9883	0,5250	0,0846
SOM #8	3x30	0,9979	0,9937	0,9818	0,9792	1,40%	2,57%	17,43%	57,51%	0,9954	0,9869	0,6417	0,1207
SOM #9	6x15	0,9900	0,9877	0,9668	0,9545	1,40%	0,78%	17,06%	50,22%	0,9799	0,9743	0,7278	0,3091
SOM #10	9x10	0,9944	0,9902	0,9679	0,9594	1,40%	3,96%	16,49%	56,28%	0,9886	0,9793	0,6275	0,1068

Fonte: Autoria própria.

**Tabela 2** - Comparação das estatísticas mensais dos modelos SOM e do MF com aquelas dos dados históricos para o posto fluviométrico Emas.

Modelo / Estrutura		CORRELAÇÃO				VIÉS RELATIVO				NASH			
		Média	Desvio padrão	Distorção	Curtose	Média	Desvio padrão	Distorção	Curtose	Média	Desvio padrão	Distorção	Curtose
Método dos fragmentos		0,9978	0,9702	0,9142	0,9342	0,77%	3,90%	4,94%	15,49%	0,9952	0,9393	0,7758	0,6778
SOM #1	1x30	0,9974	0,9973	0,9211	0,9238	0,77%	14,78%	7,52%	0,72%	0,9946	0,9692	0,8239	0,8450
SOM #2	2x15	0,9994	0,9976	0,9401	0,9481	0,77%	17,32%	14,94%	4,80%	0,9983	0,9576	0,7347	0,8201
SOM #3	3x10	0,9990	0,9930	0,9252	0,9191	0,77%	19,52%	12,64%	3,00%	0,9972	0,9457	0,7652	0,7550
SOM #4	5x6	0,9967	0,9975	0,9676	0,9748	0,77%	16,50%	6,37%	2,75%	0,9890	0,9604	0,9142	0,9244
SOM #5	2x30	0,9993	0,9970	0,9602	0,9585	0,77%	20,74%	2,18%	16,73%	0,9983	0,9406	0,9158	0,8599
SOM #6	4x15	0,9965	0,9550	0,9279	0,9351	0,77%	10,69%	8,09%	6,60%	0,9929	0,9004	0,6840	0,5541
SOM #7	6x10	0,9901	0,9272	0,9445	0,9041	0,77%	13,53%	11,71%	4,06%	0,9803	0,8472	0,7382	0,4626
SOM #8	3x30	0,9758	0,9490	0,8497	0,8470	0,77%	14,64%	10,81%	5,14%	0,9520	0,8882	0,6597	0,6412
<b>SOM #9</b>	<b>6x15</b>	<b>0,9992</b>	<b>0,9974</b>	<b>0,9577</b>	<b>0,9750</b>	<b>0,77%</b>	<b>15,92%</b>	<b>1,33%</b>	<b>5,51%</b>	<b>0,9965</b>	<b>0,9651</b>	<b>0,9146</b>	<b>0,9432</b>
SOM #10	9x10	0,9984	0,9895	0,9260	0,8819	0,77%	20,55%	2,67%	20,70%	0,9963	0,9344	0,8543	0,6407

Fonte: Autoria própria.

Quando se trata de modelos hidrológicos, valores de *NASH* iguais ou superiores a 0,75 são considerados eficazes; e valores entre 0,36 e 0,75 são considerados aceitáveis (COLLISCHONN, 2001). De acordo com Farias, Carneiro e Lourenço (2012), altos valores de correlação não significam, unicamente, previsões com alta precisão. Por exemplo, um modelo com viés alto, mesmo que possua correlação igual a 1, poderá fornecer gerações de vazões de baixa precisão. Um sistema perfeito de previsão teria que ter *r* e *VR* iguais a 1 e 0, respectivamente.

Durante a calibração de todas as redes, obteve-se valores de *NASH* entre 0,9989 e 0,9999 para o posto fluviométrico Piancó, e entre 0,9993 e 0,9999 para o posto fluviométrico Emas.

Diante disso, pode-se considerar que os resultados produzidos pelos modelos SOM foram excelentes para geração sintética de vazões mensais considerando-se as duas aplicações. De acordo com a Tabela 1, para a aplicação no posto fluviométrico Piancó, todas as redes produziram dados com médias e desvios padrão mensais similares às respectivas estatísticas observadas nos dados históricos, com valores de *NASH* comparativos superiores a 0,94. O coeficiente *NASH* para a comparação de distorções foi considerado eficaz nas redes SOM #3 e #6, sendo considerados aceitáveis nas demais. Para a estatística curtose, também se observa valores aceitáveis de *NASH* nas redes SOM #3 e #6, sendo esta última ligeiramente superior. Desta forma, percebe-se que o modelo SOM #6 apresentou um melhor desempenho quando comparado com as demais estruturas e com o MF.

Na Tabela 2, percebe-se que os resultados também foram promissores para a aplicação no posto fluviométrico Emas. Os coeficientes de *NASH* foram considerados eficazes nas comparações das médias e desvios padrão mensais, sendo superiores a 0,84. Para distorção, todas as estruturas apresentaram valores eficazes, com exceção das redes SOM #2, #6, #7 e #8, que foram aceitáveis. Com relação ao coeficiente *NASH* para a curtose, observam-se valores eficazes de *NASH* nas redes SOM #1, #2, #3, #4, #5 e #9, sendo considerados aceitáveis nas demais estruturas.

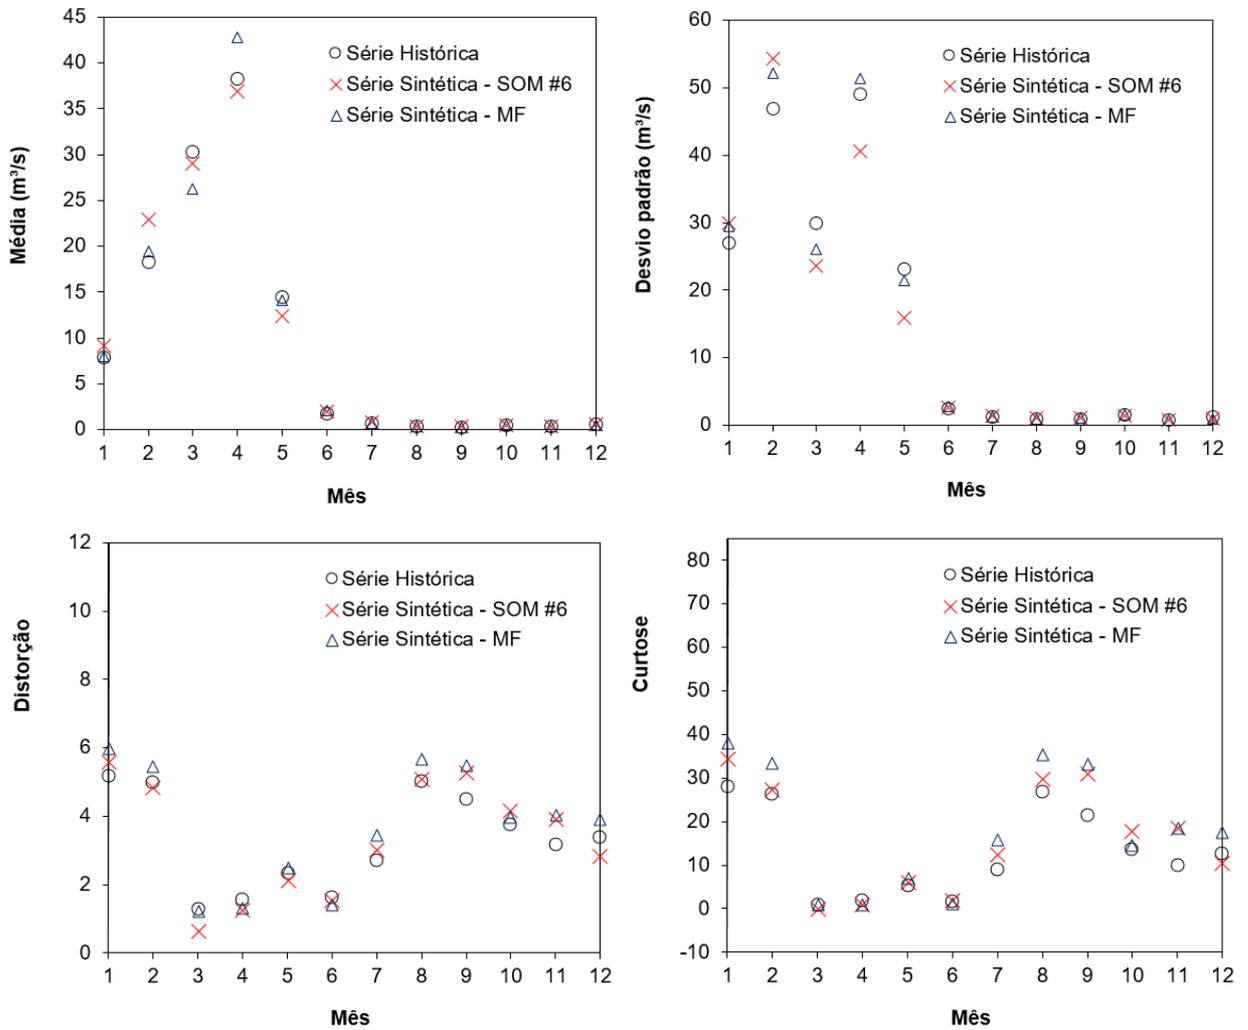
A variabilidade observada entre as estruturas testadas, no que diz respeito aos momentos estatísticos distorção e curtose, se deu basicamente devido à dificuldade em modelar estocasticamente e conseguir reproduzir erros de terceiro e quarto grau. Uma vez que os dados analisados foram considerados como

fenômenos independentes e de grande variabilidade. Mesmo assim, os procedimentos desenvolvidos utilizando os mapas auto-organizáveis de Kohonen mostraram-se promissores e constituem-se como mais uma alternativa eficiente, podendo, como visto na aplicação para os dois postos em estudo, superar o tradicional método dos fragmentos.

De forma geral, os valores de viés relativo e correlação obtidos nas comparações mensais dos momentos, para ambas aplicações, foram próximos de zero e um, respectivamente, o que confere potencialidade dos procedimentos adotados. Os valores mais distantes do esperado para esses dois parâmetros podem ser encontrados nas redes SOM #2 e #5, para o posto fluviométrico Piancó; e nas redes SOM #5 e #10, para o posto fluviométrico Emas.

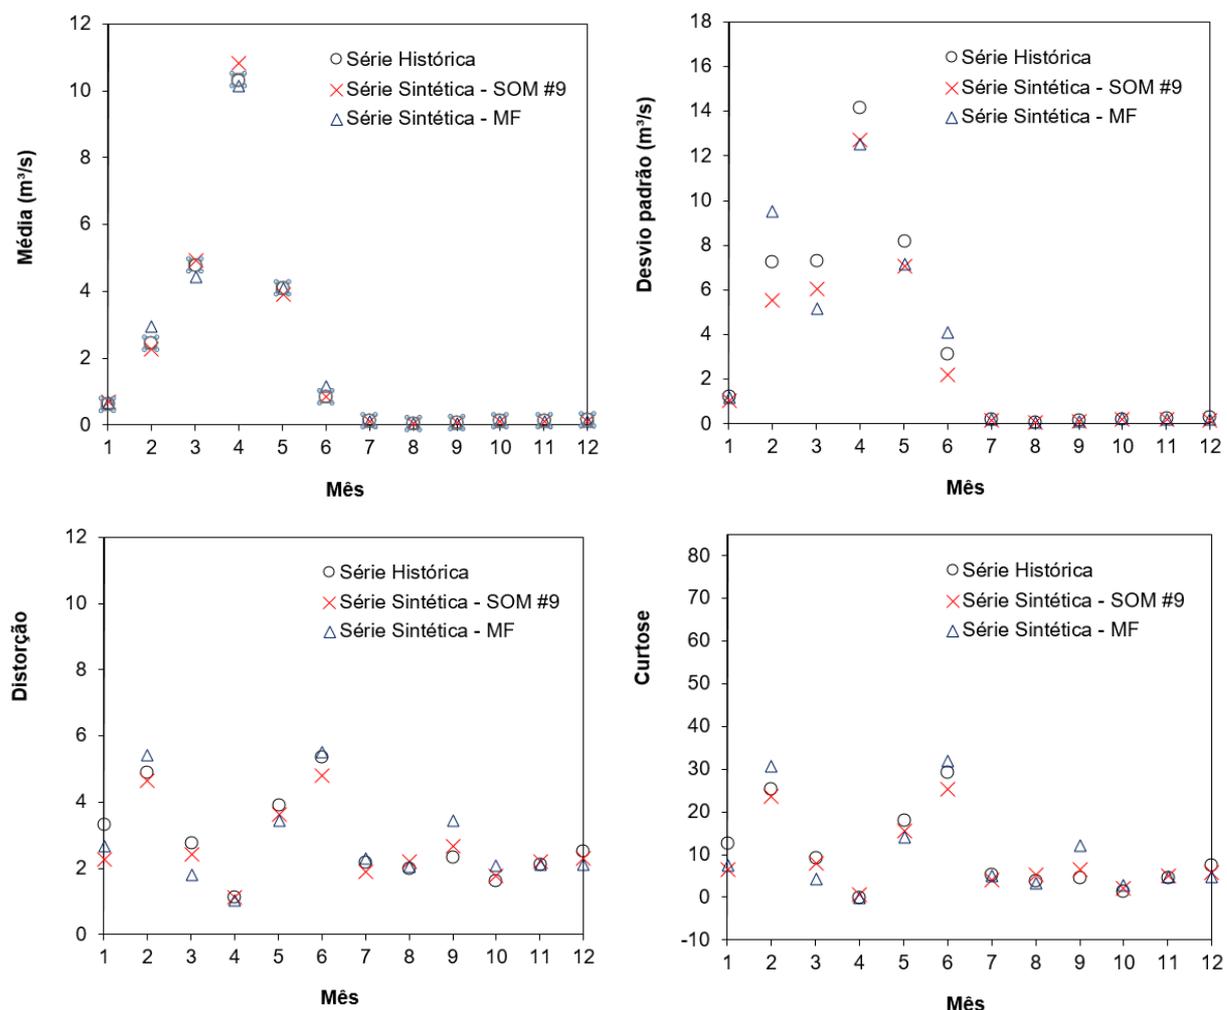
Na Figura 7 e 8, considerando os postos Piancó e Emas, respectivamente, encontra-se um comparativo das médias, desvios padrão, distorções e curtoses mensais entre os dados históricos e sintéticos gerados a partir das melhores estruturas SOM testadas e do MF.

**Figura 7** - Comparação das propriedades estatísticas entre vazões sintéticas (modelos SOM #6 e MF) e históricas no posto fluviométrico Piancó.



Fonte: Autoria própria.

**Figura 8** - Comparação das propriedades estatísticas entre vazões sintéticas (modelos SOM #9 e MF) e históricas no posto fluviométrico Emas.

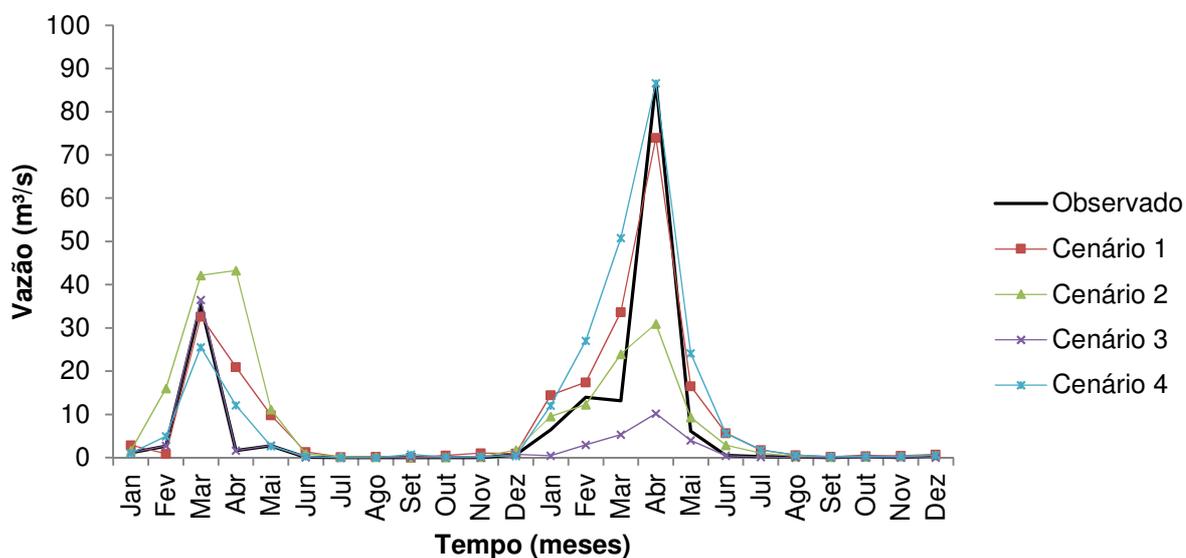


Fonte: Autoria própria.

Por meio da análise das Figuras 7 e 8, verificou-se que as propriedades estatísticas das vazões mensais sintéticas se mostraram similares às observadas nos dados históricos, indicando que a estrutura SOM e o MF, para ambos os postos, possuem qualidade na geração sintética de vazões. O modelo de inteligência artificial, no entanto, conseguiu reproduzir melhor os momentos estatísticos analisados em ambos os postos fluviométricos adotados.

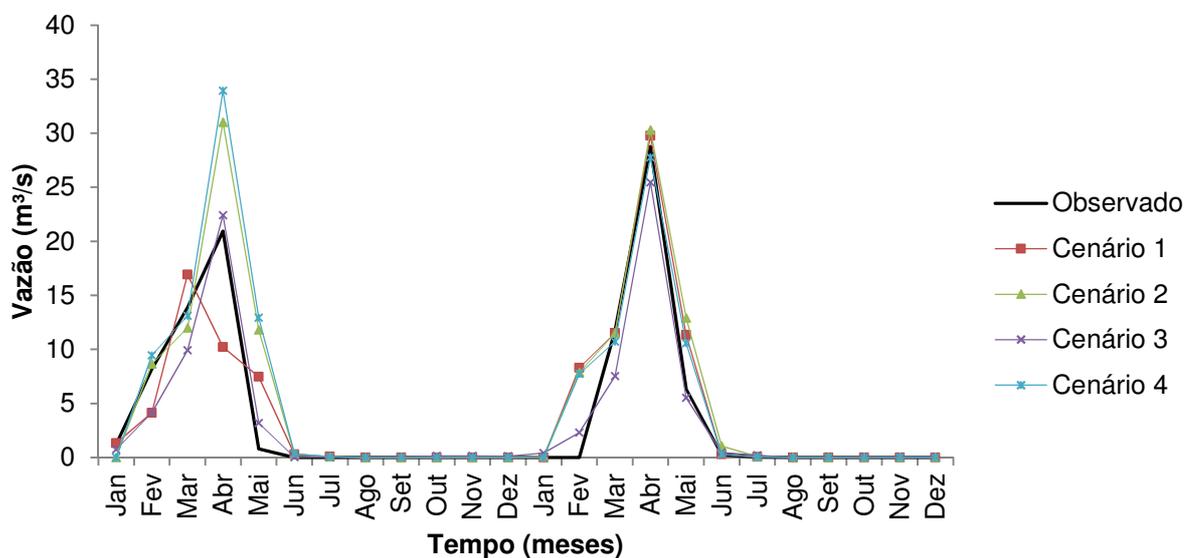
Nas Figuras 9 e 10 encontram-se um exemplo dos diferentes cenários que podem ser obtidos utilizando os mapas auto-organizáveis para geração sintética de vazões.

**Figura 9** – Comparação de cenários sintéticos (modelo SOM #6) com valores observados no período de 1999 - 2000 no posto fluviométrico Piancó.



Fonte: Autoria própria.

**Figura 10** – Comparação de cenários sintéticos (modelo SOM #9) com valores observados no período de 1964 - 1965 no posto fluviométrico Emas.



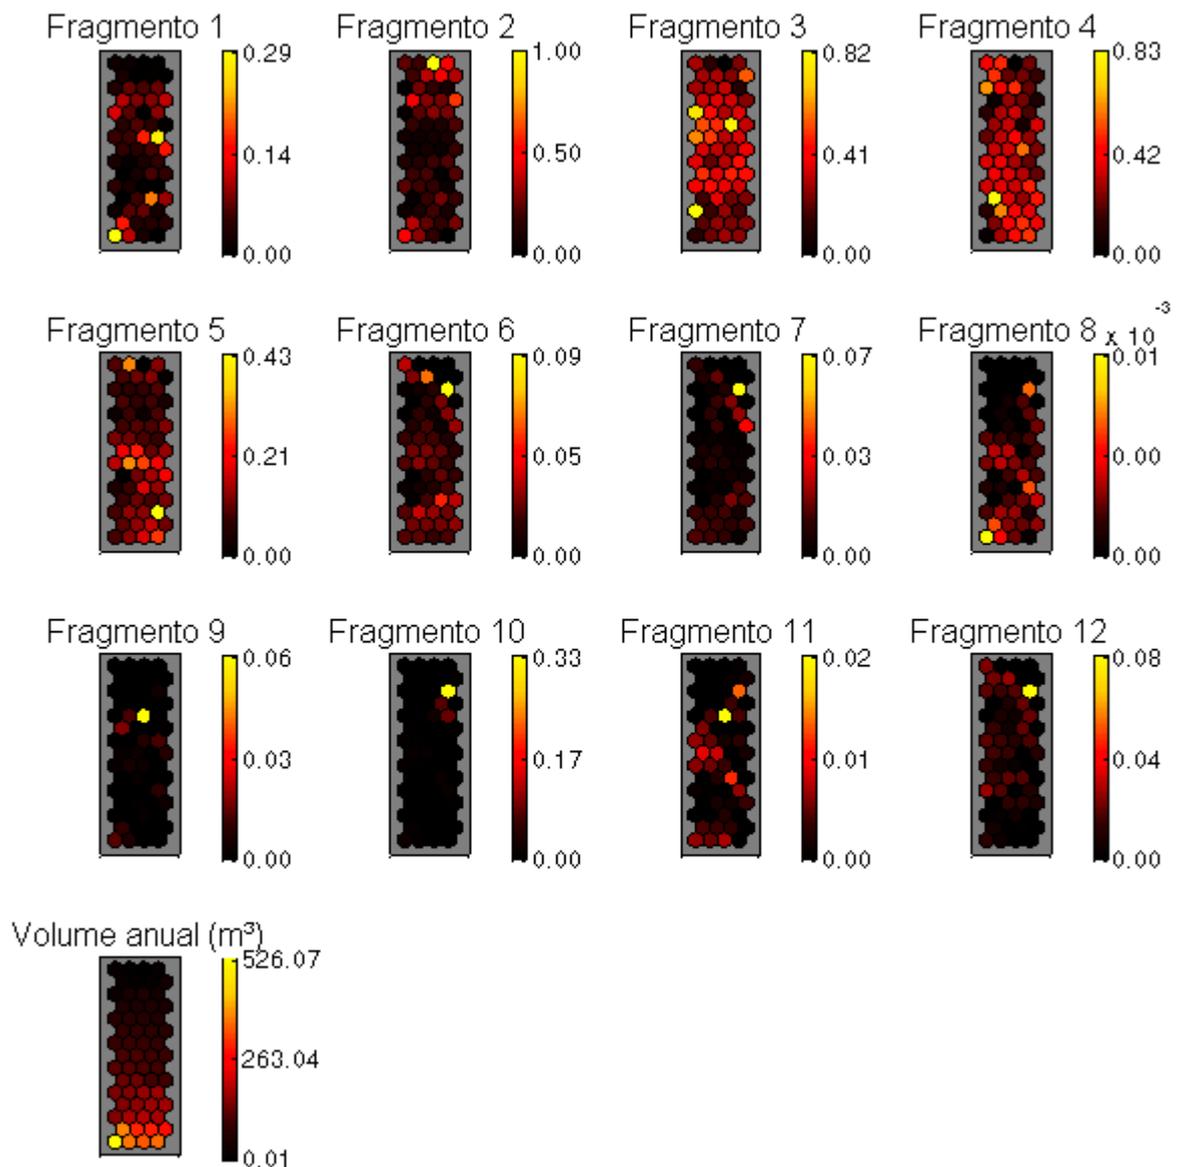
Fonte: Autoria própria.

Observa-se nas duas figuras acima que as hidrógrafas têm comportamento similar quando comparado quatro possíveis cenários e as vazões observadas, sendo

ainda possível encontrar uma variação entre os cenários nos meses mais chuvosos.

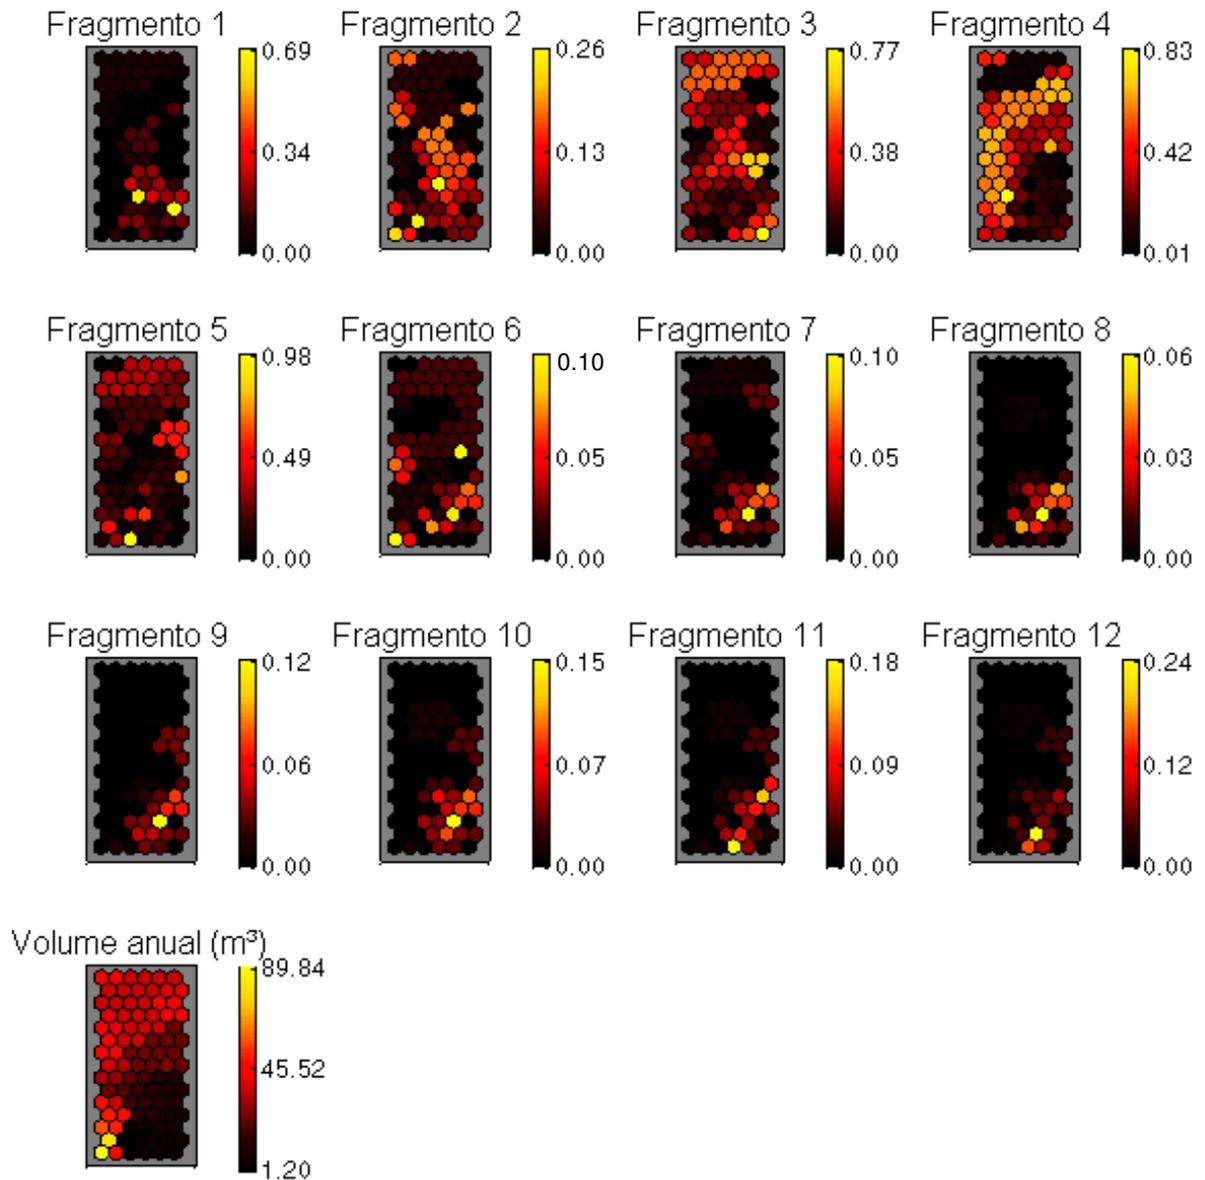
Nas Figuras 11 e 12, observam-se os planos de componentes das melhores estruturas SOM para os dois estudos de caso. A simulação dos valores em estudo para os diferentes neurônios é realizada por meio de uma escala de cores. As zonas amarelas correspondem aos maiores valores, enquanto as regiões em cor preta, aos menores.

**Figura 11** - Mapas de componentes derivados da calibração do modelo SOM #6 para o posto fluviométrico Piancó.



Fonte: Autoria própria.

**Figura 12** - Mapas de componentes derivados da calibração do modelo SOM #9 para o posto fluviométrico Emas.



Fonte: Autoria própria.

Ao comparar o mapa dos volumes anuais com os mapas dos fragmentos mensais para o posto fluviométrico Piancó, averigua-se que os maiores valores de vazão anual estão associados a valores médios nos fragmentos correspondentes aos meses de janeiro, fevereiro, março, abril, maio e junho. Já no posto fluviométrico de Emas, os altos volumes anuais estão associados a valores médios e altos de fragmentos nos meses de março e abril. É possível verificar ainda que existe uma grande variação do comportamento dos fragmentos no decorrer dos meses.

## 6 CONCLUSÃO

Esta pesquisa apresentou modelos de mapas de Kohonen para geração sintética de vazões mensais, aplicados em dois postos fluviométricos localizados no semiárido paraibano.

Os modelos desenvolvidos foram avaliados por meio de um estudo comparativo entre as propriedades estatísticas mensais das vazões observadas e geradas. Com a finalidade de verificar a sua eficácia, o estudo foi conduzido e mensurado através de índices de desempenho, sendo eles: correlação, viés relativo e eficiência *NASH*.

Os resultados das redes SOM foram também comparados com a aplicação do método dos fragmentos. Em ambos os postos fluviométricos escolhidos, o modelo de melhor desempenho conseguiu preservar os momentos estatísticos observados na série histórica, gerando resultados consistentes.

Com base nos resultados, é possível afirmar que, para modelagem estocásticas de séries de aflúências, a utilização dos mapas auto-organizáveis constitui-se uma alternativa para obtenção de cenários sintéticos, possuindo a capacidade de gerar séries estatisticamente melhores do que o método dos fragmentos. Todavia, as redes SOM nem sempre podem ser superiores aos modelos tradicionais, sendo necessário analisar várias estruturas e verificar qual apresenta o melhor desempenho.

Espera-se que este estudo possa contribuir na formulação de medidas para o melhor gerenciamento dos recursos hídricos e, mediante aos resultados significativos obtidos, que este tipo de modelagem possa ser utilizado para extensão de séries de vazões em locais carentes de informações hidrometeorológicas.

## REFERÊNCIAS BIBLIOGRÁFICAS

ARAÚJO, J. K.; CAMPOS, J. N. B. Utilização do método dos fragmentos no estudo da disponibilidade hídrica de açudes no semiárido. In: Simpósio Brasileiro de Recursos Hídricos, 9 ., 1991, Rio de Janeiro. **Anais do IX Simpósio Brasileiro de Recursos Hídricos**. Porto Alegre: ABRH, 1991. p. 467-474.

ANA – Agência Nacional de Águas. **Banco de dados Hidroweb**. Vazão diária ( $m^3/s$ ). Disponível em: < <http://hidroweb.ana.gov.br/> >. Acesso em: 23/01/2016.

ASCE. Task Committee on Definition of Criteria for Evaluation of Watershed Models of the Watershed Management. Committee Irrigation and Drainage Division. Criteria for evaluation of watershed models. **J. Irrig. Drainage Eng.**, v. 119, n. 3, p. 429-442, Jan. 1993.

BEALE, M.; HAGAN, M.; DEMUTH H. **Neural Network Toolbox 7.0.3: User's Guide**. The Math Works Inc, Natick, USA, 2012. 404p.

BERSSANETI, F. T. **Identificação de variáveis que impactam o sucesso de projetos nas empresas brasileiras**, 2011. 185 fls. Tese (Doutorado em Engenharia), Universidade de São Paulo, São Paulo, 2011.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000. 262 p.

BRASILIANO, L. N. **Regras operacionais para reservatórios baseadas em otimização estocástica implícita e redes neurais de função de base radial**. 2014. 38 fls. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Universidade Federal de Campina Grande, Pombal. 2014.

CARNEIRO, T. C.; FARIAS, C. A. S. Otimização estocástica implícita e redes neurais artificiais para auxílio na operação mensal dos reservatórios Coremas - Mãe D água. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 18, n. 4, p. 115-124, Out./Dez. 2013.

CELESTE, A. B.; BILLIB, M. Improving Implicit Stochastic Reservoir Optimization Models with Long Term Mean Inflow Forecast. **Water Resources Management**, Leiden, v. 26, n. 9, p. 2443-2451, Mar. 2012.

CELESTE, A. B.; CURI, W. F.; CURI, R. C. Análise de Métodos para Geração Sintética de Vazões em rios intermitentes. In: Simpósio Brasileiro de Recursos Hídricos, 17., 2007, São Paulo. **Anais do XVII Simpósio Brasileiro de Recursos Hídricos**. Porto Alegre: ABRH, 2007. p. 1-18.

CHANG, L. C.; CHANG, F. J., WANG, K. W.; DAI, S. Y. Constrained genetic algorithms for optimizing multi-use reservoir operation. **Journal of Hydrology**, Amsterdã, v. 390, n. 1, p. 66-74, Aug. 2010.

COLLISCHONN, W. **Simulação Hidrológica em Grandes Bacias**. 2001. 127 fls. Tese (Doutorado), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2001.

DINIZ, L. S. **Regionalização de parâmetros de modelo chuva-vazão usando redes neurais**. 2008. 213 fls. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

ELSHORBAGY, A.; SIMONOVIC, S. P.; PANU, U. S. Performance evaluation of artificial neural networks for runoff prediction. **Journal of Hydrologic Engineering**, v. 5, n. 4, p.424-427, Oct. 2000.

EMCH, P. G.; YEH, W. G. Management model for conjunctive use of coastal surface water and ground water, **Journal of Water Resources Planning and Management**, v. 124, n. 3, p. 129-139, May 1998.

FARIAS, C. A. S.; SANTOS, C. A. G. The use of Kohonen neural networks for runoff erosion modeling. **Journal of Soils and Sediments**, v. 14, n. 7, p. 1242–1250, Jan. 2014.

FARIAS, C. A. S.; SANTOS, C. A. G.; LOURENÇO, A. M. G.; CARNEIRO, T. C. Kohonen neural networks for rainfall-runoff modeling: case study of Piancó River Basin. **Journal of Urban and Environmental Engineering**, v. 7, n. 1, p. 176–182, June 2013.

FARIAS, C. A. S. **Derivation of hedging rules and forecasts by artificial neural networks for optimal real-time management of an integrated water resources system**, 2009. 127 fls. Tese (Doutorado em Engenharia), Ehime University, Matsuyama, 2009.

FARIAS, C. A. S.; BEZERRA, U. A. SILVA FILHO, J. A. Runoff-erosion modeling at micro-watershed scale: a comparison of self-organizing maps structures. **Geoenvironmental Disasters**, v. 2, n. 1, p. 1–8, June 2015.

FARIAS, C. A. S.; CARNEIRO, T. C.; LOURENÇO, A. M. G. Mapas auto-organizáveis para modelagem chuva-vazão. In: Simpósio de recursos hídricos do Nordeste, 11., 2012, João Pessoa. **Anais do XI Simpósio de Recursos Hídricos do Nordeste**. Porto Alegre: ABRH, 2012. p. 1-14.

FARIAS, C. A. S.; KADOTA, A.; SUZUKI, K.; SHIGEMATSU, K. Stochastic generation of daily groundwater levels by artificial neural networks. **Annual Journal of Hydraulic Engineering**, v. 55, n. 4, p. 55-60, Feb. 2011.

FARIAS, C. A. S.; SILVA FILHO, J. A.; BEZERRA, U. A. Um modelo de mapas auto-organizáveis para análise e estimativa da produção de sedimentos em uma microbacia localizada no semiárido paraibano. In: Encontro Nacional de Engenharia de Sedimentos, 11., 2014, São Paulo. **Anais do XI Simpósio Brasileiro de Recursos Hídricos**. Porto Alegre: ABRH, 2014. p. 1-12.

FARIAS, C. A. S.; SUZUKI, K.; KADOTA, A.; CELESTE, A. B. Synthetic generation of monthly reservoir inflows by an input delayed neural network. **Annual Journal of Hydraulic Engineering**, v. 51, n. 1, p. 85-90, Feb. 2007.

FARIAS, J. A. M. **Métodos de geração de vazões mensais e suas influências sobre a curva de garantia versus vazão regularizada em reservatórios do estado do Ceará**. 2003. 131 fls. Dissertação (Mestrado em Recursos Hídricos) - Universidade Federal do Ceará, Fortaleza, 2003.

FAVORETO, R. S.; ROHN, M. C.; MINE, M. R. M. A técnica de rede neural artificial aplicada na previsão de vazão. In: Simpósio Brasileiro de Recursos Hídricos e Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa, 5, 2001, Aracaju. **Anais do V Simpósio Brasileiro de Recursos Hídricos e Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa**. Porto Alegre: ABRH, 2001.

FLOOD, I.; KARTAM, N. Neural networks in civil engineering I: principles and understanding, **Journal Computational Civil Engineering**, v.8, n.2, p.131-148, Apr. 1994.

GARCÍA, H. L.; GONZÁLEZ, I. M. Self-organizing map and clustering for wastewater treatment monitoring. **Engineering Applications of Artificial Intelligence**, v. 17, n. 3, p. 215–225, Apr. 2004.

HAMILTON, J. D. **Time Series Analysis**. Princeton: Princeton University Press, 1994. 799 p.

HAYKIN, S. **Neural Networks**: a Comprehensive Foundation. New Jersey: Prentice Hall, 1999. 842 p.

HAYKIN, S. **Redes neurais**: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, n. 1, p. 59–69, Jan. 1982.

KUMAR, A. R. S.; GOYAL, M. K.; OJHA, C. S. P.; SINGH, R. D.; SWAMEE, P. K.; NEMA, R. K. Application of ANN, Fuzzy Logic and Decision Tree Algorithms for the development of reservoir operating rules. **Water Resources Management**, Leiden, v. 27, n. 3, p. 911-925, Jan. 2013.

LIMA, C. A. G. **Análise e sugestões para diretrizes de uso das disponibilidades hídricas superficiais da bacia hidrográfica do rio Piancó, situada no estado da Paraíba**. 2004. 274 fls. Tese (Doutorado em Recursos Naturais), Universidade Federal de Campina Grande, Campina Grande, 2004.

LOUCKS, D. P.; STEDINGER, J. R.; HAITH, D. A. **Water Resources Systems Planning and Analysis**. New Jersey: Prentice Hall - Englewood Cliffs, 1981. 559 p.

LOURENÇO, A. M. G. **Modelos chuva-vazão baseados em redes neurais artificiais para rios intermitentes no semiárido paraibano**. 2012. 46 fls. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Universidade Federal de Campina Grande, Pombal. 2012.

LUCAS, E. W. M.; SOUSA, F. A. S.; SILVA, F. D. S.; LUCIO, P. S. Modelagem hidrológica determinística e estocástica aplicada à região hidrográfica do Xingu – Pará. **Revista Brasileira de Meteorologia**, São José dos Campos, v. 24, n. 3, p. 308-322, Set. 2009.

MACHADO, F. W. **Modelagem chuva-vazão mensal utilizando redes neurais artificiais**. 2005. 174 fls. Dissertação (Mestrado), Universidade Federal do Paraná, Curitiba, 2005.

MUNICCI, L. R. **Regionalização de série de vazões mensais utilizando redes neurais artificiais**. 2014. 95 f. Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambiental), Universidade Federal do Paraná, Curitiba, 2014.

NASH, J. E.; SUTCLIFFE, J. V. River Flow Forecasting through Conceptual Models: Part I - A Discussion of Principles. **Journal of Hydrology**, v. 10, n. 3, p. 282–290, Apr. 1970.

PULITO-VELÁZQUEZ, M.; ANDREU, J.; SAHUQUILLO, A. Economic optimization of conjunctive use of surface water and groundwater at the basin scale. **Journal of Water Resources Planning and Management**, v. 132, n. 6, p. 454-467, Nov. 2006.

RAMOS, A. M.; GALVÃO, C. O. Estabilidade de redes neurais em modelagem hidrometeorológicas. In: Simpósio Brasileiro de Recursos Hídricos e Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa, 5, 2001, Aracaju. **Anais do V Simpósio Brasileiro de Recursos Hídricos e Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa**. Porto Alegre: ABRH, 2001.

RICHARDSON, C. W. Stochastic simulation of daily precipitation, temperature, and solar radiation. **Water Resources Research**, v. 17, n. 4, p. 182-190, Feb. 1981.

RODRIGUES, A. C. L.; CELESTE, A. B.; BARBOSA, R. L.; CURI, W. F.; CURI, R. C. Estudo da influência da transposição do rio São Francisco sobre o processo de outorga de uso da água na bacia hidrográfica do Rio Piancó-PB. In: Simpósio brasileiro de recursos hídricos, 17., 2007, São Paulo. **Anais do XVII Simpósio Brasileiro de Recursos Hídricos**. Porto Alegre: ABRH, 2007. p. 1-17.

SALAS, J. D.: Analysis and modeling of hydrologic time series, In: Maidment, D. R.: **Handbook of Hydrology**, McGraw-Hill, Inc., New York, pp. 19.1-19.72, 1993.

SCIENTEC, Associação para Desenvolvimento da Ciência e Tecnologia. **Plano Diretor de Recursos Hídricos da Paraíba: Bacias do Piancó e do Alto Piranhas**. SEPLAN, Brasil, 1997.

SILVA FILHO, J. A.; FARIAS, C. A. S.; ARAÚJO, S. C.; BEZERRA, U. A. Utilização do método dos fragmentos para geração sintética de vazões: um estudo de caso no semiárido paraibano. In: Congresso Nacional de Meio Ambiente de Poços de Caldas, 12., 2015, Poços de Caldas. **Anais do XII Congresso Nacional de Meio Ambiente de Poços de Caldas**. Poços de Caldas: IFSULDEMINAS, 2015. p. 1-8.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 399 p.

SOARES, P. L. B.; SILVA, J. P. Aplicação de Redes Neurais Artificiais em Conjunto com o Método Vetorial da Propagação de Feixes na Análise de um Acoplador Direcional Baseado em Fibra Ótica. **Revista Brasileira de Computação Aplicada**, v. 3, n. 2, p. 58-72, Set. 2011

SOUSA, F. A. S.; SOUSA, W. S. Rede neural aplicada ao processo chuva-vazão da Bacia Hidrográfica de Caraúbas – PB. In: Congresso Brasileiro de Meteorologia, 14, 2006, Florianópolis. **Anais do XIV Congresso Brasileiro de Meteorologia**. Florianópolis: SBMET, 2006. p. 1-6.

SOUSA, K. S. **Aplicação de redes neurais artificiais do tipo multilayer perceptron para regionalização de vazões**. 2015. 39 fls. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Universidade Federal de Campina Grande, Pombal. 2015.

SOUSA, W. S.; SOUSA, F. A. S. Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, n.2, p.173–180, Fev. 2010

SVANIDZE, G. G. **Mathematical Modeling of Hydrologic Series** (for Hydroelectric and Water Resources Computations). Fort Collins: Water Resources Publications, 1980. 314 p.

TAFNER, M. A.; XEREZ, M.; RODRIGUES FILHO, I. W. **Redes neurais, introdução e princípios de neurocomputação**. Blumenau: Eko, 1996. 199 p.

WILKS, D. S. **Statistical Methods in the Atmospheric Sciences**. 2d ed. International Geophysics Series, Vol. 91, Academic Press, 627 pp, 2006.

## APÊNDICE A – SÉRIE FLUVIOMÉTRICA DO POSTO PIANCÓ

Vazão mensal (m³/s)												
Ano	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1965	2,45	1,52	14,99	37,10	5,13	1,10	0,09	0,00	0,00	0,00	0,00	0,00
1966	0,00	1,64	1,22	0,72	0,41	0,30	0,06	0,00	0,00	0,00	0,00	0,11
1967	0,39	0,19	85,78	185,75	96,39	5,07	0,47	0,05	0,00	0,00	0,00	0,00
1968	1,05	3,33	110,96	8,87	7,85	2,11	1,03	0,19	0,00	0,00	0,00	0,00
1970	5,00	0,56	31,17	2,78	0,46	0,00	0,00	0,00	0,00	0,00	0,00	0,00
1971	6,24	62,54	60,84	109,36	24,79	7,07	2,39	0,74	0,00	0,00	0,00	0,00
1972	0,08	6,43	13,31	15,08	4,51	1,18	1,45	0,09	0,01	0,03	0,01	0,01
1973	8,56	10,23	16,21	111,01	20,69	6,41	1,20	0,52	0,00	0,00	0,00	0,21
1976	0,00	10,35	10,86	13,11	0,51	0,11	0,00	0,00	2,28	0,41	0,96	0,10
1977	2,04	7,86	20,53	63,44	72,84	3,48	0,54	0,08	0,00	0,00	0,00	0,00
1978	1,82	10,55	28,07	10,83	13,51	0,59	0,11	0,09	0,00	0,00	0,00	0,00
1979	0,28	15,28	58,37	50,15	28,39	1,00	0,08	0,00	0,00	0,00	0,00	0,00
1980	0,00	32,28	89,71	0,73	0,03	0,00	0,00	0,00	0,00	0,00	0,13	5,73
1981	0,07	12,35	51,49	42,85	0,18	0,00	0,00	0,00	0,00	0,00	0,00	0,92
1982	0,26	0,03	3,54	8,88	0,60	0,02	0,00	0,00	0,00	0,00	0,00	0,20
1984	0,00	2,29	14,05	113,35	6,28	0,15	0,01	0,00	0,00	0,00	0,00	0,00
1986	4,99	32,41	89,99	150,47	64,67	3,38	2,31	0,70	0,01	0,00	2,90	0,10
1987	1,23	2,85	9,44	14,52	1,26	0,22	0,13	0,00	0,00	0,00	0,00	0,41
1993	0,02	0,34	0,20	1,37	0,94	0,00	0,00	0,00	0,00	0,00	0,00	0,00
1994	34,51	37,18	29,25	39,17	9,53	8,51	2,72	0,34	0,01	0,01	0,14	1,17
1996	0,42	6,19	13,40	33,42	28,30	2,19	0,48	0,30	0,25	0,16	0,46	0,30
1997	2,82	0,86	31,90	20,53	9,61	1,27	0,17	0,23	0,00	0,51	1,00	0,94
1999	1,10	2,64	35,53	1,60	2,73	0,10	0,00	0,00	0,00	0,00	0,00	0,69
2000	6,44	13,93	13,16	86,89	6,17	0,50	0,21	0,16	0,03	0,20	0,01	0,41
2001	0,00	7,00	11,02	1,71	0,11	0,00	0,00	0,00	0,00	0,08	0,02	0,00
2003	14,80	3,00	18,42	12,68	2,35	0,31	0,04	0,07	0,43	0,05	0,11	0,64
2004	151,44	263,89	34,90	7,67	31,20	8,27	5,66	5,03	5,32	5,44	3,70	3,55
2006	0,06	4,51	54,11	74,32	19,74	2,14	1,43	1,00	0,76	1,19	1,16	0,86
2007	2,98	16,26	5,86	1,28	0,61	0,03	0,01	0,00	0,00	0,00	0,00	0,01
2010	1,23	0,92	1,28	3,49	1,40	1,95	1,43	0,14	0,04	6,93	0,36	1,71
2011	3,22	15,24	10,45	0,61	2,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00
2012	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Fonte: ANA (2016).

## APÊNDICE B – SÉRIE FLUVIOMÉTRICA DO POSTO EMAS

Vazão mensal (m³/s)												
Ano	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1964	1,18	8,15	13,87	20,94	0,78	0,01	0,00	0,00	0,00	0,00	0,00	0,00
1965	0,00	0,00	11,75	28,77	6,36	0,27	0,02	0,00	0,00	0,00	0,00	0,00
1967	0,00	8,02	11,13	28,80	10,97	0,29	0,04	0,00	0,00	0,00	0,00	0,00
1968	1,42	0,81	19,16	1,43	12,76	0,54	0,16	0,01	0,00	0,00	0,00	0,00
1969	0,00	0,00	6,50	8,72	0,18	0,01	0,01	0,00	0,00	0,00	0,00	0,00
1970	3,13	0,02	1,24	0,15	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,00
1971	0,10	0,82	2,86	16,49	0,96	2,28	0,00	0,00	0,00	0,00	0,00	0,00
1972	0,01	0,48	2,51	0,57	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
1985	0,63	39,82	6,91	20,74	4,13	17,22	0,43	0,06	0,01	0,00	0,00	0,03
1986	0,03	4,55	34,69	43,84	5,90	0,44	0,19	0,06	0,01	0,00	0,00	0,00
1987	0,00	0,01	2,88	0,72	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
1988	0,00	0,61	4,04	39,61	2,71	0,40	0,08	0,00	0,00	0,00	0,00	0,00
1989	0,00	0,00	0,51	32,34	10,55	0,65	0,81	0,00	0,00	0,00	0,00	0,00
1990	0,00	0,01	0,00	0,02	1,54	0,00	0,00	0,00	0,00	0,00	0,00	0,00
1991	0,00	1,15	4,79	0,32	0,64	0,00	0,00	0,00	0,00	0,00	0,00	0,00
1992	5,88	0,73	0,49	1,76	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
1994	2,04	3,84	7,75	5,53	0,29	0,22	0,01	0,00	0,00	0,00	0,00	0,00
1995	0,00	0,00	0,00	0,18	4,91	0,13	0,04	0,05	0,11	0,16	0,58	0,08
1996	0,08	0,07	0,93	6,10	10,49	0,26	0,01	0,00	0,53	0,47	0,48	0,53
1997	0,43	0,00	1,17	0,15	0,10	0,01	0,01	0,01	0,08	0,10	0,55	0,49
1998	0,44	0,19	0,26	0,50	0,20	0,19	0,15	0,11	0,11	0,10	0,14	0,08
1999	0,29	0,19	0,60	0,11	2,28	0,03	0,12	0,04	0,12	0,14	0,00	0,03
2000	0,21	0,31	0,03	0,63	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,00
2001	0,00	0,21	3,04	0,55	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
2005	0,31	0,47	0,44	0,13	0,00	0,00	0,00	0,11	0,20	0,32	0,47	1,22
2006	0,34	0,78	6,51	23,27	5,10	0,04	0,03	0,05	0,05	0,28	0,24	0,22
2007	0,12	0,52	0,19	0,42	0,39	0,41	0,42	0,24	0,51	0,65	0,24	0,24
2009	0,40	0,99	2,29	35,72	42,89	1,85	0,21	0,12	0,08	0,15	0,12	0,18
2010	0,22	0,19	0,32	0,86	0,27	0,30	0,16	0,12	0,12	0,38	0,25	0,56
2011	1,21	2,36	1,03	0,12	2,17	0,19	0,27	0,17	0,10	0,64	0,28	0,38
2012	0,44	0,69	0,60	0,53	0,33	0,45	0,49	0,30	0,46	0,67	1,03	0,49

Fonte: ANA (2016).