



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

**MODELOS CHUVA-VAZÃO BASEADOS EM REDES NEURAIIS  
ARTIFICIAIS PARA RIOS INTERMITENTES NO SEMIÁRIDO  
PARAIBANO**

Artur Moises Gonçalves Lourenço

**POMBAL - PB  
OUTUBRO - 2012**

Artur Moises Gonçalves Lourenço

**MODELOS CHUVA-VAZÃO BASEADOS EM REDES NEURAIS  
ARTIFICIAIS PARA RIOS INTERMITENTES NO SEMIÁRIDO  
PARAIBANO**

Trabalho de Conclusão de Curso apresentado à Unidade Acadêmica de Ciências e Tecnologia Ambiental do Centro de Ciências e Tecnologia Agroalimentar da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Bacharel em Engenharia Ambiental.

**Orientador:** Camilo Allyson Simões Farias

**Co-orientador:** José Cleidimário Araújo Leite

**POMBAL - PB**

**OUTUBRO - 2012**

**FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA SETORIAL  
CAMPUS POMBAL/CCTA/UFCG**

L892m Lourenço, Artur Moises Gonçalves.

Modelos chuva-razão baseados em redes neurais artificiais para rios intermitentes no semiárido paraibano. / Artur Moises Gonçalves Lourenço. – Pombal: UFCG/CCTA, 2012.

46 f.

Orientador: Prof. Dr. Camilo Allyson Simões Farias.  
Coorientador: Prof. Dr. José Cleidimário Araújo Leite.

Monografia (Graduação em Engenharia Ambiental) – UFCG/  
CCTA/UACTA.

1. Recursos hídricos – Planejamento e gestão. 2. Sustentabilidade hídrica. 3. Hidroinformatica. 4. Reservatórios – Operações. 5. Vazões – Previsões. 6. Modelagem de sistemas. I. Farias, Camilo Allyson Simões. II. Leite, José Cleidimário Araújo. III. Título.

UFCG/CCTA

CDU 556.18:004.8(813.3)(043)

Artur Moises Gonçalves Lourenço

**MODELOS CHUVA-VAZÃO BASEADOS EM REDES NEURAIS  
ARTIFICIAIS PARA RIOS INTERMITENTES NO SEMIÁRIDO  
PARAIBANO**

Trabalho de Conclusão de Curso apresentado à Unidade Acadêmica de Ciências e Tecnologia Ambiental do Centro de Ciências e Tecnologia Agroalimentar da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Bacharel em Engenharia Ambiental.

Aprovado em 26/10/2012

**BANCA EXAMINADORA:**

---

Orientador – Prof. Dr. Camilo Allyson Simões Farias  
(Universidade Federal de Campina Grande - CCTA - UACTA)

---

Examinador Interno – Prof.<sup>a</sup> Dr.<sup>a</sup> Érica Cristine Medeiros Nobre Machado  
(Universidade Federal de Campina Grande - CCTA - UACTA)

---

Examinador Externo – Prof. Dr. Valterlin da Silva Santos  
(Universidade Federal de Campina Grande - CCJS - UACC)

**Para um anjo que se tornou minha Mãe, me acolheu,  
deu-me uma família e revelou o sentido da vida...**

## **Agradecimentos**

A algo supremo, criador da vida, que não poderá ser explicado ou negado seja qualquer o nível de conhecimento que o homem um dia virá a ter;

À minha família por fazer o possível e o que antes se pensava impossível para possibilitar uma ótima educação ética e científica, permitindo-me despertar o privilegiado dom de pensar e refletir;

À Universidade Federal de Campina Grande pela oportunidade para realização do curso;

Ao CNPq pela concessão da bolsa de estudos;

Aos professores da Unidade Acadêmica de Ciências e Tecnologia Ambiental - UACTA, CCTA, UFCG - Câmpus de Pombal, em especial Luís Gustavo, Andréa Maria, Valmir Cristiano, José Cleidimário, André Sobral, Ricardo Schmidt e Érica Cristine, pela transmissão do conhecimento e ensinamentos da melhor forma, mesmo com todos os problemas enfrentados;

Ao André Leandro pelos ensinamentos e por me conduzir a aplicação dos conhecimentos obtidos na universidade por meio do extensionismo nas comunidades mais necessitadas;

Ao Prof. Dr. Camilo Allyson Simões Farias, por todos os ensinamentos, paciência, profissionalismo e por ter despertado em mim a incessante sede de conhecimento;

À Coordenação do Curso de Graduação em Engenharia Ambiental, nas pessoas de Camilo e Everton, pela eficiência, atenção e amizade extensivas a todos os alunos;

À Raphaele por me ensinar o que não foi visto em nenhuma disciplina no decorrer do curso, mas que foi decisivo para que eu conseguisse chegar até aqui, amar e ser amado;

Aos meus colegas da 1.<sup>a</sup> turma de Engenharia Ambiental da UFCG pelo convívio, lições e amizades durante essa trajetória;

A todos que contribuíram de alguma forma para que eu chegasse até aqui, o meu muito obrigado.

## Sumário

|   |             |
|---|-------------|
| <b>Agradecimentos</b> .....   | <b>iv</b>   |
| <b>Lista de Tabelas</b> .....                                       | <b>vi</b>   |
| <b>Lista de Figuras</b> .....                                       | <b>vii</b>  |
| <b>Resumo</b> .....   | <b>viii</b> |
| <b>Abstract</b> .....   | <b>ix</b>   |
| <b>1. Introdução</b> .....  | <b>10</b>   |
| <b>2. Revisão Bibliográfica</b> .....                               | <b>13</b>   |
| 2.1. Estimativa de Vazão .....                                      | 13          |
| 2.2. Redes Neurais Artificiais.....                                 | 13          |
| 2.2.1. Redes Neurais Biológicas .....                               | 13          |
| 2.2.2. Redes Neurais Artificiais .....                              | 14          |
| 2.2.3. Histórico .....  | 14          |
| 2.2.4. Vantagens das RNA.....                                       | 15          |
| 2.2.5. Desvantagens das RNA .....                                   | 16          |
| 2.2.6. Aplicações das RNA.....                                      | 17          |
| <b>3. Desenvolvimento</b> .....                                     | <b>18</b>   |
| 3.1. Descrição da Área de Estudo .....                              | 18          |
| 3.1.1. Bacia Hidrográfica do Rio Piancó.....                        | 18          |
| 3.1.2. Sistema Coremas – Mãe d'Água.....                            | 20          |
| 3.2. Modelos Chuva-Vazão.....                                       | 22          |
| 3.2.1. Modelos de Baseados em RNA .....                             | 22          |
| 3.2.1.1. Coleta do Conjunto de Dados do Sistema .....               | 24          |
| 3.2.1.2. Pré-Processamento dos Dados de Entrada das RNA .....       | 25          |
| 3.2.1.3. Arquitetura e Topologia das Redes Neurais Artificiais..... | 26          |
| 3.2.1.4. Funções de Ativação .....                                  | 28          |
| 3.2.1.5. Calibração dos modelos de RNA.....                         | 29          |
| 3.2.2. Modelos Baseados em Regressão Linear Múltipla .....          | 30          |
| 3.3. Avaliação do Desempenho dos Modelos.....                       | 32          |
| <b>4. Resultados e Discussão</b> .....                              | <b>34</b>   |
| 4.1. Modelo RNA#1.....  | 34          |
| 4.2. Modelo RNA#2 e Modelo Integrado RNA#1+RNA#2.....               | 34          |
| 4.3. Modelos RLM e RLM+RNA#1 .....                                  | 37          |
| <b>5. Conclusão</b> .....   | <b>40</b>   |
| <b>6. Recomendações para Trabalhos Futuros</b> .....                | <b>42</b>   |
| <b>7. Referencias Bibliográficas</b> .....                          | <b>43</b>   |

## Lista de Tabelas

|  |    |
|--|----|
| <b>Tabela 1</b> - Características fisiográficas da Bacia do Rio Piancó.....                                  | 18 |
| <b>Tabela 2</b> - Postos e períodos utilizados .....   | 24 |
| <b>Tabela 3</b> - Valores de autocorrelação da vazão para os dados observados.....                           | 25 |
| <b>Tabela 4</b> - Valores de correlação entre vazão e precipitação para os dados.....                        | 26 |
| <b>Tabela 5</b> - Porcentagem de acertos do modelo de RNA#1 para ocorrência de vazões.<br>.....              | 34 |
| <b>Tabela 6</b> - Resultados para os conjuntos de calibração e teste dos modelos de RNA.<br>.....            | 35 |
| <b>Tabela 7</b> - Resultados para os conjuntos de calibração e teste para os modelos RLM<br>e RLM+RNA1. .... | 38 |

## Lista de Figuras

|  |    |
|--|----|
| <b>Figura 1</b> - Localização da Bacia Hidrográfica do Rio Piancó.....   | 19 |
| <b>Figura 2</b> - Registro da cheia do Rio Piancó que afetou a população da cidade de Pombal – PB residente na várzea do rio. ....   | 20 |
| <b>Figura 3</b> - Imagem de satélite dos reservatórios Coremas - Mãe d'Água.....   | 21 |
| <b>Figura 4</b> - Canal da Redenção, à esquerda, e a barragem do açude Mãe d'Água, à direita.....  | 22 |
| <b>Figura 5</b> – Fluxograma de funcionamento dos modelos de RNA. ....   | 23 |
| <b>Figura 6</b> - Localização dos postos utilizados na Bacia do Rio Piancó.....  | 25 |
| <b>Figura 7</b> - Detalhe de um neurônio. ....   | 27 |
| <b>Figura 8</b> - Topologia das RNA. ....  | 28 |
| <b>Figura 9</b> - Fluxograma do funcionamento dos modelos RLM e RLM+RNA#1. ....  | 31 |
| <b>Figura 10</b> - Comparação entre estimativas diárias de vazão obtidas com o modelo integrado RNA#1+RNA#2 e os valores observados no posto Piancó durante o período de testes (1987). .... | 36 |
| <b>Figura 11</b> - Comparação entre estimativas diárias de vazão obtidas com o modelo RNA#2 e os valores observados no posto Piancó durante o período de testes (1987).....                  | 37 |
| <b>Figura 12</b> - Comparação entre estimativas diárias de vazão obtidas com o modelo RLM e os valores observados no posto Piancó durante o período de testes (1987). ....                   | 39 |
| <b>Figura 13</b> - Comparação entre estimativas diárias de vazão obtidas com o modelo RLM+RNA#1 e os valores observados no posto Piancó durante o período de testes (1987).....              | 39 |

## Resumo

ARTUR MOISES GONÇALVES LOURENÇO. **Modelos Chuva-Vazão Baseados em Redes Neurais Artificiais para Rios Intermitentes no Semiárido Paraibano.**

Pombal - PB, Centro de Ciências e Tecnologia Agroalimentar, UFCG, outubro de 2012. 46 p.il. Trabalho de Graduação. Curso de Engenharia Ambiental. Orientador: Prof. Dr. Camilo Allyson Simões Farias.

Este trabalho tem como objetivo principal o desenvolvimento e a análise de modelos baseados em Redes Neurais Artificiais (RNA) para estimativa diária de vazões na Bacia do Rio Piancó, semiárido paraibano. O princípio básico dos modelos propostos consiste em estimar vazões diárias com base em valores passados de vazão e precipitação. Modelos chuva-vazão são essenciais não somente para mitigação dos impactos das incertezas climáticas, mas também por contribuírem no conhecimento integrado da climatologia e hidrologia de uma determinada região. Regiões semiáridas sofrem periodicamente com eventos de secas e, paradoxalmente, com inundações que afetam plantações, vilarejos rurais e bairros de populações carentes de cidades de médio e pequeno porte, comprometendo o seu desenvolvimento social e econômico. Esses eventos extremos podem ser mitigados por meio da operação adequada dos reservatórios existentes, sendo que, para isso, uma estimativa de vazão confiável é primordial. Os modelos de RNA propostos apresentaram resultados promissores, indicando um grande potencial para estimativa de vazão diária. Espera-se que estes modelos possam ser utilizados num sistema de proteção contra os efeitos de secas e cheias, de modo que possam incentivar o manejo eficiente dos recursos hídricos existentes na região, contribuindo para minimização de conflitos sociais, econômicos e ambientais.

**Palavras-chave:** Inteligência artificial, estimativa diária de vazões, ocorrência de vazões.

## Abstract

ARTUR MOISES GONÇALVES LOURENÇO. **Rainfall-Runoff Models Based on Artificial Neural Networks for Intermittent Rivers in Semiarid Paraíba, Brazil.**

Pombal - PB, Center for Agri-food Science and Technology, UFCG, october 2012. 46 p.il. Monograph. Environmental Engineering Course. Supervisor: Prof.Camilo Allyson Simões Farias, Dr. Eng.

This work aims to develop Artificial Neural Networks (ANN) models in order to estimate daily streamflows in *Piancó* River Basin, which is located in a semiarid region of *Paraíba*, Brazil. The basic principle of the proposed models consists of estimating daily streamflows based on past values of streamflow and precipitation. Rainfall-runoff models are essential for mitigating the impacts of climatic uncertainties and also for enabling an integrated knowledge of the regional climatology and hydrology. Semiarid areas suffer periodically from drought events and, paradoxically, with floods, that affect crops, rural villages, and poor neighborhoods of medium and small cities. This situation limits the social and economic development of that region. Extreme events can have their effects mitigated through the proper operation of existing reservoirs and, for that, a reliable prediction of streamflows is fundamental. The proposed ANN models were shown to be very efficient for the estimation of daily streamflows. The model is expected to be used in a drought and flood damage reduction system so that it can encourage the efficient management of existing water resources in that region and contribute to the minimization of social, economic and environmental conflicts.

**Key-words:** Artificial intelligence, daily streamflow estimation, streamflow occurrence.

## 1. Introdução

O crescimento populacional sem qualquer planejamento se reflete na crise ambiental vista diariamente nos meios de comunicação em forma de notícias. Neste espaço de tempo em que o homem habita a Terra, que pode considerado pequeno em uma escala geológica, o mesmo vem acarretando diversos impactos negativos ao meio ambiente devido a exploração irracional dos recursos naturais, em especial aos recursos hídricos, que são primordiais para a vida. Não somente o avanço no estágio de degradação e a maior demanda por estes recursos, tornando-os de precária qualidade e pouca quantidade, vêm se desenvolvendo, mas também o avanço tecnológico, que traz consigo ferramentas que fortalecem e dão alento para o desenvolvimento de estudos sobre o gerenciamento dos recursos hídricos.

Sabe-se que a maior parte da superfície do planeta Terra é composta de água, mas apenas cerca de 2,7% desta água é considerada doce. Ainda assim, cerca de 99% desta mesma água está congelada nos polos ou são águas subterrâneas de difícil acesso (UNESCO, 1998). Unindo tudo isso com a má distribuição da água na superfície do planeta Terra, com a concentração populacional em áreas de escassez de água e com fenômenos como *El Niño* e *La Nina*, que são intensificados pelo aquecimento global e que mudam totalmente o regime pluviométrico das regiões, se torna imprescindível a manutenção e o manejo eficiente deste bem a fim de mitigar as consequências das ações do homem e alcançar um desenvolvimento compatível com a capacidade de suporte do meio ambiente, contribuindo para a chamada sustentabilidade.

Em regiões semiáridas, como é o caso da maior parte do Nordeste do Brasil, a situação se agrava ainda mais tendo em vista as chuvas irregulares, as altas taxas de evaporação e os baixos índices pluviométricos. A região sertaneja do estado da Paraíba, em particular, sofre com frequentes secas, que têm seus efeitos intensificados pela crescente demanda hídrica e conseqüente geração de conflitos entre os múltiplos usuários da água.

O sertão paraibano está inserido no conhecido Polígono das Secas, uma área de aproximadamente um milhão de metros quadrados caracterizada por demasiados períodos de seca. Por outro lado, o sertão paraibano também sofre com problemas relacionados às cheias.

Segundo Ab'Saber (1999), o perfil longitudinal dos rios que drenam vastas extensões de colinas sertanejas é extremamente raso e tangente ao chamado perfil de equilíbrio. Disso resulta que, em anos de pluviosidade alta, as grandes chuvas, extensivas a imensas áreas dos sertões secos, podem provocar aumento excessivo do volume d'água dos rios de longo ou médio curso, pressionando os setores do baixo vale por meio de transbordamentos catastróficos.

Para Ab'Saber (1999), as pequenas bacias torrenciais que saem dos bordos das chapadas, da cimeira dos maciços antigos e dos brejos de todos os tipos são alimentadas por precipitações que acrescentam importantes volumes d'água aos rios sertanejos. Desta forma, as planícies inundáveis dos baixos vales dos rios regionais, como é o caso do vale do Rio Piancó – principal rio que corta parte do sertão paraibano –, têm seu espaço quase totalmente afetado pelo extravasamento das águas fluviais. Após os volumes destes rios serem incrementados com diferentes cursos d'água que recebem ao longo do seu percurso, as inundações afetam plantações e habitações rurais dispersas, vilarejos de fundo de vale e bairros de populações carentes das cidades de médio e pequeno porte. A população mais afetada é a parcela mais pobre que está localizada geralmente em sítios inadequados na periferia das cidades ou em residências localizadas nas margens do rio.

Entre as várias medidas possíveis para minimização dos efeitos destes eventos extremos, a definição e implantação de regras "ótimas" de operação de sistemas de reservatórios para minimização dos prejuízos, tanto econômicos quanto ambientais e sociais, é uma das ações mais promissoras. Esta forma de convivência com situações extremas requer um sistema de estimativa de vazões confiável, que seja capaz de estimar com uma precisão equiparada às decisões que precisam ser tomadas.

As Redes Neurais Artificiais (RNA) são ferramentas capazes de extrair modelos e detectar tendências que são muito complexas para serem percebidas por humanos ou outras técnicas computacionais. Em vez de usar uma abordagem algorítmica, as RNA processam a informação de forma similar ao sistema nervoso biológico. Elas possuem um grande número de elementos ligados que trabalham em paralelo com o objetivo de solucionar um problema específico. As RNA "aprendem" a partir de exemplos selecionados e são muito eficazes para solução de sistemas não-

lineares, na adaptação a circunstâncias, entre outras várias vantagens (Haykin, 1999; Farias *et al.*, 2006; Farias, 2009).

O fato de o Rio Piancó ser intermitente é considerado mais uma dificuldade para a estimativa diária de vazões nesta região, pois além de se trabalhar com um grande volume de dados diários, estes dados possuem grande quantidade de valores zeros, ou seja, dias em que não ocorreram vazões. A existência de muitos valores nulos prejudica o mapeamento de dados de entrada e saída durante a calibração de modelos hidrológicos para esta região.

Para contornar este problema, um modelo para estimar a ocorrência de vazão baseado em RNA foi proposto. O modelo de ocorrência indicava a ocorrência de vazão no dia, para só então ser aplicado outro modelo, também baseado em RNA, que pudesse fazer a estimativa diária desta vazão. Desta forma este trabalho tem como principal objetivo estimar vazões diárias em regiões semiáridas e teve como estudo de caso o Rio Piancó, localizado no sertão paraibano.

## **2. Revisão Bibliográfica**

### **2.1. Estimativa de Vazão**

Modelos de estimativa de vazão confiáveis são de fundamental importância para o planejamento e gerenciamento adequado de sistemas hídricos. Os modelos podem ser de curto (e.g., horário ou diário), médio (e.g., mensal ou sazonal) ou longo prazo (e.g., anual). Em geral, as estimativas de curto prazo são baseadas em modelos estatísticos ou modelos físicos, que se utilizam da relação entre chuva e vazão (Loucks *et al.*, 1981; Lettenmaier & Wood, 1993; Nandalal *et al.*, 1981).

Os modelos estatísticos tradicionais, como o de Box-Jenkins (Box e Jenkins, 1976), modelos de auto-regressão linear (AR), média móvel (MA) e auto-regressivo de média móvel (ARMA), são utilizados para previsão de séries temporais e geralmente pressupõem relações lineares entre as variáveis envolvidas, o que limita a sua aplicação para um conjunto de dados com características não-lineares, como é o caso da estimativa de vazões.

Os modelos físicos, como a exemplo do SSARR – *Streamflow Synthesis and Reservoir Regulation* (US Army Engineer Division, 1972) e SMAP – *Soil Moisture Accounting Procedure* (Lopes *et al.*, 1982), possuem formulações matemáticas que tentam modelar o comportamento do ciclo hidrológico. Nos últimos anos, a comunidade científica tem se focado no desenvolvimento de sistemas de estimativa de vazões baseados em modelos hidrológicos alimentados por previsões de chuva obtidas com modelos numéricos de tempo (Cardoso *et al.*, 2008; Cardoso *et al.*, 2009). Esta estratégia vem sendo adotada em diversos locais e tem sido objeto de diversos artigos na literatura (Boughton e Chiew, 2007; Littlewood *et al.*, 2007; Collischonn *et al.*, 2005).

### **2.2. Redes Neurais Artificiais**

#### **2.2.1. Redes Neurais Biológicas**

O sistema nervoso humano contém aproximadamente 100 bilhões de células fundamentais chamadas neurônios. Este grupo de células conectadas forma a complexa rede responsável pelo funcionamento do nosso organismo. As conexões entre os neurônios são mediadas por sinapses, que são os espaços funcionais que

transmitem impulsos eletroquímicos capazes de estimular ou inibir ações como emoção, pensamento, cognição etc. (Haykin, 1999; Gil, 2002; Farias, 2009).

### **2.2.2. Redes Neurais Artificiais**

De acordo com Haykin (1999), uma rede neural artificial pode ser definida como um conjunto de unidades de processamento simples que funciona como um processador paralelamente distribuído. Estas unidades, chamadas de neurônios, são responsáveis pelo armazenamento do conhecimento experimental para sua posterior disposição.

As RNA são inspiradas no sistema nervoso biológico e, como o cérebro, elas aprendem a partir de exemplos e têm o conhecimento adquirido armazenado nas conexões entre os neurônios (Demuth *et al*, 2012).

### **2.2.3. Histórico**

As primeiras ideias sobre cognição e o uso de redes neurais como solucionador de problemas tiveram início com os estudos de Hipócrates (460-379 a.C.). Entretanto, somente em 1943, McCulloch e Pitts sugeriram a construção de uma máquina computacional baseada no cérebro humano (Haykin, 1999).

Os pesquisadores não obtiveram muito sucesso até 1949, quando Donald Hebb escreveu o livro “*The Organization of Behavior: A Neuropsychological Theory*”, no qual propôs que o condicionamento psicológico seria uma propriedade individual dos neurônios. A partir de um ponto de vista neurobiológico, ele sugeriu uma regra específica de aprendizagem para os neurônios, que foi utilizada por pesquisadores e começou a ser aplicada em modelos computacionais (Hebb, 1949; Haykin, 1999).

De acordo com Haykin (1999), o primeiro neurocomputador que obteve sucesso foi criado em 1958 por Frank Rosenblatt. Este neurocomputador ficou conhecido como *perceptron* e tinha a capacidade de classificar conjuntos linearmente separáveis. Em 1960, Widrow e Hoff idealizaram um neurônio artificial baseado no modelo de McCulloch e Pitts (1943). Este modelo, conhecido como ADALINE, foi muito importante porque introduziu o algoritmo do mínimo quadrado médio (LMS, do inglês *least-mean-square*), uma regra de aprendizagem utilizada até os dias atuais.

A publicação “*Perceptrons*” em 1969, de Minsky e Papert, reduziu o interesse dos cientistas em torno das RNA. Minsky e Papert (1969) provaram que o modelo de Rosenblatt não era capaz de resolver vários problemas devido às restrições de representação.

Rumelhart *et al.* (1986) melhoraram a ideia de *perceptron* com a criação do algoritmo de retropropagação, um eficiente método para resolução de vários tipos de problemas, tais como: reconhecimento de fala, compreensão de imagens, previsão de séries temporais etc. O sucesso obtido por este algoritmo intensificou as pesquisas sobre RNA e, atualmente, várias universidades ao redor do mundo possuem centros de pesquisas e programas educacionais voltados para este campo de estudo (Rumelhart *et al.*, 1986; Haykin, 1999).

#### **2.2.4. Vantagens das RNA**

Existem muitos benefícios do uso de RNA. Algumas destas vantagens são:

- As RNA têm capacidade de adaptação de acordo com as mudanças ambientais, *i.e.*, elas podem ser re-treinadas para se adaptar a novas circunstâncias. Uma RNA pode inclusive ser projetada para se ajustar em tempo real;
- Uma vez que cada neurônio é potencialmente afetado pela atividade dos outros neurônios da rede, pode-se dizer que as RNA tratam a informação contextual naturalmente;
- As RNA podem extrair modelos e efetivamente generalizar o mapeamento de valores de entrada e saída;
- As RNA são capazes de extrair as mais complexas tendências não-lineares existentes entre as variáveis envolvidas.

### 2.2.5. Desvantagens das RNA

A seguir algumas desvantagens e limitações quanto o uso das RNA:

- O treinamento das RNA pode ser demorado dependendo do tipo de aplicação e/ou do tamanho do volume de dados, em alguns casos pode levar horas ou até dias;
- É necessário computadores com *hardwares* de tecnologia consideravelmente avançada para realizar o treinamento da RNA com mais velocidade;
- Há uma necessidade de uma grande séria histórica de dados para poderem ser aplicados à rede;
- Deve-se fazer um pré-tratamento dos dados de entrada das RNA (e.g. normalização), de forma que devem ser cuidadosamente selecionados para que a rede receba bons exemplos e possa dispor o conhecimento adquirido de forma correta;
- Não há regras gerais para se determinar o número de dados de entrada da rede ou o número de neurônios ocultos. Em geral, esses parâmetros são estabelecidos através do critério da parcimônia e/ou tentativa-e-erro;
- As RNA têm dificuldade para fazer a extrapolação do conjunto de dados, pois como elas recebem exemplos para o seu treinamento há pouca possibilidade que a mesma produza resultados fora dos limites que foram apresentados.

### 2.2.6. Aplicações das RNA

Um vasto registro de aplicações de RNA pode ser visto na literatura. Elas são aplicadas em vários ramos científicos, tais como medicina, robótica, engenharia, finanças, segurança etc. (Haykin, 1999; Demuth e Beale, 2005). Na área de recursos hídricos, as RNA são principalmente aplicadas para os seguintes propósitos:

- Estimativa dos valores de variáveis hidrológicas, tais como chuva, vazão, evapotranspiração, níveis freáticos etc;
- Geração de séries estocásticas;
- Derivação de regras para operação de sistemas hídricos; e
- Previsão de valores de variáveis que indicam a qualidade da água.

Algumas destas aplicações podem ser encontradas nos trabalhos de Govindaraju e Rao (2000), Coulibaly *et al.* (2001), Jeong e Kim (2005), Nayak *et al.* (2006), Farias *et al.* (2006), Farias (2009) e Alves *et al.* (2007).

### 3. Desenvolvimento

#### 3.1. Descrição da Área de Estudo

##### 3.1.1. Bacia Hidrográfica do Rio Piancó

A região estudada é a Bacia Hidrográfica do Rio Piancó, uma sub-bacia pertencente à Bacia Hidrográfica do Rio Piranhas-Açu, que engloba parte dos estados da Paraíba e Rio Grande do Norte. Esta bacia está localizada no extremo sudoeste da Paraíba, totalmente inserida na mesorregião do sertão paraibano, e é a maior em extensão territorial do estado, com 9.242,76 km<sup>2</sup> e um total de 271.255 habitantes (PERH/PB, 2006).

A região possui pouca oferta de água subterrânea, com predominância de formações cristalinas. A área conta com uma temperatura média anual de 26°C e precipitação média anual de aproximadamente 821 mm, sendo que 60% deste valor concentra-se entre os meses de fevereiro e abril, período chuvoso. A evaporação potencial anual é aproximadamente 2300 mm, com as maiores taxas mensais no período de setembro a dezembro (Lima, 2004). A vegetação natural da bacia, do Bioma Caatinga, quando não explorada racionalmente – como acontece no perímetro –, pode causar o assoreamento de rios e reservatórios. Dos solos da bacia, 28,1% são passíveis de utilização, entretanto, apenas 2,8% dessa área está sendo explorado, geralmente por pequenas propriedades e projetos públicos de irrigação.

Os principais parâmetros que definem as características fisiográficas da Bacia Hidrográfica do Rio Piancó são apresentados na Tabela 1.

**Tabela 1** - Características fisiográficas da Bacia do Rio Piancó.

|                            |                          |
|----------------------------|--------------------------|
| Área de Drenagem           | 9.232,50 km <sup>2</sup> |
| Coeficiente de Compacidade | 1,63                     |
| Densidade de Drenagem      | 0,43 km/km <sup>2</sup>  |
| Fator de Forma             | 0,39                     |
| Perímetro                  | 560,50 km                |

O Rio Piancó tem sua nascente na Serra do Umbuzeiro, município de Santa Inês, e segue até ser barrado pelo sistema de reservatórios Coremas - Mãe d'Água, onde é perenizado, até desaguar no Rio Piranhas, na cidade de Pombal - PB. Durante este percurso, seu volume é incrementado com diferentes cursos d'água que recebe em seu leito. De acordo com o Plano Diretor de Recursos Hídricos do Estado da Paraíba – PDRH/PB (SCIENTEC, 1997), a Bacia do Rio Piancó conta com 1336 açudes, sendo que 90,6% deles caracterizam pequenos reservatórios. Isso faz com que o escoamento superficial seja algo preocupante, no tocante à demanda e disponibilidade hídrica do sistema. Na Figura 1 mostra-se a localização da referida bacia.



**Figura 1** - Localização da Bacia Hidrográfica do Rio Piancó (Fonte: Autor).

O município de Pombal, localizado no sertão da Paraíba, encontra-se em crescente desenvolvimento, devido, principalmente, à instalação de um câmpus universitário da Universidade Federal de Campina Grande. O sítio urbano da cidade está encravado nas várzeas do Rio Piancó e, recentemente, no ano de 2008, a cidade sofreu com inundações que não foram evitadas mesmo com a existência dos

reservatórios Coremas - Mãe d'Água, que têm como uma de suas finalidades o controle de cheias. Neste ocorrido, as comunidades carentes localizadas às margens do Rio Piancó foram as mais afetadas. Estas comunidades ribeirinhas têm nestes locais sua forma de subsistência por meio da agricultura familiar ou ainda apenas por ali terem seu lugar de residência. Na Figura 2 apresentam-se fotografias do episódio de cheia observado no município de Pombal.



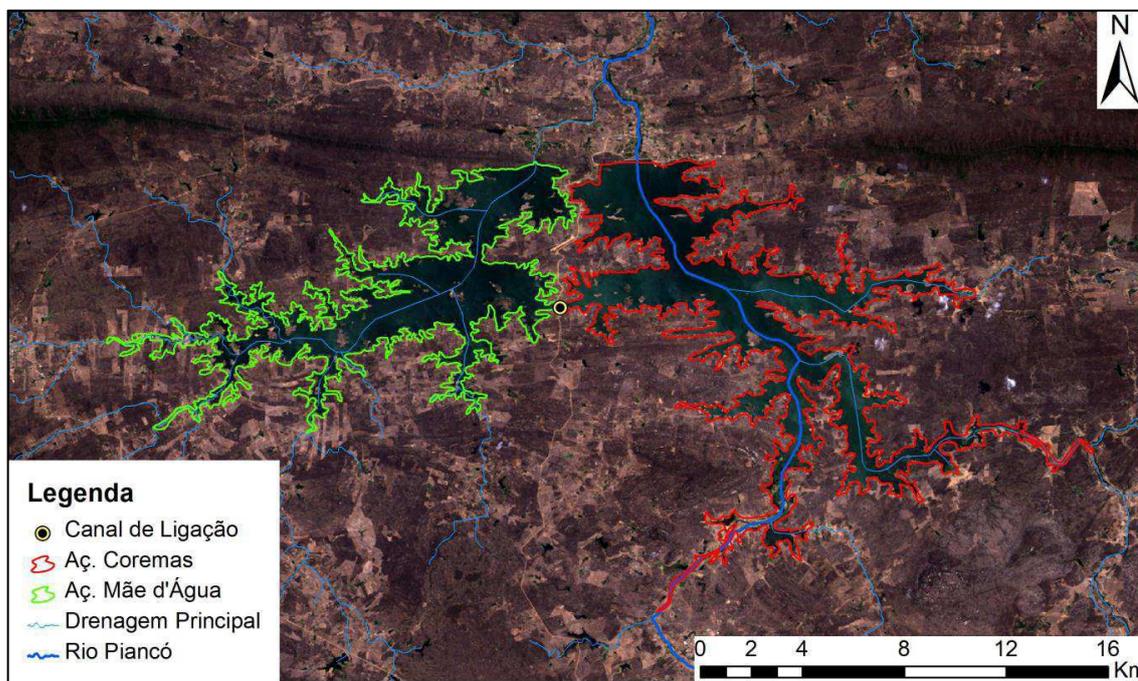
**Figura 2** - Registro da cheia do Rio Piancó que afetou a população da cidade de Pombal – PB residente na várzea do rio. (Fonte: Autor)

### 3.1.2. Sistema Coremas – Mãe d'Água

O sistema de reservatórios Coremas - Mãe d'Água tem capacidade de armazenamento de 1,358 bilhões de metros cúbicos e possui os seguintes usos: perenização de vales, controle de cheias, irrigação, piscicultura, aproveitamento de culturas nas áreas de montante, abastecimento de água para as populações urbanas e rurais e geração de energia.

O sistema de reservatórios é formado pelos açudes Estevam Marinho (Coremas) e Mãe d'Água, construídos nas décadas de 30 e 50, respectivamente. Eles são interligados por um canal com capacidade máxima de vazão igual a 12

m<sup>3</sup>/s. Na cota máxima, os reservatórios formam um lago com superfície líquida de  $115,6 \times 10^6 \text{ m}^2$  (Lima, 2004). Na Figura 3 apresenta-se uma imagem do satélite Landsat-5, sensor TM, composição colorida R3G2B1, imageada em 23 de agosto de 2011, na qual é possível a visualização dos dois reservatórios.



**Figura 3** - Imagem de satélite dos reservatórios Coremas - Mãe d'Água (Fonte: Autor).

O reservatório Coremas tem uma capacidade máxima de 720 milhões de metros cúbicos. Seus principais tributários são o Rio Piancó e o Rio Emas, que juntos são responsáveis por 80,2% da afluência do sistema. Ele conta com uma usina hidroelétrica com capacidade para produzir 3,52 MW de potência para uma vazão máxima turbinada de 7,3 m<sup>3</sup>/s. O reservatório Mãe d'Água tem uma capacidade de 638,7 milhões de metros cúbicos. Seu principal tributário é o Rio Aguiar, responsável por 19,8% da afluência do sistema. Deste reservatório, parte o Canal da Redenção, que hoje é responsável pelo suprimento das demandas de irrigação das Várzeas de Sousa (5000 ha), localizadas entre os municípios de Sousa - PB e Aparecida - PB.

Na Figura 4 são apresentadas imagens do Canal da Redenção e da barragem do açude Mãe d'Água.



**Figura 4** - Canal da Redenção, à esquerda, e a barragem do açude Mãe d'Água, à direita (Fonte: Autor).

## **3.2. Modelos Chuva-Vazão**

### **3.2.1. Modelos de Baseados em RNA**

A necessidade de modelos do tipo chuva-vazão que sejam confiáveis é de extrema valia para o gerenciamento de um sistema hídrico do porte e da importância do Coremas - Mãe d'Água. O fato do trecho do Rio Piancó a montante do sistema Coremas - Mãe d'Água ser intermitente dificulta o ajuste de modelos para estimativa de vazões diárias devido a quantidade de situações em que ocorrem valores nulos.

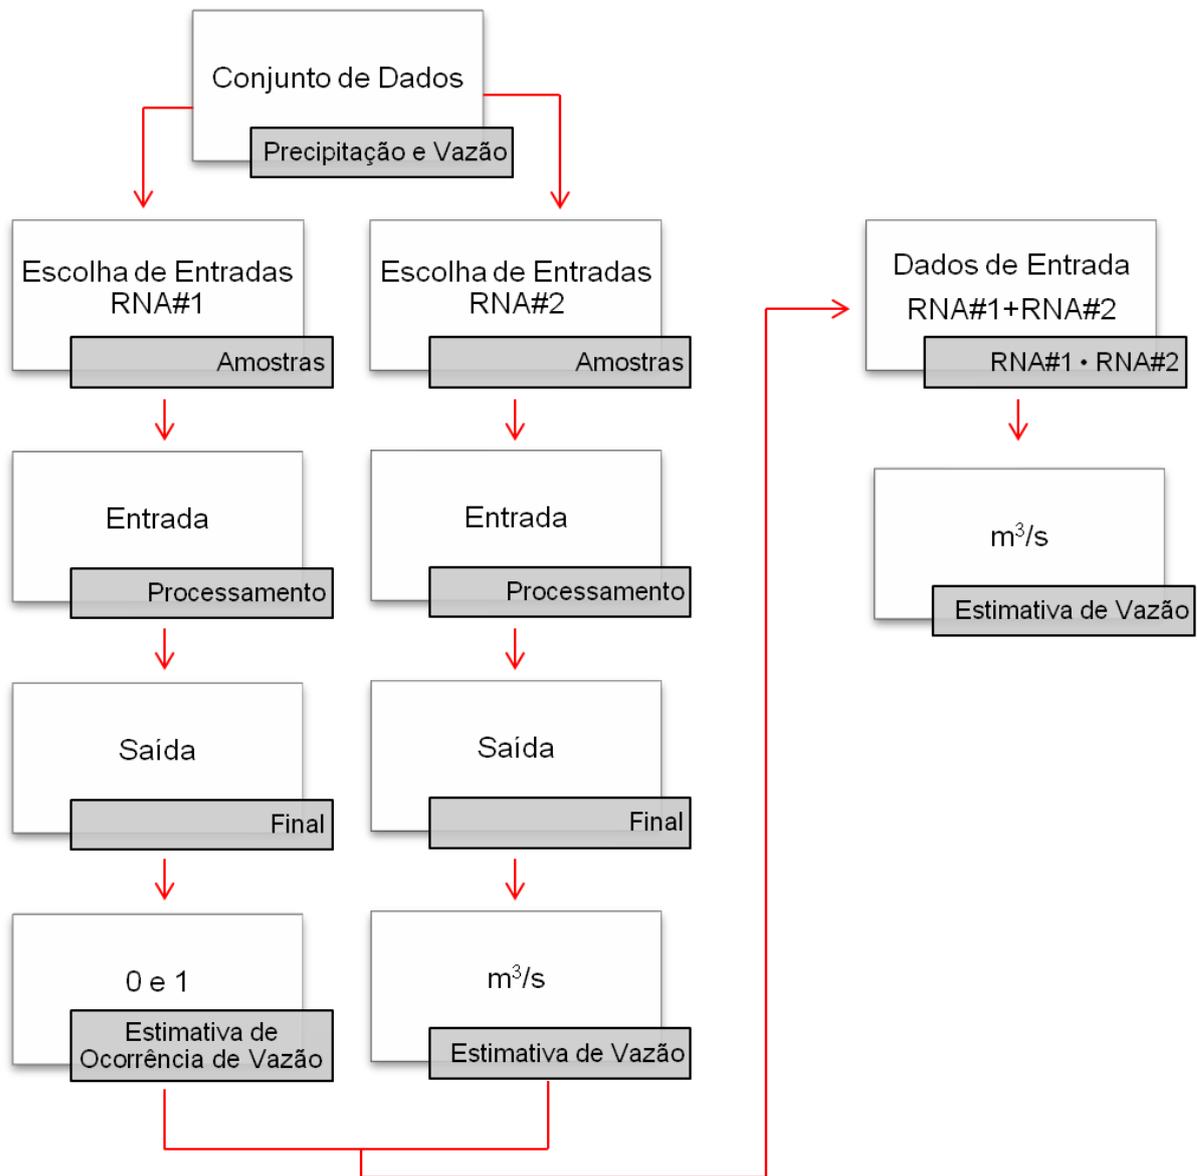
O primeiro modelo proposto de RNA (RNA#1) consiste em estimar a ocorrência de vazões diárias com base em valores de precipitações e vazões passadas. O modelo indica com valores de saída 0 (zero) e 1 (um) a não ocorrência e ocorrência de vazões, respectivamente.

O outro modelo, também baseado em RNA e aqui chamado de RNA#2, tem como objetivo estimar diretamente os valores de vazões, e não apenas a ocorrência, utilizando as mesmas entradas do modelo RNA#1. Os dois modelos de RNA podem ser integrados de forma que o modelo de RNA#2 seja apenas utilizado para estimativa quando o modelo de ocorrência RNA#1 fornecer saída igual à indicação de ocorrência de vazão, ou seja, valor igual a 1.

Este procedimento foi aplicado para evitar os vários problemas normalmente encontrados quando da calibração de modelos para estimativa de vazões em rios intermitentes, como é o caso do Rio Piancó, até ser barrado pelo sistema de

reservatórios. Os dados de vazão nesse estudo possuem muitos valores zeros, o que pode dificultar o processo de calibração de modelos chuva-vazão.

Na Figura 5 apresenta-se o fluxograma para o funcionamento dos modelos de RNA.



**Figura 5** - Fluxograma de funcionamento dos modelos de RNA.

Na literatura pode-se encontrar trabalhos em que foram usados modelos matemáticos para gerar vazões diárias de rios intermitentes, a partir de séries históricas, também usando o preceito de ocorrência ou não de vazão, porém, baseados em cadeias de Markov. Para maiores detalhes, consultar Aksoy *et al* (2000).

### 3.2.1.1. Coleta do Conjunto de Dados do Sistema

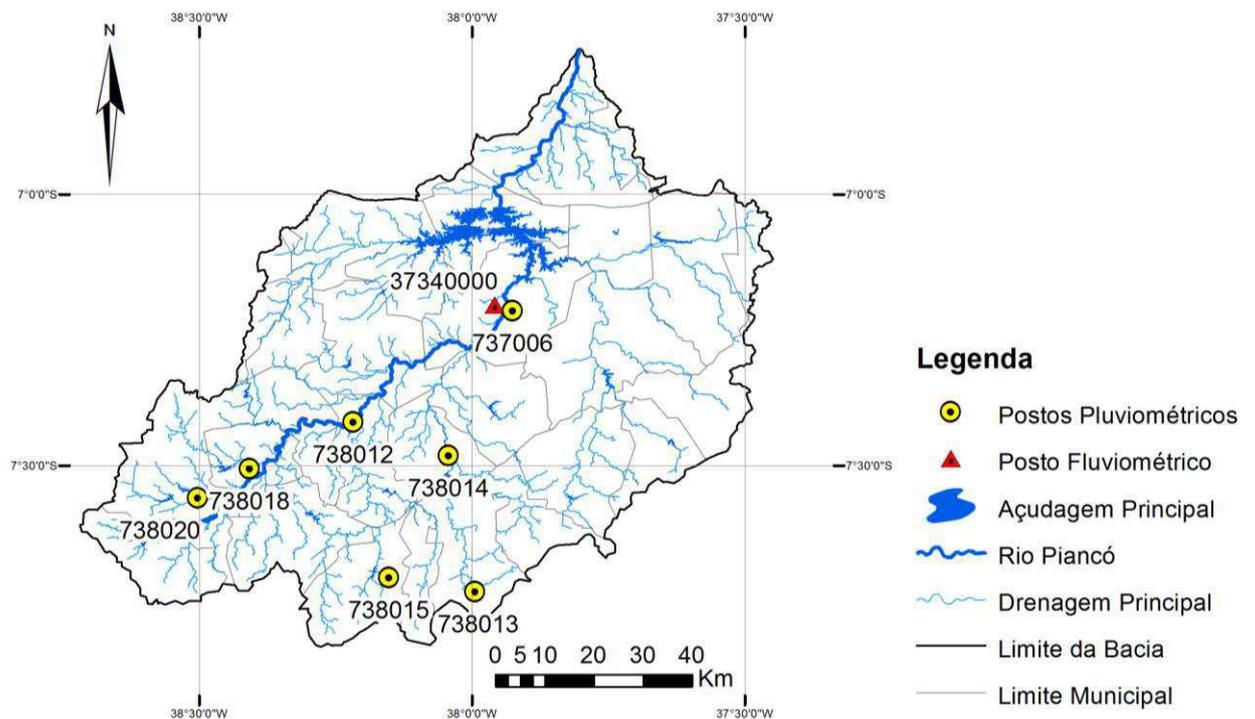
As séries de dados históricos de vazão e precipitação foram coletadas a partir do website Hidroweb, pertencente à Agência Nacional das Águas (ANA, 2012), e junto à Agência Executiva de Gestão das Águas do Estado da Paraíba (AESAs, 2012). Foram escolhidos anos que não tivessem falhas de leituras, pretendendo assim dar mais veracidade aos dados. Os anos que apresentaram características muito discrepantes em relação ao comportamento das chuvas e vazões da região também foram excluídos, tendo em vista a probabilidade de leituras errôneas e/ou problemas no sistema de banco de dados.

Na Tabela 2 apresentam-se os postos e o período de dados utilizados neste trabalho. Na Figura 6 mostra-se a localização dos postos da área de estudo com seus respectivos códigos.

**Tabela 2 - Postos e períodos utilizados**

| Tipo          | Nome            | Código   | Anos  |
|---------------|-----------------|----------|---|
| Fluviométrico | Piencó          | 37340000 | 1966, 1967, 1972, 1973, 1976, 1978, 1979, 1982, 1987. |
| Pluviométrico | Conceição       | 738020   |   |
|               | Ibiara          | 738018   |   |
|               | Nova Olinda     | 738014   |   |
|               | Princesa Isabel | 738013   |   |
|               | Piencó          | 737006   |   |
|               | Boa Ventura     | 738012   |   |
|               | Manaira         | 738015   |   |

## Localização dos Postos na Bacia do Rio Piancó



**Figura 6** - Localização dos postos utilizados na Bacia do Rio Piancó.

### 3.2.1.2. Pré-Processamento dos Dados de Entrada das RNA

Antes de iniciar a calibração das RNA, se faz necessário preparar o conjunto de dados e definir suas entradas. Esta etapa se torna muito delicada, pois é aqui que a rede receberá as amostras de dados para o seu aprendizado. A precisão e eficiência das RNA estão diretamente ligadas à precisão e veracidade dos dados observados de precipitação e vazão.

Primeiramente, fez-se uma análise estatística para a escolha das entradas das RNA. O critério escolhido consistiu em calcular as correlações entre cada conjunto de possíveis dados de entrada dos modelos (dados passados de vazão e atuais e passados de precipitação) e a vazão observada. Os valores das correlações podem ser vistos nas Tabelas 3 e 4, nas quais  $t$  indica o índice para dia;  $Q(t)$  é a vazão no dia  $t$ ; e  $P(t)$  é a precipitação no dia  $t$ .

**Tabela 3** - Valores de autocorrelação da vazão para os dados observados.

| Variáveis            | Correlação |
|----------------------|------------|
| $Q(t) \times Q(t-1)$ | 0,81       |
| $Q(t) \times Q(t-2)$ | 0,67       |

|                      |      |
|----------------------|------|
| $Q(t) \times Q(t-3)$ | 0,61 |
| $Q(t) \times Q(t-4)$ | 0,51 |
| $Q(t) \times Q(t-5)$ | 0,47 |

**Tabela 4** - Valores de correlação entre vazão e precipitação para os dados.

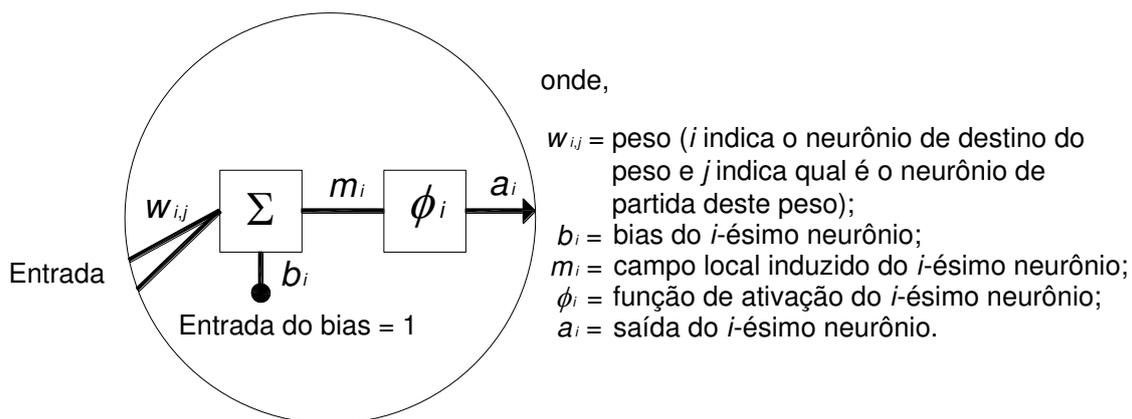
| Postos          | Correlação         |                      |                      |
|-----------------|--------------------|----------------------|----------------------|
|                 | $Q(t) \times P(t)$ | $Q(t) \times P(t-1)$ | $Q(t) \times P(t-2)$ |
| Conceição       | 0,21               | 0,28                 | 0,27                 |
| Ibiara          | 0,34               | 0,41                 | 0,36                 |
| Nova Olinda     | 0,23               | 0,32                 | 0,25                 |
| Princesa Isabel | 0,28               | 0,33                 | 0,25                 |
| Piancó          | 0,35               | 0,41                 | 0,35                 |
| Boa Ventura     | 0,29               | 0,33                 | 0,30                 |
| Manaira         | 0,14               | 0,22                 | 0,18                 |

Para os valores passados de vazão, optou-se por considerar como entrada das RNA os valores com correlação acima de 0,6, ou seja,  $Q(t)$ ,  $Q(t-1)$  e  $Q(t-2)$ . No caso dos valores de precipitação, foram escolhidos os postos e precipitações cuja correlação com os dados de vazão eram maiores ou iguais a 0,30. Esses valores foram escolhidos considerando critérios de parcimônia. Os postos e precipitações escolhidos foram: Ibiara ( $P(t)$ ,  $P(t-1)$  e  $P(t-2)$ ); Nova Olinda ( $P(t-1)$ ), Princesa Isabel ( $P(t-1)$ ), Piancó ( $P(t)$ ,  $P(t-1)$  e  $P(t-2)$ ) e Boa Ventura ( $P(t-1)$  e  $P(t-2)$ ). Sendo assim, as camadas de entrada das RNA contaram com 13 neurônios. O número de neurônios na camada oculta foi obtido a partir de um processo baseado em tentativa-e-erro.

### 3.2.1.3. Arquitetura e Topologia das Redes Neurais Artificiais

As redes utilizadas foram do tipo *perceptron* de multicamadas, do inglês *multilayer perceptron*, que neste estudo são formadas por uma camada de entrada, uma oculta e uma de saída. As redes são do tipo alimentada adiante, ou seja, o sinal é propagado para frente através da rede, camada por camada.

Na Figura 7 mostram-se os detalhes de como funciona um neurônio. Nesta rede, cada elemento do vetor de entrada está conectado a cada neurônio na camada oculta e cada elemento da camada oculta está conectado ao neurônio de saída.



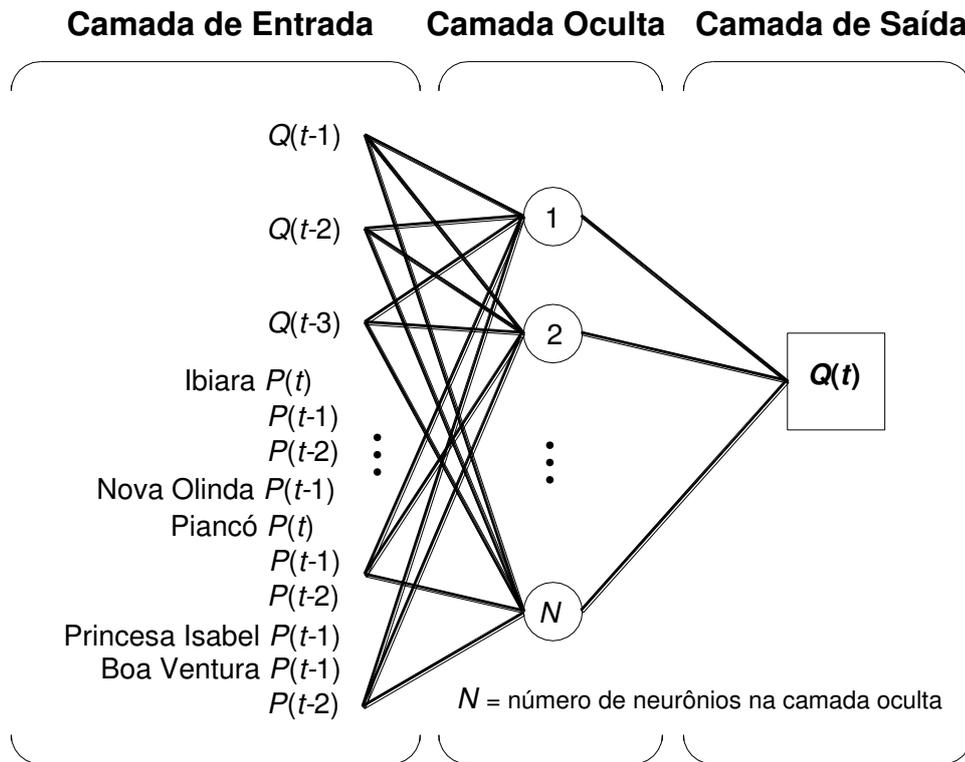
**Figura 7** – Detalhe de um neurônio.

Analisando a Figura 7, nota-se que o  $i$ -ésimo neurônio da camada oculta possui um somatório que coleta o valor de entrada multiplicado pelo peso de sua conexão ( $w_{ij}$ ) e o bias ( $b_i$ ) para formar o valor de saída ou campo local induzido ( $m_i$ ).

Cada campo local induzido é submetido a uma função de ativação ( $\phi_i$ ) para que se torne o valor de entrada do neurônio da camada de saída. O neurônio da camada de saída possui o mesmo esquema dos neurônios da camada oculta e o seu campo local induzido, depois de submetido à função de ativação, se torna a saída final da RNA.

O número de neurônios da camada oculta foi obtido pelo processo denominado tentativa-e-erro considerando a eficiência na calibração e critérios de parcimônia. Tanto a RNA#1 como a RNA#2 apresentaram os melhores resultados com o número de 5 neurônios na camada oculta.

Na Figura 8 observa-se um esquema detalhado da topologia das RNA.



**Figura 8** - Topologia das RNA.

#### 3.2.1.4. Funções de Ativação

Para relacionar as entradas e saídas das RNA são necessárias funções diferenciáveis e contínuas. Um neurônio pode usar qualquer função de transferência diferenciável para gerar suas saídas. Comumente para redes multicamadas são usados três tipos funções de transferência: *log-sigmoid*, *tan-sigmoid* e a linear. De acordo com Haykin (1999), as funções *sigmóides* são boas funções de ativação para cada neurônio devido ao seu comportamento geralmente aceitável.

Algumas regras heurísticas indicam o uso de certas funções de ativação para tipos específicos de problemas. Por exemplo, Klimasauskas (1991) sugere funções *Log-Sigmoid* para problemas de classificação que envolvem aprendizagem sobre o comportamento médio, e funções *tan-sigmoid* se o problema envolver aprendizagem sobre desvios em relação à média, tais como problemas de previsão (Zhang *et al*, 1998).

Neste estudo, funções *tan-sigmoid* e lineares foram utilizadas para os neurônios da camada oculta e da camada de saída, respectivamente.

### **3.2.1.5. Calibração dos modelos de RNA**

Os dados originais (entradas e saídas desejadas) foram convenientemente escalonados para melhorar a eficiência na calibração dos modelos de RNA. O processo de escalonamento consiste em normalizar as entradas e saídas desejadas de forma que tenham média igual a zero e desvio padrão unitário (Demuth *et al.*, 2008).

Todos os modelos de RNA foram treinados utilizando o conhecido algoritmo de retropropagação de erros, o qual tem sido utilizado com sucesso em vários campos da engenharia. Nesta aplicação, o algoritmo *Levenberg-Marquardt* (LM) foi usado para retropropagação. Uma explicação detalhada do algoritmo LM pode ser encontrada em Hagan e Menhaj (1994).

A calibração das RNA é do tipo supervisionada, ou seja, os pesos sinápticos e níveis de *bias* entre os neurônios são ajustados por meio das iterações (ou épocas) com o intuito de adequar uma série de dados de entrada a outra série de respostas conhecidas. As RNA têm sua calibração encerrada pelo processo conhecido como *Early Stopping Method* (Demuth *et al.*, 2012). Este método divide os dados de calibração em dois subconjuntos: um de treinamento e outro de validação. O subconjunto de treinamento é usado para calcular gradientes e ajustar os pesos e níveis de *bias*. O subconjunto de validação tem seus erros monitorados para evitar *overfitting* dos dados e conseqüentemente melhorar o grau de generalização da RNA. A calibração é parada quando o erro no subconjunto de validação cresce por um determinado número de iterações.

Como o critério de parada para a calibração dos modelos de RNA foi o *Early Stopping Method*, os três subconjuntos foram divididos da seguinte forma: treinamento (75% do total dos dados), validação (25% do total de dados) e teste (o ano de 1987). É importante ressaltar que os dados utilizados para o teste são totalmente independentes dos utilizados para calibração do modelo.

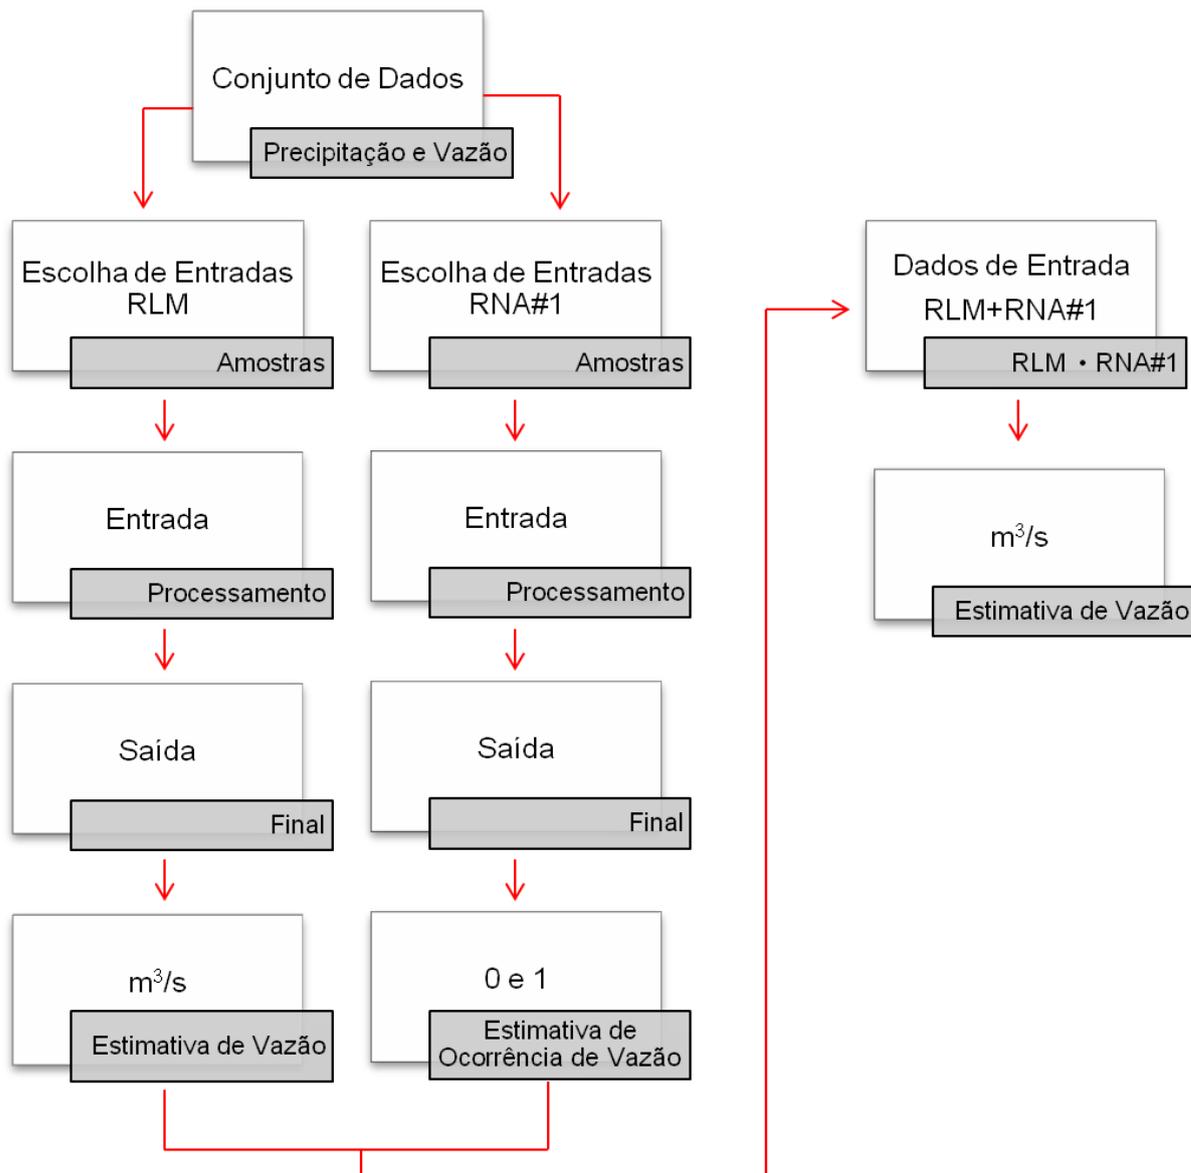
### 3.2.2. Modelos Baseados em Regressão Linear Múltipla

Foi desenvolvido um modelo para estimativa de vazões baseado em Regressão Linear Múltipla (RLM) para efeito de comparação com os modelos de RNA.

De forma sucinta (Draper e Smith, 1981), a regressão linear múltipla procura estabelecer uma relação analítica da variável  $Y$  a ser prevista, que neste caso é a vazão  $Q(t)$ , com outras  $n$  variáveis  $X_i$ , que são as variáveis independentes. Desta forma, a equação matemática resultante estima, por meio da combinação linear das variáveis independentes, que neste estudo são os valores passados de chuva e vazão.

Em um segundo momento, o modelo de RLM foi integrado ao modelo de ocorrência de vazões diárias RNA#1, gerando um novo modelo RNA#1+RLM. Esta técnica foi implementada com o fim de identificar se o modelo RLM seria beneficiado e produziria melhores resultados comparados aos do modelo de regressão sem integração, o RLM.

Na Figura 9 apresenta-se o fluxograma para o funcionamento do modelo de RLM funcionando de forma independente e integrado com o modelo RNA#1.



**Figura 9** - Fluxograma do funcionamento dos modelos RLM e RLM+RNA#1.

É importante frisar que os dados de entrada do modelo RLM são os mesmos utilizados nos modelos de RNA. Assim como os modelos de RNA, o modelo RLM foi implementado em ambiente Matlab R2012a.

### 3.3. Avaliação do Desempenho dos Modelos

O desempenho de modelos é usualmente avaliado por meio do uso de índices estatísticos. Neste trabalho foram utilizados os seguintes índices: (a) correlação, mostrado na Equação 1; (b) viés relativo, na Equação 2; e (c) eficiência de *Nash-Sutcliffe* (Equação 3).

$$r = \frac{n \sum Q_{obs}(t)Q_{cal}(t) - (\sum Q_{obs}(t))(\sum Q_{cal}(t))}{\sqrt{n(\sum Q_{obs}^2(t)) - (\sum Q_{obs}(t))^2} \sqrt{n(\sum Q_{cal}^2(t)) - (\sum Q_{cal}(t))^2}} \quad (1)$$

$$VR = \frac{\overline{Q_{cal}} - \overline{Q_{obs}}}{\overline{Q_{obs}}} \times 100\% \quad (2)$$

$$NASH = 1 - \frac{\sum(Q_{obs}(t) - Q_{cal}(t))^2}{\sum(Q_{obs}(t) - \overline{Q_{obs}})^2} \quad (3)$$

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 somatório entre  $t = 1$  e  $t = n$ .

A correlação ou coeficiente de correlação de *Pearson* mede o grau de dependência linear entre os valores calculados e observados. O viés relativo mostra se o modelo para estimativa de vazões possui uma tendência a subestimar ou superestimar as vazões observadas e o *NASH* (Nash e Sutcliffe, 1970) expressa a aderência entre as vazões calculadas e as observadas, ou seja, o nível de sobreposição dos hidrogramas observados e calculados.

Valores altos de correlação não significam, por si só, estimativas com alta precisão. Por exemplo, um sistema com um viés muito alto, mesmo que possua correlação igual à unidade ( $r=1$ ), fornecerá estimativas de vazões de baixa precisão, embora seja possível remover este viés por meio de modelos estatísticos (Farias, 2010). Um modelo perfeito de estimativa apresentaria resultados com  $r = 1$  e  $VR = 0$ .

O índice de eficiência *NASH*, que pode variar entre  $-\infty$  e 1, é comumente utilizado para expressar aderência entre vazões simuladas e observadas, sendo considerado um dos mais importantes critérios estatísticos para avaliar a precisão de

modelos hidrológicos (ASCE, 1993). Esse índice considera tanto os erros sistemáticos quanto os erros randômicos, indicando que o ajuste é cada vez melhor à medida que o seu valor aproxima-se de 1.

## 4. Resultados e Discussão

### 4.1. Modelo RNA#1

O desempenho do modelo de RNA#1 foi verificado por meio da porcentagem de acertos, que é dada pela divisão da quantidade de acertos pela quantidade total das estimativas. Os resultados para todos os conjuntos de dados podem ser vistos na Tabela 5.

**Tabela 5** - Porcentagem de acertos do modelo de RNA#1 para ocorrência de vazões.

| Conjunto de dados | Acertos (%) |
|-------------------|-------------|
| Calibração        | 98,34       |
| Teste             | 97,53       |

Os resultados obtidos na Tabela 5 foram satisfatórios, uma vez que a porcentagem de acertos do conjunto de teste foi maior que 97%.

### 4.2. Modelo RNA#2 e Modelo Integrado RNA#1+RNA#2

Na Tabela 6 apresentam-se os índices de desempenho para calibração e teste do modelo RNA#2 com e sem a integração com o modelo RNA#1. Os resultados indicam que as estimativas com os modelos baseados em RNA obtiveram um desempenho satisfatório nos valores altos de correlação e baixos níveis de viés relativo.

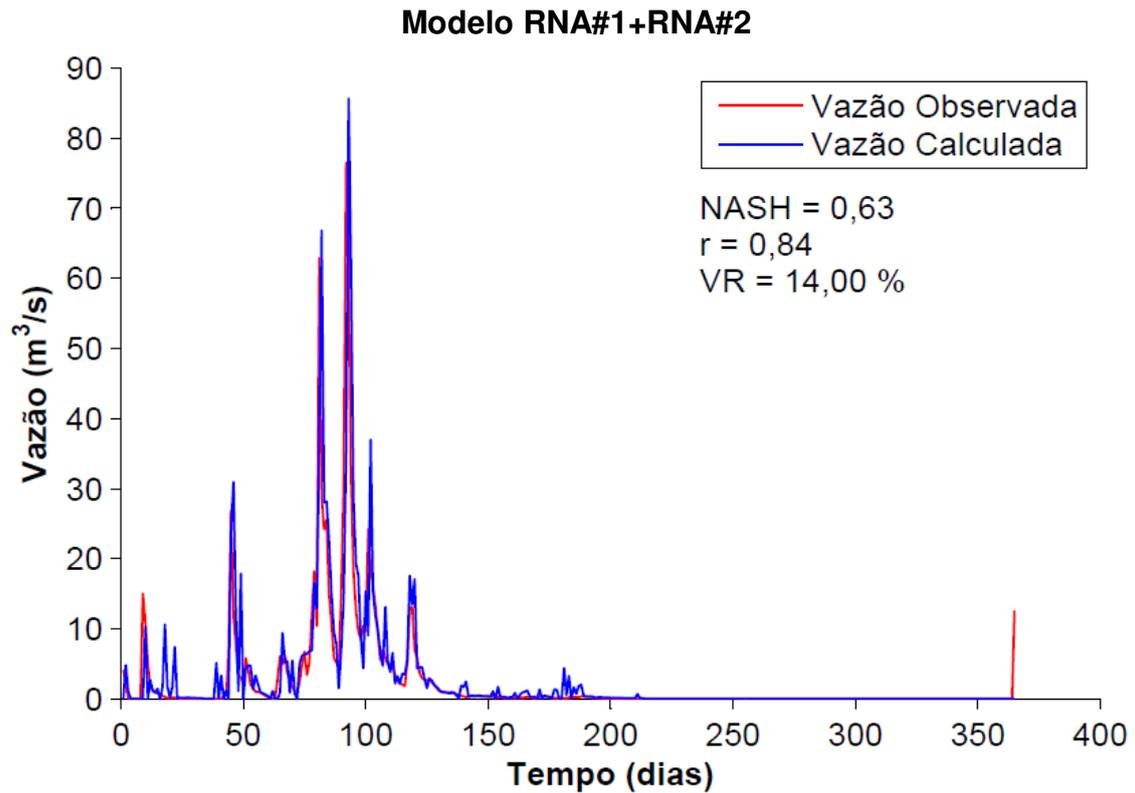
**Tabela 6** - Resultados para os conjuntos de calibração e teste dos modelos de RNA.

| Conjunto de dados | Índice      | RNA#1+RNA#2 | RNA#2   |
|-------------------|-------------|-------------|---------|
| Calibração        | <i>NASH</i> | 0,79        | 0,78    |
|                   | <i>r</i>    | 0,89        | 0,89    |
|                   | <i>VR</i>   | -0,00 %     | 3,00 %  |
| Teste             | <i>NASH</i> | 0,63        | 0,63    |
|                   | <i>r</i>    | 0,84        | 0,84    |
|                   | <i>VR</i>   | 14,00 %     | 21,00 % |

Como pode ser visto na Tabela 6, os valores de *NASH* de calibração foram superiores a 0,75 nos dois modelos, podendo-se considerar os mesmos como de boa precisão, conforme Collischonn e Tucci (2003). Para Collischonn (2001), o desempenho de um modelo é considerado adequado e eficiente se o valor de *NASH* superar 0,75, e é considerado aceitável se o valor de *NASH* fica entre 0,36 e 0,75, como observado nos resultados para o conjunto de teste.

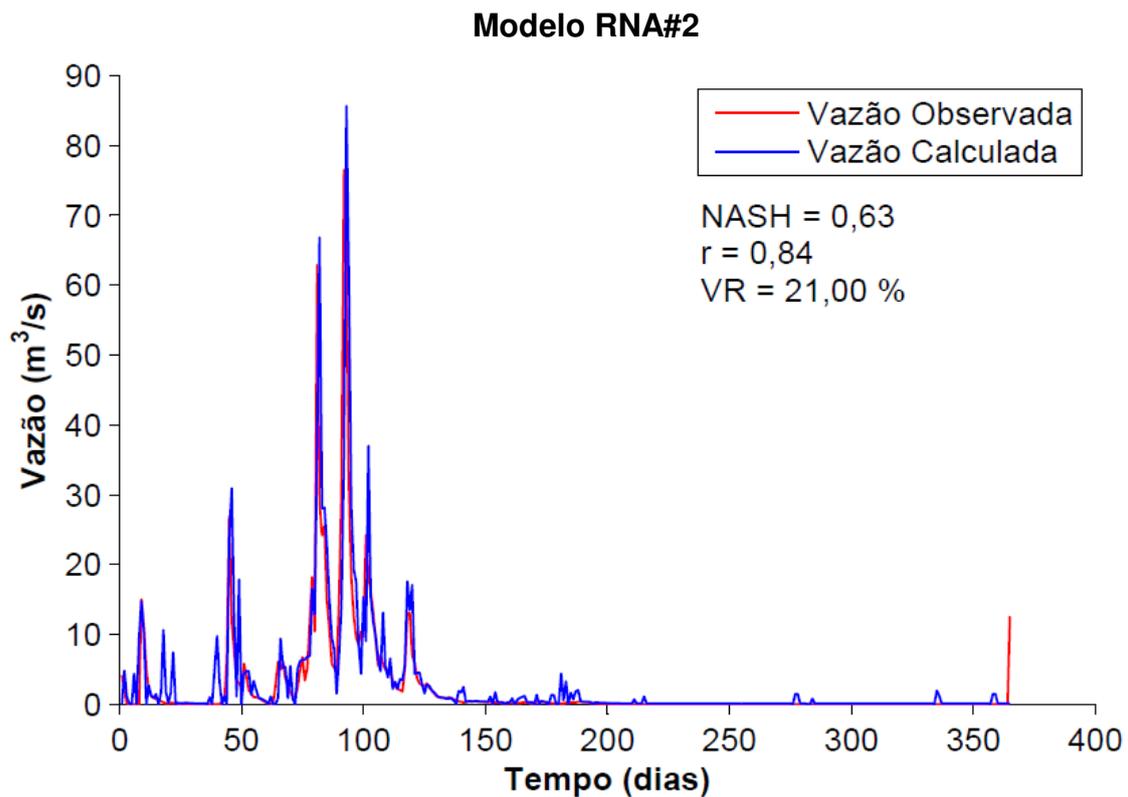
Fazendo uma análise entre o desempenho do processo de calibração do modelo integrado RNA#1+RNA#2 com o modelo RNA#2 (Tabela 6), observa-se que o primeiro obteve melhor eficiência no *NASH* e viés relativo e comportamento semelhante para o índice de correlação. Entretanto, esta melhora é considerada pequena e, portanto, pode-se dizer que os modelos apresentaram desempenhos similares. Pode-se atribuir o desempenho semelhante à capacidade das RNA, em especial da RNA#2, de adaptação às circunstâncias. O fato da integração dos modelos pode explicar o melhor resultado para o *VR*.

Na Figura 10 apresenta-se um comparativo entre as estimativas diárias de vazão obtidas com o modelo integrado RNA#1+RNA#2 e os valores observados de vazão para o posto fluviométrico investigado.



**Figura 10** - Comparação entre estimativas diárias de vazão obtidas com o modelo integrado RNA#1+RNA#2 e os valores observados no posto Piancó durante o período de testes (1987).

Na Figura 11 apresenta-se um comparativo entre as estimativas diárias de vazão obtidas com o modelo de RNA#2 e os valores observados de vazão para o posto fluviométrico investigado.



**Figura 11** - Comparação entre estimativas diárias de vazão obtidas com o modelo RNA#2 e os valores observados no posto Piancó durante o período de testes (1987).

Analisando a sobreposição dos hidrogramas calculados e observados dos modelos de RNA (Figuras 10 e 11), observa-se a grande aproximação dos mesmos no período de testes, demonstrando uma boa aderência.

#### 4.3. Modelos RLM e RLM+RNA#1

Na Tabela 7 apresentam-se os resultados dos índices de desempenho para o modelo RLM e o RLM+RNA#1.

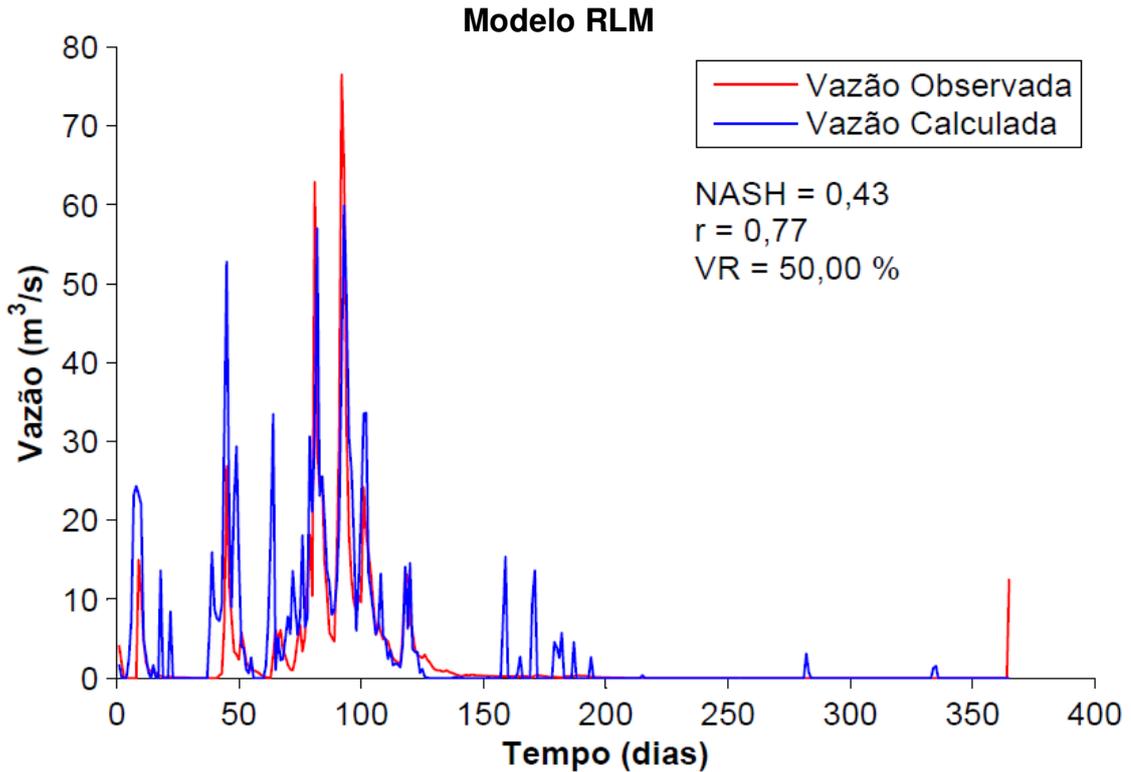
**Tabela 7** - Resultados para os conjuntos de calibração e teste para os modelos RLM e RLM+RNA1.

| Conjunto de dados | Índice      | RLM     | RLM+RNA#1 |
|-------------------|-------------|---------|-----------|
| Calibração        | <i>NASH</i> | 0,73    | 0,74      |
|                   | <i>r</i>    | 0,85    | 0,86      |
|                   | <i>VR</i>   | 13,00 % | 7,00 %    |
| Teste             | <i>NASH</i> | 0,43    | 0,52      |
|                   | <i>r</i>    | 0,77    | 0,80      |
|                   | <i>VR</i>   | 50,00 % | 35,00 %   |

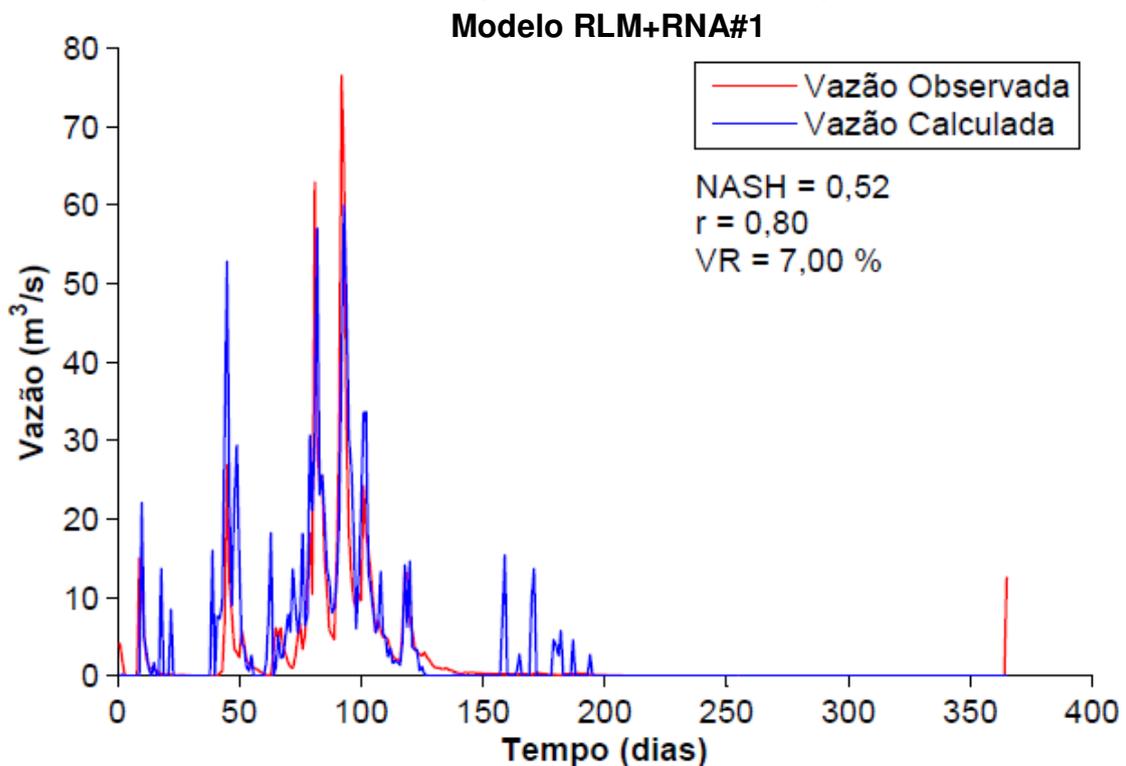
O modelo RLM+RNA#1 apresentou melhores resultados em todos os índices de desempenho de calibração e testes quando comparado à aplicação apenas do modelo RLM (Tabela 7). Dessa forma, observa-se que a integração do modelo de ocorrência de vazão RNA#1 teve uma forte influência na melhora dos resultados no modelo de regressão, o que não ficou evidenciado no modelo de redes neurais RNA#2.

Comparando os resultados obtidos pelos modelos de RNA (Tabela 6) com o modelo de RLM (Tabela 7), pode-se perceber a capacidade das redes neurais de detectar e extrair tendências não-lineares, produzindo assim resultados melhores do que a simples regressão.

Nas Figuras 12 e 13 apresentam-se os resultados para os períodos de testes dos hidrogramas calculados pelos modelos RLM e RLM+RNA#1 versus o hidrograma de vazões observadas.



**Figura 12** - Comparação entre estimativas diárias de vazão obtidas com o modelo RLM e os valores observados no posto Piacó durante o período de testes (1987).



**Figura 13** - Comparação entre estimativas diárias de vazão obtidas com o modelo RLM+RNA#1 e os valores observados no posto Piacó durante o período de testes (1987).

## 5. Conclusão

Este trabalho teve como principal objetivo estimar vazões diárias em regiões semiáridas e utilizou como estudo de caso o Rio Piancó, localizado no sertão paraibano. Esta região sofre com eventos extremos, como longos períodos de seca e períodos de chuvas intensas, ambos causando prejuízos sociais, ambientais e econômicos. A operação adequada dos reservatórios existentes nestas regiões pode ser considerada uma das formas mais eficazes de manter a sustentabilidade hídrica destes sistemas, de forma a mitigar os prejuízos resultantes das cheias e secas.

Neste estudo, foram propostos modelos de RNA: um primeiro modelo indicava a ocorrência de vazão no dia, para só então ser aplicado um outro modelo, também baseado em RNA, que pudesse fazer a estimativa diária desta vazão. O modelo para estimativa de ocorrência apresentou resultados bem satisfatórios, com acertos da ordem de 98%. O modelo RNA#1+RNA#2, que integrava os modelos de ocorrência e de estimativa de vazões, apresentou bons resultados quando analisados os índices estatísticos de desempenho, porém estes resultados não se mostraram significativos quando comparados ao funcionamento do modelo de estimativa (RNA#2) de forma independente. Por outro lado, a integração do modelo de ocorrência a um modelo de estimativa de vazão baseado em regressão linear múltipla produziu melhores resultados quando comparado ao uso do modelo de regressão de forma independente.

As conclusões obtidas neste estudo são:

- O modelo baseado em RNA para estimativa da ocorrência de vazões diárias é uma técnica que pode incorporar melhores resultados em modelos chuva-vazão para rios intermitentes.
- O modelo RNA#1 para estimativa de ocorrência de vazões diárias integrado ao modelo RNA#2 para estimativa de vazões diárias não incorporou melhores resultados ao mesmo. Este fato pode ser explicado devido à alta capacidade de adaptação das RNA no tratamento de dados com características complexas de não linearidade.
- Todos os modelos de RNA apresentaram melhor desempenho que o modelo de RLM, mesmo quando este foi integrado ao modelo de RNA#1, que estimava a ocorrência de vazões.

Os modelos propostos neste trabalho podem desempenhar um grande papel no gerenciamento de recursos hídricos de regiões semiáridas, auxiliando nas decisões a serem tomadas quanto à operação dos reservatórios existentes nesses locais, que, em geral, são alimentados por rios intermitentes.

## **6. Recomendações para Trabalhos Futuros**

Recomenda-se, para continuação deste estudo, o uso de uma maior quantidade de postos pluviométricos de acordo com a disponibilidade de dados e o desenvolvimento de outros modelos utilizando diferentes tipos de RNA como: redes neurais de bases radiais e redes neurais recorrentes. Propõe-se, ainda, a utilização desta metodologia para outras bacias hidrográficas com características semelhantes.

## 7. Referencias Bibliográficas

AB'SABER, A. N. O Sertão e os Sertanejos: Uma Geografia Sofrida. In: Dossiê Nordeste Seco – **Revista de Estudos Avançados**. São Paulo: USP, v. 13, nº36, p. 7-59, 1999.

AGÊNCIA EXECUTIVA DE GESTÃO DAS ÁGUAS DO ESTADO DA PARAÍBA. **Plano Estadual de Recursos Hídricos da Paraíba**, Brasil, Paraíba, 2006.

AGÊNCIA EXECUTIVA DE GESTÃO DAS ÁGUAS DO ESTADO DA PARAÍBA. **Meteorologia: Dados de Chuva Diária**, Paraíba, 2012. Disponível em: <http://site2.aesa.pb.gov.br/aesa/medicaoPluviometrica.do?metodo=chuvadasDiariasMa> pa. Acesso em: 30 jan. 2012.

AGÊNCIA NACIONAL DE ÁGUAS. Disponível em <http://hidroweb.ana.gov.br/>. Acesso em: 07 jan. 2012.

AKSOY H.; BAYAZIT M., A Daily Intermittent Streamflow Simulator. **Turk Journal Engineering Environmental Science**, pp 265 – 276, 2000.

ALVES, F. M., FARIAS, C. A. S., SRINIVASAN V. S., SUZUKI, K. Use of artificial neural networks as a runoff-erosion model applied to a semi-arid region of Brazil, **Proceedings of the 13th JSCE Congress of Civil Engineering** - Shikoku Division, pp. 174-175, Takamatsu, Japan, 2007.

AMERICAN SOCIETY OF CIVIL ENGINEERS. Task Committee on Definition of Criteria for Evaluation of Watershed Models of the Watershed Management Committee, Irrigation and Drainage Division. **Journal of Irrigation and Drainage Engineering**, v.119, n.3, p.429-442, 1993.

BOUGHTON W., CHIEW F. Estimating runoff in ungauged catchments from rainfall, PET and the AWBM model, **Environmental Modelling and Software**, Vol. 22 i4, pp. 476-487, 2007.

BOX, G. E. P., JENKINS, G. M. Time series analysis forecasting and control. **San Francisco: Holden- Day**, 1976.

CARDOSO, G. B.; MONCUNILL, D.; REIS, D. S. Jr; MARTINS, E. S.; NASCIMENTO, L. S. V. Real-Time Optimization of Reservoir's Operation to Mitigate Flood Damages Using Short Term Reservoir's Inflow Forecasts. In: **IAHS 8th Scientific Assembly** - Hydroinformatics in Hydrology, Hydrogeology and Water Resources Management,

Hyderabad. Proceedings of Symposium JS.4 at the Joint IAHS & IAH Convention, 2009.

CARDOSO, G. B.; MONCUNILL, D.; REIS, D. S. Jr; MARTINS, E. S.; NASCIMENTO, L. S. V Short Term Reservoir s Inflow Forecasts Based upon Multi-Model Precipitation Forecasts: The Case of the Jaguaribe River Basin, Brazil. In: **HydroPredict - International Interdisciplinary Conference on Predictions for Hydrology, Ecology, and Water Resources Management: Using Data and Models to Benefit Society**, Praga, 2008.

COLLISCHONN, W., ANDREOLLI H. R. I., TUCCI, C. E. M. Forecasting river Uruguay flow using rainfall forecasts from a weather prediction model, **Journal of Hydrology**, Vol. 305, pp. 87-98, 2005.

COLLISCHONN, W.; TUCCI, C. E. M. Ajuste multiobjetivo dos parâmetros de um modelo hidrológico. **Revista Brasileira de Recursos Hídricos**, v.8, n., p.27-39, 2003.

COLLISCHONN, W. **Simulação hidrológica em grandes bacias**. Tese de Doutorado, UFRGS, Porto Alegre, 194p, 2001.

COULIBALY, P., ANCTIL F., BOBÉE B. Multivariate reservoir inflow forecasting using temporal neural networks, **Journal of Hydrologic Engineering**, ASCE, 6, pp. 367–376, 2001.

DEMUTH H.; BEALE, M.; HAGAN, M. **Neural Network Toolbox 7: User's Guide**. The MathWorks Inc Natick, USA, 404 p, 2012.

DEMUTH H.; BEALE, M. **Neural Network Toolbox 4: User's Guide**. The MathWorks Inc Natick, USA, 846 p, 2005.

DRAPER, N., SMITH, H. **Applied regression analysis**. 2. ed. New York: John Wiley & Sons, 1981.

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**. Tese de Doutorado, Ehime University, Matsuyama – Japão, 127 p, 2009.

FARIAS, C. A. S., A. B. CELESTE, Y. SAKATA, A. KADOTA and K. SUSUKI: Use of Monte Carlo optimization and artificial neural networks for deriving reservoir operating rules, **Annual Journal of Hydraulic Engineering**, JSCE, 50(1), pp. 25-30, 2006.

GIL, R.: **Neuropsicologia**, 2nd ed., Livraria Santos Editora, São Paulo, Brazil, 2002.

GOVINDARAJU, R. S., RAO A. R. **Artificial Neural Networks in Hydrology**, Kluwer Academic Publishers, The Netherlands, 2000.

HAGAN, M. T.; MENHAJ M. B. Training feedforward networks with the Marquardt algorithm, **IEEE Transactions on Neural Networks**, 5(6), pp. 989-993, 1994.

HAYKIN S.: **Neural Networks: a Comprehensive Foundation**, 2 ed., Prentice Hall, Upper Saddle River, USA, 1999.

HEBB, D. O.: **The Organization of Behavior: A Neuropsychological Theory**, Wiley, New York, 1949.

JEONG, D. II., KIM Y. O. Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction, **Hydrological Processes**, 19, pp. 3819-3835, 2005.

KLIMASAUSKAS, C. C. **Applying neural networks Part 3: Training a neural network**, PC-AI, 20–24, 1991.

LETTENMAIER D. P., WOOD, E. F. **Hydrologic Forecasting” in Handbook of Hydrology**, Org. by Maidment, D. R., McGraw-Hill Inc., pp. 26.1–26.30, New York, USA, 1993.

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**. Ph.D. Thesis, Universidade Federal de Campina Grande, Campina Grande, Brasil, 2004.

LITTLEWOOD, I. G.; CLARKE, R. T.; COLLISCHONN, W.; CROKE, B. F. W. Predicting daily streamflow using rainfall forecasts, a simple loss module and unit hydrographs: Two Brazilian catchments Source, **Environmental Modelling & Software**, Vol. 22 (9), pp. 1229-1239, 2007.

LOPES, J. E., BRAGA B. F. F., CONEJO, J.L., A Simplified Hydrologic Model: in Applied Modeling in Catchment Hydrology, **Water Resources Publication**, pp. 167-176, 1982.

LOUCKS, D. P., STEDINGER J. R., HAITH D. A.: **Water Resources Systems Planning and Analysis**, Prentice Hall, Englewood Cliffs, USA, 1981.

McCULLOCH, W.S., PITTS W. A logical calculus of the ideas immanent in nervous activity, **Bulletin of Mathematical Biophysics**, 5, pp. 115–133, 1943.

MINSKY, M. L., PAPERT S. A. **Perceptrons**, MIT Press, Cambridge, Massachusetts, USA, 1969.

NANDALAL, K. D. W., LOUCKS J. J., BOGARDI D. P., STEDINGER J. R., HAITH D. A.: **Water Resources Systems Planning and Analysis**, Prentice Hall, Englewood Cliffs, USA, 1981.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part 1 – A discussion of principles. **Journal of Hydrology**, v.10, n.3, p.282-290, 1970.

NAYAK, P. C., SATYAJI, Y. R., SUDHEER, K. P. Groundwater level forecasting in a shallow aquifer using artificial neural network approach, **Water Resources Management**, 20, pp. 77-90, 2006.

RUMELHART, D. E., HINTON G. E., WILLIAMS R. J.: Learning internal representations by error propagation, in **Parallel Distributed Processing: explorations in the Microstructure of Cognition**, edited by D. E. Rumelhart and J. L. McClelland, 1(8), MIT Press, Cambridge, USA, 1986.

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.

UNITED NATIONS EDUCATIONAL, SCIENTIFIC AND CULTURAL ORGANIZATION. **Water Use in the World: Present Situation/Future Needs**. 7 Place de Fontenoy, 75352 Paris 07 SF, pp. 40, 1998.

US ARMY ENGINEER DIVISION. **Program description and user manual for SSARR**, North Pacific, Portland Oregon, USA. 1972.

ZHANG, G., PATUWO, E., HU, M. Forecasting with artificial neural networks: the state of the art. **International Journal of Forecasting**, (14):35–62, 1998.