

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
UNIDADE ACADÊMICA DE CIÊNCIA E TECNOLOGIA AMBIENTAL  
CENTRO DE CIÊNCIA E TECNOLOGIA AGROALIMENTAR  
CAMPUS DE POMBAL - PB

TATIANE CAROLYNE CARNEIRO



OTIMIZAÇÃO ESTOCÁSTICA IMPLÍCITA E REDES NEURAIS  
ARTIFICIAIS PARA AUXÍLIO NA OPERAÇÃO MENSAL DO SISTEMA  
COREMAS - MÃE D'ÁGUA

**DIGITALIZAÇÃO  
SISTEMOTECA - UFCG**

POMBAL  
2012

TATIANE CAROLYNE CARNEIRO

**OTIMIZAÇÃO ESTOCÁSTICA IMPLÍCITA E REDES NEURAIS  
ARTIFICIAIS PARA AUXÍLIO NA OPERAÇÃO MENSAL DO SISTEMA  
COREMAS - MÃE D'ÁGUA**

Trabalho de Conclusão de Curso  
submetido à Coordenação do  
Curso de Engenharia Ambiental  
como requisito para  
integralização dos créditos da  
disciplina Trabalho de Conclusão  
de Curso.

ORIENTADOR: CAMILO ALLYSON SIMÕES DE FARIAS

POMBAL  
2012

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA SETORIAL  
CAMPUS POMBAL/UFCG

C289o Carneiro, Tatiane Carolyne.

Otimização estocástica implícita e redes neurais artificiais para auxílio na operação mensal do sistema Coremas-Mãe D'Água / Tatiane Carolyne Carneiro. – Pombal: UFCG, 2012.

31f.

Orientador: Prof.º Dr. Camilo Allyson Simões de Farias

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

1. Recursos Hídricos. 2. Redes Neurais Artificiais. 3. Otimização Estocástica. 4. Modelos de Simulação. I. Farias, Camilo Allyson Simões de. II. Título.

UFCG/CCTA

CDU 556(813.3)(043)

TATIANE CAROLYNE CARNEIRO

**OTIMIZAÇÃO ESTOCÁSTICA IMPLÍCITA E REDES NEURAIIS  
ARTIFICIAIS PARA AUXÍLIO NA OPERAÇÃO MENSAL DO SISTEMA  
COREMAS MÃE D'ÁGUA**

Trabalho de Conclusão de Curso  
submetido à Coordenação do  
Curso de Engenharia Ambiental  
como requisito para  
integralização dos créditos da  
disciplina Trabalho de Conclusão  
de Curso.

Aprovado em 28 de Fevereiro de 2011.

**BANCA EXAMINADORA**

---

Prof. Dr. Camilo Allyson Simões de Farias  
Universidade Federal de Campina Grande

---

Prof. Dr. Manoel Moisés Ferreira de Queiroz  
Universidade Federal de Campina Grande

---

Prof. M.Sc. José de Araújo Pereira  
Instituto Federal da Paraíba - Cajazeiras

UFMG / BIBLIOTECA

Ao meu pai, João Carneiro, que mesmo não estando mais entre nós, é a inspiração maior de minhas conquistas e quem me ensinou a fazer e ser sempre alguém melhor.

## **AGRADECIMENTOS**

A Deus, por sua caminhada junto a mim em todos os momentos.

A Adrian José Molina Rugama, pelos ensinamentos e por todo amor.

A Luiz Eugenio Nunes, pelo incentivo e força durante minha caminhada.

A meus pais, minha mãe que em todos os momentos esteve ao meu lado e ao meu pai que não esta mais entre nós, mais que sempre esteve presente em minha vida.

Aos colegas da turma 2007.1 de Engenharia Ambiental pela companhia em todos esses anos.

Aos professores da Unidade Acadêmica de Ciência e Tecnologia Ambiental, em especial, os professores José Cleidimário Araújo Leite, Camilo Allysson Simões de Farias, Juliana Fernandes Moreira, Andréa Maria Brandão Mendes, Helber Rangel e Valmir Marques Cristiano.

Aos meus amigos, em especial á Elisângela Maria da Silva, amiga em todos os momentos.

As minhas companheiras de republica.

A todos que direto ou indiretamente contribuíram para esse momento.

<b>Sumário</b>	<b>Página</b>
RESUMO	ix
ABSTRACT	x
1. INTRODUÇÃO.....	01
2. REVISÃO BIBLIOGRÁFICA.....	03
2.1 Redes Neurais Artificiais.....	03
2.2 Técnicas de Otimização.....	03
2.3 Modelos de Otimização: Determinístico e Estocástico.....	04
2.4 Geração Sintética de Vazões.....	04
2.5 Política Operacional Linear Padrão (SLOP).....	05
3. MATERIAL E MÉTODOS.....	05
3.1 Área de Estudo.....	05
3.2 Modelo Chuva Vazão por meio de Redes Neurais Artificias.....	08
3.3 Geração Estocástica de Vazões.....	11
3.4 Regras Operacionais por meio de Otimização estocástica e Redes Neurais Artificiais	13
3.4.1 Técnica de Otimização Estocástica Implícita.....	13
3.4.2 Modelo de Otimização Determinístico.....	13
3.4.3 Regras Operacionais por meio de Redes Neurais Artificias.....	14
3.5 Modelo de Simulação.....	15
3.6 Índices de Sustentabilidade.....	16
3.6.1 Confiabilidade.....	16
3.6.2 Vulnerabilidade.....	16

3.6.3	Computação dos Índices.....	17
4.	RESULTADOS E DISCUSSÃO.....	18
4.1	Modelo Chuva Vazão por meio de Redes Neurais Artificiais.....	18
4.2	Geração Estocástica de Vazões.....	19
4.3	Regras Operacionais por meio de Otimização Estocástica Implícita e Redes Neurais Artificiais	20
5.	CONCLUSÃO.....	24
6.	REFERÊNCIAS BIBLIOGRÁFICAS.....	25
	ANEXOS.....	28

## RESUMO

Este trabalho apresenta regras mensais de operação baseadas em Otimização Estocástica Implícita (OEI) e Redes Neurais Artificiais (RNA) para um sistema hídrico localizado no sertão Paraibano. A técnica de OEI consiste em otimizar a operação do sistema usando um conjunto de possíveis cenários de entrada e, posteriormente, na utilização dos dados ótimos gerados para construção de regras operacionais. Neste estudo, utilizou-se RNA para relacionar alocações do reservatório com volume inicial, vazão corrente, estimativas mensais de evaporação potencial e demanda, e valor anterior de alocação. Os cenários sintéticos de vazões afluentes foram obtidos a partir do Método dos Fragmentos (MF). Os resultados gerados pelo MF indicam que o modelo apresenta potencial para simulação mensal de vazões em regiões semiáridas. As regras operacionais mensais obtidas com o modelo OEI-RNA foram aplicadas para operação do reservatório Coremas - Mãe d'Água e critérios de sustentabilidade foram utilizados para análise dos resultados. Os índices de sustentabilidade indicam que o modelo OEI-RNA foi superior às regras de operação padrão e similar a um modelo determinístico com o conhecimento de todo o horizonte de operação. Sendo assim, espera-se que este modelo possa servir como apoio na tomada de decisão para a operação mensal de reservatórios em regiões semiáridas.

**Palavras-Chave:** operação de reservatórios, redes neurais artificiais, otimização estocástica implícita.

## ABSTRACT

This paper presents monthly operating rules based on Implicit Stochastic Optimization (ISO) and Artificial Neural Networks (ANN) for a water system located in Paraíba's outback, Brazil. The ISO technique consists of optimizing the system operation using a set of possible scenarios as input and, after, utilizing the optimal outcomes in order to construct reservoir operating rules. In this study, ANN were used for relating reservoir releases to initial storage, current inflow, monthly estimations of potential evaporation and demand, and previous reservoir release. The synthetic scenarios of reservoir inflows were generated by the Fragment Method (FM). The results obtained by the MF indicate that this approach has potential for simulating monthly flows in semiarid regions. The monthly operating rules obtained by the ISO-ANN model were applied to the operation of Coremas - Mãe d'Água reservoir and sustainability criteria were used for analyzing the results. The outcomes suggest the ISO-ANN model is superior to the standard rules of operation and similar to the application of a determinist model with the knowledge of inflows for the whole operating horizon. As a consequence, this model may support the decision-making process for monthly operation of reservoirs in semiarid regions.

**Keywords:** reservoir operation, artificial neural networks, implicit stochastic optimization.

## 1. INTRODUÇÃO

O crescimento populacional e conseqüente aumento das demandas por alimento e energia são os principais responsáveis pela crise da água no mundo. Para o atendimento destas crescentes demandas, tanto em termos de qualidade como de quantidade, é frequentemente necessário que o sistema hídrico local seja operado e monitorado de forma eficaz. Em regiões semiáridas, este manejo se torna ainda mais complexo por causa das variações climáticas, alta taxa de evaporação, má distribuição dos recursos hídricos e baixa pluviometria (Vajpeyi, 1998; Loucks, 2000; Celeste *et al.*, 2005; Farias *et al.*, 2006, Farias, 2009).

O desenvolvimento das regiões está condicionado diretamente à quantidade e qualidade de seus recursos hídricos. O estado da Paraíba está localizado em uma região semiárida e sofre com frequentes secas. Estas secas podem ter seus efeitos minimizados através de um gerenciamento adequado dos recursos hídricos existentes que deve considerar a variabilidade hidrológica tanto no presente quanto no futuro.

Existem diversas medidas para mitigação dos efeitos das secas em regiões semiáridas, sendo a Otimização Estocástica Implícita (OEI) uma alternativa promissora. Neste procedimento, um modelo de série temporal é usado para gerar um certo número de cenários sintéticos de entrada ao sistema (e.g., vazões). O sistema é então otimizado para estes cenários e regras de operação são produzidas através de modelos de regressão linear múltipla. Na maioria dos casos, estas regras operacionais relacionam alocações com o volume inicial do reservatório e vazões esperadas para um passo à frente (Young, 1967; Willis *et al.*, 1984; Celeste *et al.*, 2005). Diferente do uso de equações de regressão, este estudo usará Redes Neurais Artificiais (RNA) a fim de extrair tendências não-lineares entre as variáveis envolvidas.

As RNA são um ramo da inteligência artificial que surgem para 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 fortemente ligados (neurônios) trabalhando em paralelo para resolver um problema específico. Estas ferramentas aprendem através de exemplos selecionados cuidadosamente, tornando-se muito

eficazes para solução de sistemas não-lineares, na adaptação a circunstâncias, entre outras vantagens (Haykin, 1999; Farias *et al.*, 2006; Farias, 2009).

Este trabalho propõe o desenvolvimento e aplicação de procedimentos capazes de incorporar as incertezas hidrológicas para operação sustentável de sistemas hídricos localizados na região semiárida do estado da Paraíba, Brasil. O processamento destas incertezas será realizado através da técnica de OEI combinada com RNA.

## **2. REVISÃO BIBLIOGRÁFICA**

### **2.1. Redes Neurais Artificiais**

As RNA são sistemas paralelamente distribuídos e constituídos por unidades de processamento capazes de modelar desde problemas simples até os mais complexos. Sua estrutura é distribuída em camadas que são interligadas por conexões chamadas de pesos sinápticos e onde é armazenado o conhecimento adquirido através de um processo de aprendizagem (Ludermir *et al.*, 2007).

O estudo das RNA teve como base os neurônios biológicos que compõem o cérebro humano. A partir de seu funcionamento foi desenvolvido o primeiro neurônio artificial proposto no trabalho *A logical calculus of the ideas immanent in nervous activity*, no ano de 1943, pelo psicólogo Warren McCulloch juntamente com o matemático Walter Pitts. O primeiro neurônio artificial ficou conhecido como “neurônio MCP” em homenagem aos seus criadores.

No modelo do neurônio artificial existe uma unidade de processamento com ramificações, que são as entradas (dendritos) e saídas (axônios). As sinapses são pesos que ponderam a passagem de dados das entradas para as saídas. A combinação desses neurônios artificiais é o que chamamos de RNA. Segundo Ludermir *et al.* (2007), a rede neural é calibrada através de estímulos externos contínuos que ajustam os parâmetros da rede por meio de um processo de aprendizagem.

### **2.2. Técnicas de Otimização**

A procura por políticas ótimas para sistemas hídricos está diretamente relacionada com a seleção das variáveis de operação (Loucks *et al.*, 1981). Estas variáveis podem ser divididas em dois grupos: variáveis de decisão e de estado. As variáveis de decisão representam a solução ótima, enquanto as variáveis de estado são consequências dos valores atribuídos às variáveis de decisão. A procura pela combinação ótima das variáveis de decisão, de forma a minimizar ou maximizar um objetivo (função objetivo) sujeito a restrições, é a grande finalidade das técnicas de otimização. Em geral, os modelos matemáticos de otimização podem ser classificados como:

- Programação linear;
- Programação dinâmica; e
- Programação não-linear.

### **2.3. Modelos de Otimização: Determinístico e Estocástico**

Os modelos de otimização podem ser classificados como determinísticos ou estocásticos. Modelos determinísticos descrevem o comportamento de um sistema no qual as variáveis de entrada são admitidas como certas, ou seja, as variáveis independentes têm um impacto conhecido sobre as variáveis dependentes. Em contraste, os modelos estocásticos consideram a existência de variáveis incertas no sistema. Os modelos mais comuns de otimização estocástica são Otimização Estocástica Implícita (OEI) e Otimização Estocástica Explícita (OEE).

Na técnica de OEI usa-se um modelo de série temporal para gerar um certo número de cenários sintéticos de entrada ao sistema (e.g., vazões). O sistema é então otimizado para estes cenários e regras de operação são produzidas através de modelos de regressão linear múltipla. Na maioria dos casos, estas regras operacionais relacionam alocações com o volume do reservatório e vazões esperadas para um passo à frente (Young, 1967; Willis *et al.*, 1984; Celeste *et al.*, 2005).

### **2.4. Geração Sintética de Vazões**

Para a aplicação de técnicas de otimização estocástica, geralmente necessita-se de longas séries temporais das variáveis que fazem parte do sistema.

A geração sintética surge como uma importante alternativa para extensão de séries hidrológicas, o que é de extremo valor para o planejamento e operação de sistemas hídricos, com especialidade para regiões onde dados históricos são escassos.

As séries sintéticas devem apresentar propriedades estatísticas semelhantes aos dados históricos e serem igualmente prováveis. Existem vários métodos na literatura que podem ser utilizados para geração de séries para diferentes intervalos temporais. Entre os métodos mais comuns, podemos citar o Método dos Fragmentos (MF), Modelo de Thomas-Fiering, modelos de auto-regressão, etc. (Reddy, 1987; Svanidze, G. G., 1980; Thomas e Fiering, 1962).

## 2.5. Política Operacional Linear Padrão (SLOP)

Uma das regras de operação mais simples é a Política Operacional Linear Padrão, do inglês *Standard Linear Operation Policy* (SLOP). Este modelo, que é mostrado na Figura 1, estabelece que quando a água disponível é igual ou inferior à demanda, toda a água armazenada é liberada, e quando a água disponível é superior à demanda, a mesma é atendida e o excedente começa a ser acumulado no reservatório até atingir seu volume máximo. A partir daí, o vertimento é iniciado (Loucks *et al.*, 1981; Celeste, 2004).

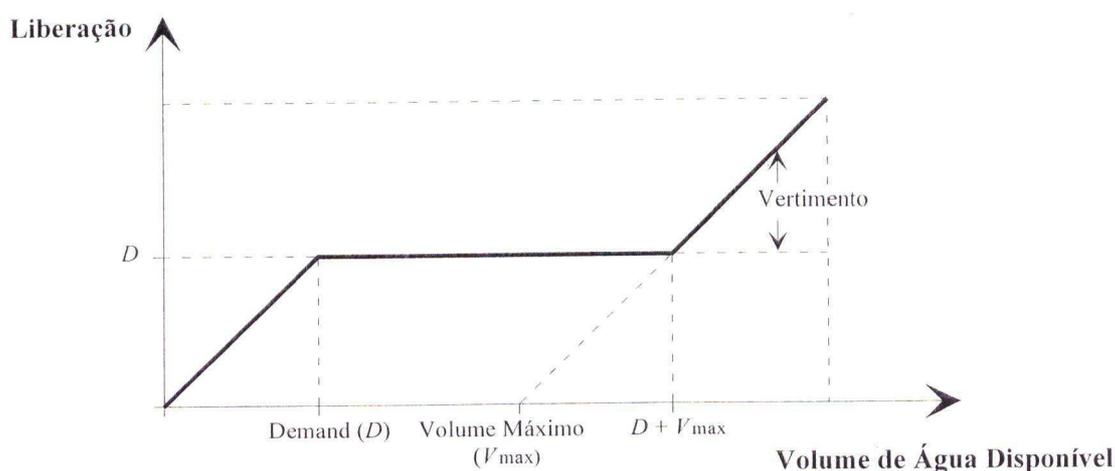


Figura 1. Política Operacional Linear Padrão (Adaptado de Farias, 2009)

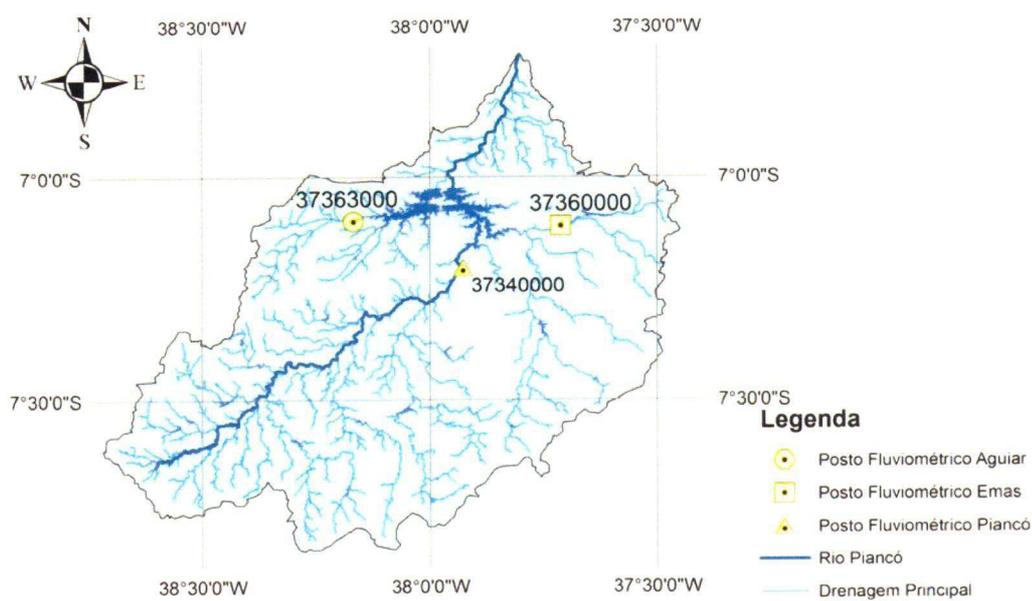
## 3. MATERIAL E MÉTODOS

### 3.1. Área de estudo

Os procedimentos e modelos desenvolvidos nesta pesquisa foram aplicados para operação dos reservatórios Coremas e Mãe d'Água, localizados na região semiárida do estado da Paraíba.

O Sistema Coremas - Mãe d'Água está situado no extremo sudoeste da Paraíba, na sub-bacia do Rio Piancó. A região conta com uma temperatura média anual superior a  $24^{\circ}\text{C}$  e precipitação média anual de 821 mm, sendo que 60% deste valor concentra-se entre os meses de fevereiro e abril. A evaporação potencial anual é de quase 3000 mm, com as maiores taxas mensais no período de setembro a

dezembro (Lima, 2004). As vazões afluentes ao reservatório são provenientes de três grandes tributários: Riacho Aguiar, Riacho Emas e Rio Piancó, como mostrado na Figura 2.



**Figura 2.** Localização do Sistema Coremas – Mãe d'Água na sub-bacia hidrográfica do Rio Piancó.

O Rio Piancó nasce na Serra do Umbuzeiro, município de Santa Inês, e deságua no Rio Piranhas, em Pombal. 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 sub-bacia do Rio Piancó conta com 1336 açudes, sendo que 90,6% deles caracterizam micros e pequenos reservatórios. Isso faz com que o escoamento superficial seja algo preocupante, no tocante à demanda e disponibilidade hídrica do sistema.

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, mas apenas

2,8% dessa área estão sendo exploradas, geralmente por pequenas propriedades e projetos públicos de irrigação.

Os açudes Estevam Marinho (Coremas) e Mãe d'Água foram construídos na década de 30 e 50 e barram, respectivamente, o Rio Piancó e o Riacho Aguiar. Os principais usos destes açudes são: perenização dos vales, controle de cheias, irrigação, piscicultura, aproveitamento de culturas nas áreas de montante, abastecimento de água para as populações urbanas, e geração de energia. Eles são interligados por um canal com a 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 x 10<sup>6</sup> m<sup>2</sup> (Lima, 2004). A Figura 3 apresenta uma foto de satélite dos dois açudes.

O reservatório Coremas tem uma capacidade máxima de 720 milhões de metros cúbicos e seus principais tributários são o Rio Piancó e Riacho Emas, que juntos controlam aproximadamente 80,2% das afluições ao 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 e o seu principal tributário é o Riacho Aguiar, responsável por 19,8% de toda afluição ao sistema. Deste reservatório parte o Canal da Redenção, que é responsável pelo suprimento das demandas de irrigação das Várzeas de Sousa (5000 ha), localizada entre os municípios de Sousa e Aparecida.



**Figura 3.** Foto de satélite do Sistema Coremas – Mãe d'Água. (Fonte: Google Earth)

As demandas mensais dos reservatórios, utilizadas nesse trabalho, estão apresentadas na Tabela 1.

**Tabela 1.** Demandas mensais do Sistema Coremas - Mãe d'Água.

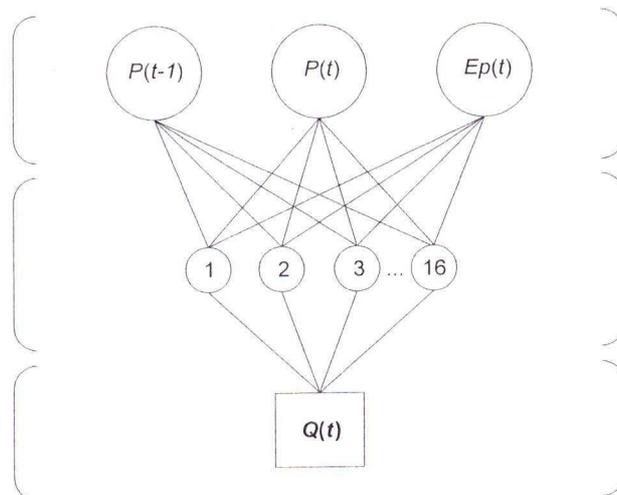
	Irrigação	Abastecimento humano	Psicultura	Total (m <sup>3</sup> /s)
Jan	8,12	2,28	0,049	10,45
Fev	7,45	2,28	0,049	9,78
Mar	6,77	2,28	0,049	9,10
Abr	6,68	2,28	0,049	9,01
Mai	6,51	2,28	0,049	8,84
Jun	6,64	2,28	0,049	8,97
Jul	7,11	2,28	0,049	9,44
Ago	7,92	2,28	0,049	10,25
Set	8,40	2,28	0,049	10,73
Out	8,70	2,28	0,049	11,03
Nov	8,72	2,28	0,049	11,04
Dez	8,21	2,28	0,049	10,54

Fonte: Lima, 2004.

### 3.2. Modelo Chuva-Vazão por meio de Redes Neurais Artificiais

O modelo chuva-vazão mensal deste estudo é uma RNA do tipo *perceptron de múltiplas camadas* e treinada pelo conhecido algoritmo de retropropagação de erros (Haykin, 1999). Este modelo é utilizado para o preenchimento de falhas nos dados utilizados pela técnica de OEI.

A arquitetura da RNA utilizada possui uma camada de entrada, uma oculta (ou intermediária) e uma de saída. A topologia da RNA é do tipo alimentada adiante, ou seja, as conexões acontecem da camada de entrada para camada oculta, e da camada oculta para camada de saída. A camada de entrada possui três neurônios que são compostos pelo valor prévio de precipitação média  $P(t-1)$ , valor corrente de precipitação média  $P(t)$ , e evaporação potencial  $Ep(t)$ , todos expressos em [mm]. O número de neurônios da camada oculta é obtido através de um processo baseado em tentativa e erro. Os melhores resultados foram obtidos com 16 neurônios na camada oculta. Na camada de saída, o único neurônio é a lâmina escoada no posto fluviométrico de Piancó  $Q(t)$ , também expressa em [mm]. Foram utilizadas funções sigmóides para os neurônios da camada oculta e uma função linear para o neurônio da camada de saída. A Figura 4 apresenta a estrutura da RNA desta pesquisa.



**Figura 4.** Estrutura do modelo chuva-vazão baseado em RNA.

O modelo chuva-vazão mensal baseado em RNA foi implementado e calibrado utilizando dados de oito postos pluviométricos (médias aritméticas) e o posto fluviométrico Piancó, como mostrado na Tabela 2.

**Tabela 2.** Postos utilizados para calibração do modelo chuva-vazão.

<b>Código</b>	<b>Nome do posto</b>	<b>Tipo</b>	<b>Município</b>
737006	Piancó	Pluviométrico	Piancó
738020	Conceição	Pluviométrico	Conceição
738015	Manaíra	Pluviométrico	Manaíra
738013	Princesa Isabel	Pluviométrico	Princesa Isabel
738019	Santana dos Garrotes	Pluviométrico	Santana dos Garrotes
738012	Boa Ventura	Pluviométrico	Boa Ventura
738014	Nova Olinda	Pluviométrico	Nova Olinda
738018	Ibiara	Pluviométrico	Ibiara
37340000	Piancó	Fluviométrico	Piancó

Os dados utilizados para treinamento, validação e teste do modelo de RNA compreendem os anos de 1963-1974, 1975-1981 e 1982-1988, respectivamente.

Os dados originais (entradas e saídas desejadas) foram convenientemente escalonados para melhorar a eficiência na calibração dos modelos 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). O algoritmo escolhido para a calibração é o de retropropagação de erro, o qual tem sido utilizado com sucesso em vários campos da engenharia. Nesta aplicação, o algoritmo *Scaled Conjugate Gradient* (SCG) foi usado para retropropagação. Uma explicação detalhada do algoritmo SCG pode ser encontrada em Moller (1993).

A RNA tem sua calibração encerrada pelo processo conhecido como *Early Stopping Method* (Demuth *et al.*, 2008). 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.

A avaliação do desempenho do sistema de previsão de vazões foi realizada com base nos seguintes índices: correlação ( $r$ ), viés relativo ( $VR$ ) e eficiência de Nash-Sutcliff ( $NASH$ ). A correlação mede o grau de dependência linear entre as previsões e os valores observados de vazão, expressando na realidade um valor potencial de bom ajuste. O viés relativo, por sua vez, mostra se o sistema de previsão de vazões possui uma tendência a subestimar ou superestimar as vazões observadas. O índice de eficiência  $NASH$ , que pode variar entre  $-\infty$  e um, é tradicionalmente utilizado para expressar aderência entre vazões simuladas e observadas. 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 um.

Valores altos de correlação não significam, por si só, previsões com alta precisão. Por exemplo, um sistema com um viés muito alto, mesmo que possua correlação igual à unidade ( $r=1$ ), fornecerá previsões de vazões de baixa precisão, embora seja possível remover este viés através de modelos estatísticos. Um sistema perfeito de previsão teria  $r = 1$  e  $VR = 0$ . As equações para o cálculo destes índices podem ser encontradas em Salas (1993).

### 3.3. Geração Estocástica de Vazões

Para geração estocástica de vazões foram utilizadas as vazões observadas nos postos fluviométricos de Emas, Aguiar e Piancó. Estes postos foram escolhidos por serem os grandes tributários do Sistema Coremas - Mãe d'Água, reservatórios em estudo e maior reserva hídrica do estado da Paraíba. Os postos e o período de dados utilizados são apresentados na Tabela 3.

**Tabela 3.** Postos e período de dados utilizados para geração sintética de vazões.

Posto Fluviométrico	Período	Fonte
Piancó	1963-1988	Hidroweb (ANA, 2010)
Aguiar		Preenchidos pelo modelo chuva-vazão de RNA
Emas		Hidroweb com falhas preenchidas pelo modelo chuva-vazão de RNA

A série utilizada é a soma das vazões correspondentes nos três postos, formando uma única série de vazões. O Sistema Coremas - Mãe d'Água é composto pela junção de dois açudes, que quando atingem um determinado nível, se tornam um só reservatório. Nessa pesquisa, o reservatório será utilizado como um reservatório equivalente, ou seja, o volume ativo do sistema será considerado como a soma dos volumes ativos dos reservatórios individuais.

Para aplicação do modelo de OEI é necessária a implementação de um modelo para geração sintética de vazões afluentes ao Sistema Coremas - Mãe D'água com propriedades estatísticas similares às dos dados observados. O modelo escolhido é o Método dos Fragmentos (MF), que foi primeiramente proposto por Svarnidze (1980) e tem sido vastamente utilizado para geração sintética de vazões (Araújo & Campos, 1991; Celeste *et al.*, 2007). O MF consiste em desagregar vazões anuais em vazões mensais segundo uma forma padronizada (Celeste *et al.* 2007).

O primeiro passo do MF consiste em calcular os fragmentos dividindo as vazões de cada mês pela soma de todas as vazões mensais do respectivo ano, como mostrado na Equação 1.

$$Fr_{i,j} = \frac{Q_{i,j}}{\sum_{j=1}^{12} Q_{i,j}} \quad (1)$$

onde  $Fr_{i,j}$  e  $Q_{i,j}$  são, respectivamente, o fragmento e a vazão do mês  $j$  do ano  $i$ .

O segundo passo consiste em avaliar as vazões quanto à dependência linear e, caso sejam serialmente dependentes, utilizar modelos estatísticos para produzir uma série de resíduos serialmente independentes.

Após a verificação quanto à dependência linear, as vazões anuais históricas são padronizadas pela Equação 2 de forma que tenham a média e o desvio padrão iguais a zero e um, respectivamente.

$$QA_p = \frac{QA - \overline{QA}}{\sigma_{QA}} \quad (2)$$

onde  $QA_p$  é a vazão anual padronizada;  $QA$  é a vazão anual;  $\overline{QA}$  é a vazão média anual dos dados históricos; e  $\sigma_{QA}$  é o desvio padrão das vazões anuais dos dados históricos.

Por fim, as vazões padronizadas são modeladas através de uma distribuição de probabilidade adequada.

O MF foi utilizado para geração estocástica de vazões afluentes e, assim como no trabalho de Celeste *et al.* (2007), um estudo preliminar dos dados mostrou que as vazões anuais eram serialmente independentes. Uma análise dos resíduos gerados após a padronização dos dados pela Equação (2) mostrou que os números aleatórios poderiam ser gerados através de uma distribuição normal de probabilidades.

A nova geração de vazões anuais se procede através da simulação aleatória de números através da distribuição de probabilidade modelada e pela posterior aplicação das funções inversas de padronização. Em seguida, as vazões anuais geradas são desagregadas seguindo o modelo proposto por (Celeste *et al.*, 2007, apud Srikanthan e McMahon, 1980). Este modelo consiste em ordenar as vazões anuais dos dados históricos em ordem crescente, de forma que a primeira classe tenha limite inferior igual a zero e a última classe tenha limite superior igual a infinito. As classes intermediárias, neste caso, são definidas pelas médias de duas vazões

sucessivas. Após a definição destes limites, cada vazão anual gerada pertencerá a uma classe correspondente e as vazões mensais serão geradas através da multiplicação dos fragmentos daquela classe pelo valor anual sintético.

Neste estudo foi gerada uma sequência de 500 anos de vazões sintéticas e suas estatísticas foram comparadas com as estatísticas observadas nas vazões históricas.

### **3.4. Regras Operacionais por meio de Otimização Estocástica Implícita e Redes Neurais Artificiais**

#### **3.4.1. Técnica de Otimização Estocástica Implícita**

A técnica de OEI consiste das seguintes etapas:

- 1) Gerar sequências de  $M$  meses de valores de vazões afluentes ao sistema hídrico através do modelo de geração estocástica de vazões;
- 2) Para cada sequência de  $M$  meses encontrar as alocações ótimas de água a partir de um modelo de otimização determinístico;
- 3) Relacionar as alocações ótimas com outras variáveis do sistema a fim de derivar regras operacionais.

As alocações ótimas são comumente relacionadas através de regressão linear com outras variáveis do sistema. Entretanto, como a relação entre estas variáveis geralmente apresenta tendências não-lineares, este estudo utilizará um modelo baseado em RNA.

#### **3.4.2. Modelo de Otimização Determinístico**

Este modelo assume que o principal objetivo da operação é encontrar alocações de água que melhor satisfazem as demandas sem comprometer o sistema. A função objetivo do problema de otimização é escrita como segue:

$$\text{minimizar } \sum_{t=1}^N \left[ \frac{R(t) - D(t)}{D(t)} \right]^2 \quad (3)$$

onde  $N$  é o horizonte de operação;  $R(t)$  é a alocação no mês  $t$ ; e  $D(t)$  a demanda no mês  $t$ .

Alocações e volumes de cada período são relacionados com vazão afluente, evaporação e vertimento pela equação da continuidade:

$$\begin{aligned} S(1) &= S_0 + Q_T(1) - R(1) - Ev(1) - Sp(1) \\ S(t) &= S(t-1) + Q_T(t) - R(t) - Ev(t) - Sp(t); \quad \forall t = 2, \dots, N \end{aligned} \quad (4)$$

onde  $S(t)$  é o volume do reservatório no final do mês  $t$ ;  $S_0$  é o volume inicial;  $Q_T(t)$  é a vazão afluente ao sistema durante o mês  $t$ ;  $Ev(t)$  é a evaporação sobre a superfície líquida do reservatório durante o mês  $t$ ; e  $Sp(t)$  é o vertimento que eventualmente pode ocorrer durante o mês  $t$ .

As limitações físicas do sistema definem as restrições para alocações, volume e vertimento.

$$0 \leq R(t) \leq D(t); \quad \forall t \quad (5)$$

$$S_{\text{morto}} \leq S(t) \leq S_{\text{max}}; \quad \forall t \quad (6)$$

$$Sp(t) \geq 0; \quad \forall t \quad (7)$$

$$Ev(t) \geq 0; \quad \forall t \quad (8)$$

onde  $S_{\text{max}}$  e  $S_{\text{morto}}$  são os volumes máximo e morto do reservatório, respectivamente.

Este modelo de otimização, formulado como um problema de programação quadrática com restrições lineares, é implementado em MATLAB.

### 3.4.3. Regras Operacionais por meio de Redes Neurais Artificiais

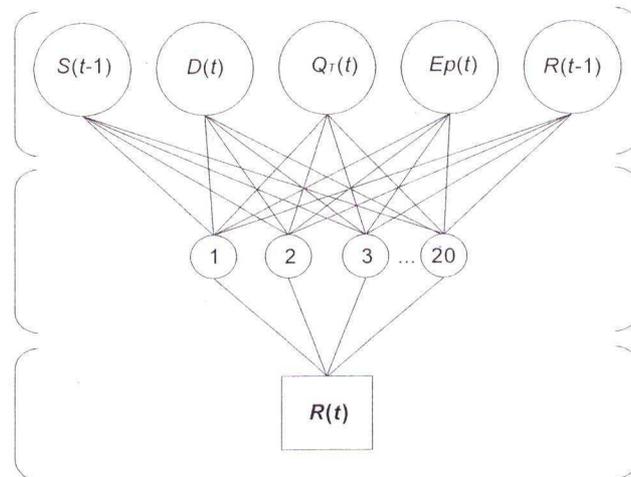
O modelo é uma rede neural alimentada adiante com múltiplas camadas treinada pelo conhecido algoritmo de retropropagação. Este modelo é responsável pela derivação das regras de operação baseadas nos resultados ótimos obtidos pelo modelo de otimização determinístico.

A arquitetura da RNA é formada por uma camada de entrada, uma oculta e uma de saída. A camada de entrada é composta de cinco neurônios, que são o volume inicial do reservatório  $S(t-1)$ , a vazão afluente corrente  $Q_T(t)$ , evaporação potencial corrente  $Ep(t)$ , demanda corrente  $D(t)$  e alocação anterior  $R(t-1)$ . O número de neurônios na camada oculta é obtido através de um processo baseado em tentativa e erro. Os melhores resultados foram obtidos com 20 neurônios na camada oculta.

O valor de alocação  $R(t)$  é o único neurônio da camada de saída. A estrutura da rede está mostrada na Figura 5.

Funções sigmóides foram usadas para os neurônios da camada oculta e uma função linear foi utilizada no neurônio de saída.

Os dados originais (entradas e saídas desejadas) são convenientemente escalonados para melhorar a eficiência na calibração da RNA (Demuth *et al.*, 2008). O algoritmo escolhido para a calibração é o de retropropagação de erro, o qual tem sido utilizado com sucesso em vários campos da engenharia. Nesta aplicação, o algoritmo Levenberg-Marquardt (LM) foi usado para retropropagação. A RNA tem a sua calibração encerrada pelo *Early Stopping Method* (Demuth *et al.*, 2008).



**Figura 5.** Estrutura da RNA responsável pela definição das regras de operação.

### 3.5. Modelo de Simulação

Para efeitos de simulação, o balanço hídrico do Sistema Coremas - Mãe d'Água é representado pela Equação 9.

$$\begin{aligned}
 V(1) &= V_0 + Q(1) - R(1) - Sp(1) - Ev(1) \\
 V(t) &= V(t-1) + Q(t) - R(t) - Sp(t) - Ev(t); \quad \forall t = 2, \dots, N
 \end{aligned}
 \tag{9}$$

onde  $N$  é o horizonte de operação;  $V(t)$  é o volume do reservatório no final do mês  $t$ ;  $V_0$  é volume inicial do reservatório;  $Q(t)$  é a vazão afluente ao reservatório no mês  $t$ ;  $R(t)$  é a alocação de água no mês  $t$ ;  $Sp(t)$  é o vertimento que porventura poderá ocorrer; e  $Ev(t)$  é a evaporação no mês.

O SLOP foi aplicado para simulação do reservatório Coremas Mãe – D'Água, considerando o funcionamento do sistema segundo a Equação 9.

### 3.6. Índices de Sustentabilidade

Vários critérios de risco têm sido estudados com o objetivo de identificar a sustentabilidade de sistemas de abastecimento de água. Hashimoto *et al.* (1982) propôs um conjunto de indicadores (confiabilidade, resiliência e vulnerabilidade) visando a verificação do desempenho e a seleção de políticas alternativas de operação para sistemas hídricos. Este estudo faz uso dos índices de confiabilidade e vulnerabilidade para avaliar o desempenho dos procedimentos aplicados.

#### 3.6.1. Confiabilidade

Este indicador avalia a probabilidade do sistema não falhar. Matematicamente, a confiabilidade pode ser definida como a probabilidade de um sistema estar em um estado satisfatório dentro do horizonte de operação conforme Equação 10.

$$REL = \text{Prob}\{TS_t \in S_{ST}\} = 1 - \frac{NF}{N} \quad (10)$$

onde  $REL$  é a confiabilidade;  $TS_t$  é uma série temporal condicionada ao índice de tempo  $t$  ( $t = 1, 2, \dots, N$ );  $S_{ST}$  é o conjunto de estados satisfatórios; e  $NF$  é o número de intervalos de tempo nos quais ocorreram falhas.

#### 3.6.2. Vulnerabilidade

Este índice avalia a magnitude das falhas do sistema e é definido como segue:

$$VUL = \frac{1}{FE} \sum_{fe=1}^{FE} DEF_{fe} \quad (11)$$

onde  $VUL$  é a vulnerabilidade,  $FE$  é o número total de eventos com falhas; e  $DEF_{fe}$  é o volume do déficit do  $fe$ -ésimo evento com falha.

### 3.6.3. Computação dos Índices

Os índices de risco são utilizados para avaliar o desempenho do sistema ao longo das séries temporais de alocações de água. O estado satisfatório é condicionado às liberações para atender as demandas desejadas. Os indicadores foram analisados para vários níveis  $\eta$  de demanda ( $\eta = 5\%, 10\%, \dots, 100\%$ ). Conseqüentemente, para um dado  $\eta$ , o estado de falha ocorria quando as liberações eram menores que  $\eta$  por cento das respectivas demandas.

Neste estudo, o índice de vulnerabilidade para cada período foi calculado pelo desvio quadrado entre alocações e demandas. Desta forma, se  $VUL^\eta(t)$  indica a vulnerabilidade no período  $t$ , então:

$$VUL^\eta(t) = \begin{cases} \left[ \frac{R(t) - \eta D(t)}{\eta D(t)} \right]^2, & \text{se } R(t) < \eta D(t) \\ 0, & \text{se } R(t) \geq \eta D_c(t) \end{cases} \quad (12)$$

A vulnerabilidade total é obtida pela soma das vulnerabilidades para cada período  $t$ , como pode ser visto a seguir:

$$VUL^\eta = \sum_{t=1}^N VUL^\eta(t) \quad (13)$$

O valor final da vulnerabilidade  $VUL_F^\eta$ , em porcentagem, é finalmente dado pela seguinte equação:

$$VUL_F^\eta = \frac{VUL^\eta}{VUL_{\max}^{100}} \cdot (100) \quad (14)$$

onde  $VUL_{\max}^{100}$  é o maior valor de vulnerabilidade para  $\eta = 100\%$  dentre todos os modelos avaliados.

## 4. RESULTADOS E DISCUSSÃO

### 4.1. Modelo Chuva-Vazão por meio de Redes Neurais Artificiais

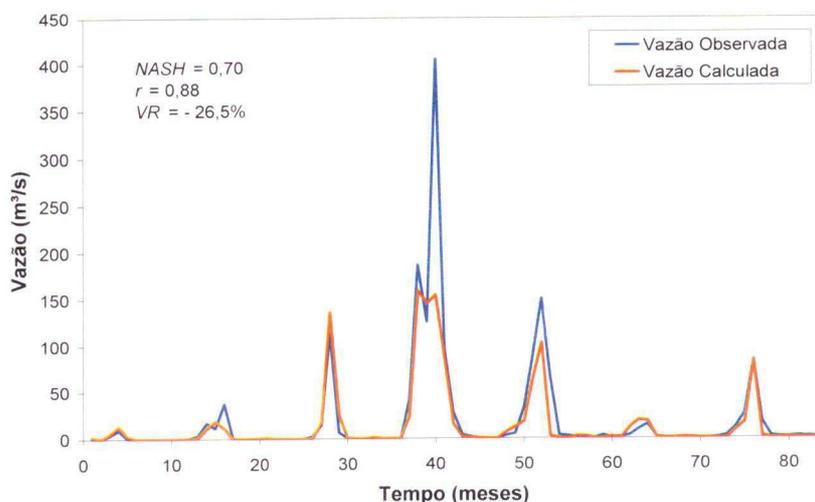
Os índices de correlação, viés relativo e *NASH*, calculados para todos os conjuntos de dados (calibração e teste), encontram-se na Tabela 4.

**Tabela 4.** Correlação, viés relativo e *NASH* entre as vazões mensais calculadas e observadas.

Calibração (treinamento e validação)			Teste		
<i>R</i>	<i>VR</i>	<i>NASH</i>	<i>R</i>	<i>VR</i>	<i>NASH</i>
0,87	-10,30%	0,75	0,88	-26,5%	0,70

A Figura 6 mostra um comparativo entre as previsões mensais de vazão obtidas com o modelo de RNA e os correspondentes valores observados de vazão para o posto fluviométrico investigado. Vale notar que estes gráficos mostram os resultados para o período de testes, ou seja, para uma série de dados totalmente independente daquelas utilizadas para calibração (treinamento e validação) do modelo.

Os resultados mostram que as previsões do modelo de RNA possuem alta correlação com os valores observados. Os valores de viés relativo no conjunto de testes apresentaram-se bastante razoáveis, tendo em vista que uma das limitações das RNA é atingir os picos de vazão em virtude do pequeno número de exemplos de treinamento para eventos extremos. A tendência é que esta limitação se restrinja com o futuro aumento no número de dados observados. Os valores do *NASH*, tanto na calibração como no teste, foram maiores ou iguais a 0,70, o que indica que as previsões mensais de vazão possuem boa qualidade. O modelo calibrado foi utilizado para preencher falhas nos postos fluviométricos de Emas e Aguiar. Para isto, os dados de entrada do modelo foram compostos das médias de precipitações observadas nos postos pluviométricos listados nas Tabelas 5 e 6.



**Figura 6.** Comparação entre previsões mensais de vazão obtidas com o modelo RNA e os valores observados no posto Piancó durante os sete anos do período de teste (1982–1988).

**Tabela 5.** Postos utilizados para preenchimento de falhas no posto fluviométrico de Emas.

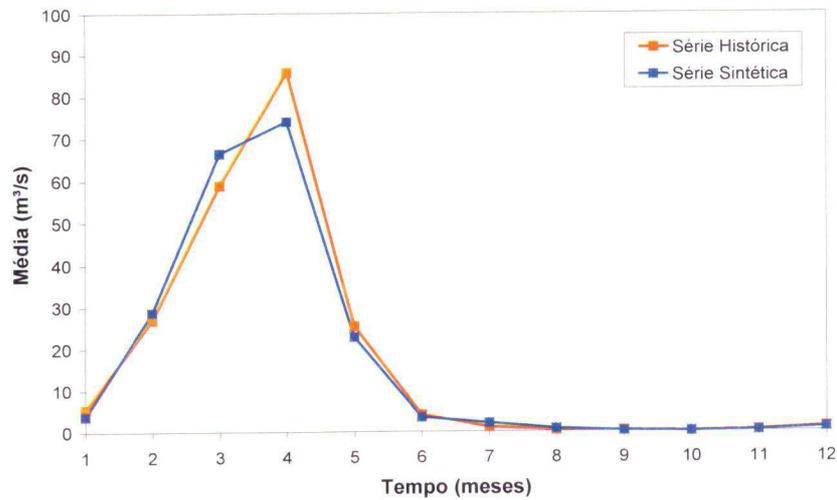
Código	Nome do posto	Tipo	Município
737021	Catingueira	Pluviométrico	Catingueira
738016	Juru	Pluviométrico	Juru
738017	Imaculada	Pluviométrico	Imaculadas

**Tabela 6.** Postos utilizados para preenchimento de falhas no posto fluviométrico de Aguiar.

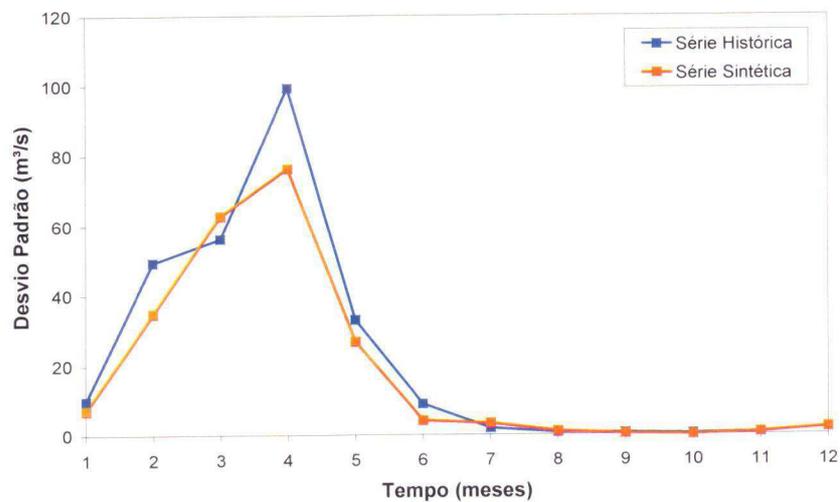
Código	Nome do posto	Tipo	Município
738010	Serra Grande	Pluviométrico	Serra Grande
737019	Açude Coremas	Pluviométrico	Coremas

#### 4.2. Geração Estocástica de Vazões

As estatísticas (médias e desvios padrões mensais) das vazões geradas pelo MF foram bastante satisfatórias quando comparadas com as das vazões históricas, como pode ser visto nas Figuras 7 e 8.



**Figura 7.** Comparação entre as médias da série sintética obtida pelo MF com os valores das médias da série histórica utilizada pelo modelo.



**Figura 8.** Comparação entre os desvios padrão da série sintética obtida pelo MF com os valores dos desvios padrão da série histórica utilizada pelo modelo.

Com estes resultados, é possível sugerir que os dados gerados são de boa qualidade e, portanto, que o modelo se adaptou bem às características da região semiárida.

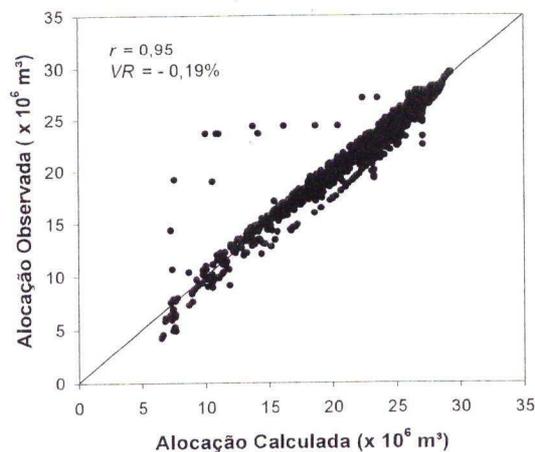
### 4.3. Regras Operacionais por meio de OEI e RNA

O MF foi utilizado para gerar 24000 valores mensais (2000 anos) de vazões afluentes ao reservatório Coremas - Mãe d'Água. O procedimento de OEI foi aplicado e obteve 24.000 valores ótimos de alocações mensais. Os dados de

volume inicial, vazão afluente, evaporação potencial, demanda e alocação anterior foram agrupados e treinados pela RNA descrita para geração de regras operacionais. O modelo OEI-RNA foi calibrado utilizando-se 90% dos dados (50% para treinamento e 40% para validação) e testado com os outros 10%.

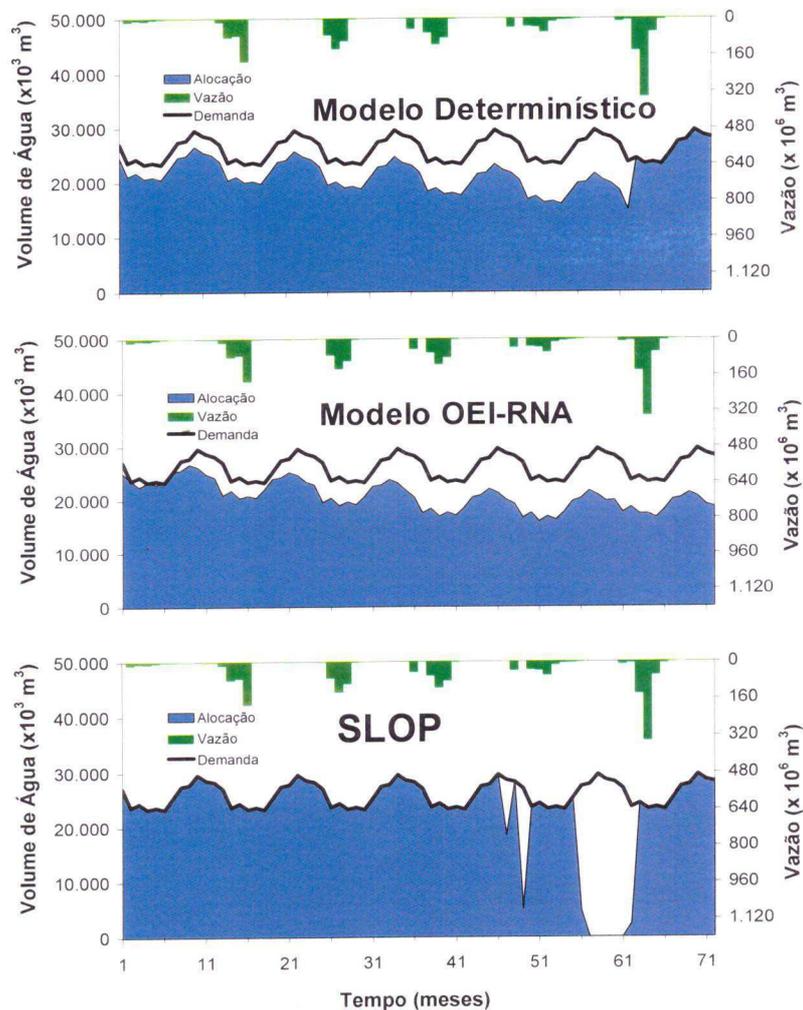
A Figura 9 apresenta o gráfico de correlação entre os valores de alocação observados e os valores calculados pela RNA para o período de testes.

O alto valor de correlação combinado com o baixo valor de viés relativo entre as alocações calculadas e observadas para o período de testes indica que o modelo de RNA é muito confiável para derivação de alocações metas.



**Figura 9.** Gráfico de correlação entre os valores de alocações observadas e os valores calculados pela RNA para o período de testes.

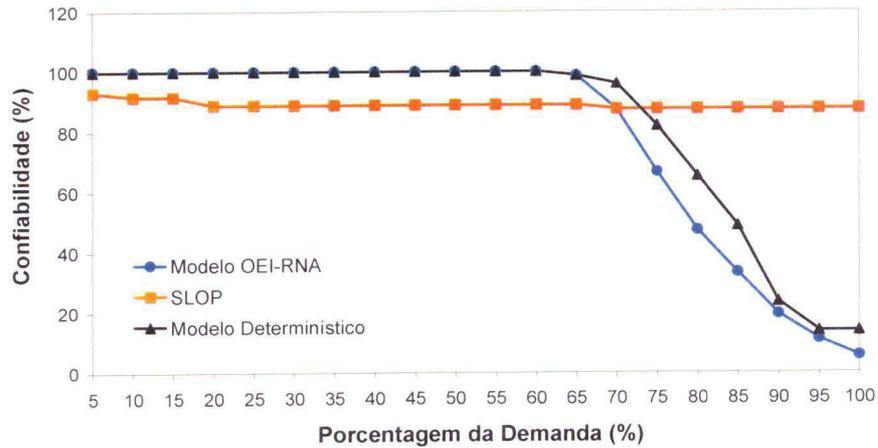
Para verificar o desempenho do modelo OEI-RNA, uma nova sequência de aflúências ao reservatório Coremas – Mãe d'Água com seis anos de dados mensais foi gerada através do método MF. Resultados obtidos pela aplicação do modelo de otimização determinístico foram utilizados para efeitos de comparação. O modelo determinístico fornece valores “ideais” de alocações uma vez que conhece as aflúências para todo o horizonte de operação e, portanto, possui melhores meios para derivar regras operacionais superiores. Simulações baseadas no modelo SLOP também foram utilizadas para comparação. A Figura 10 mostra os resultados de alocações para todos os modelos nos seis anos simulados.



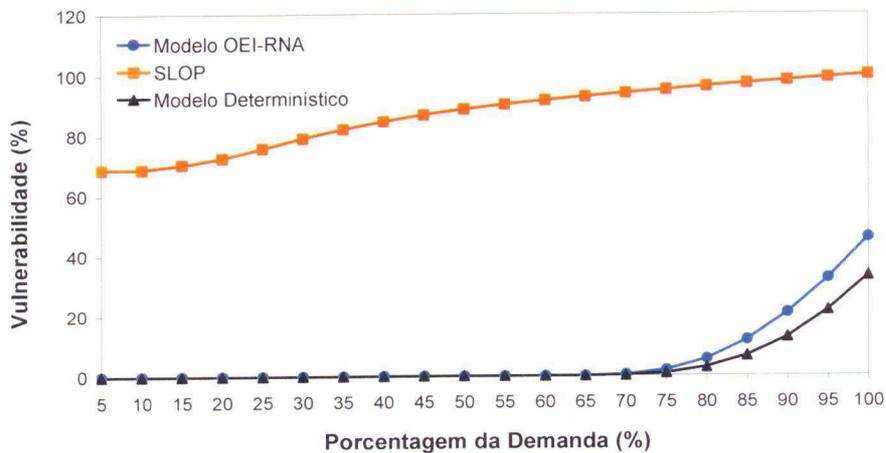
**Figura 10.** Alocação de água através dos modelos: determinístico, OEI-RNA e SLOP.

Comparando os resultados do modelo OEI-RNA com o SLOP, pode-se notar que o modelo OEI-RNA tenta mitigar os déficits concentrados que acontecem com o SLOP pela diminuição das alocações antes dos períodos secos de forma a diminuir a magnitude destes déficits. Análises da Figura 10 mostram que na operação com o modelo OEI-RNA o volume do reservatório se comporta de maneira similar à operação com o modelo determinístico. Esta informação indica que os resultados derivados são satisfatórios, uma vez que o modelo OEI-RNA tem informações apenas sobre o volume inicial e de variáveis hidrológicas para o mês corrente, enquanto o modelo determinístico tem conhecimento de vazões para todo o horizonte de operação.

Os resultados de confiabilidade e vulnerabilidade para todos os modelos e níveis de demanda estão apresentados nas Figuras 11 e 12.



**Figura 11.** Índice de confiabilidade para todos os modelos.



**Figura 12.** Índice de vulnerabilidade para todos os modelos.

Uma investigação do resultado apresentado na Figura 11 mostra que o modelo determinístico e o modelo OEI-RNA foram mais confiáveis que o SLOP para a maioria dos níveis de demanda, com exceção dos altos níveis de demanda ( $\eta > 70\%$ ). Este resultado era esperado, uma vez que os modelos determinístico e OEI-RNA tentam diminuir as alocações antes dos períodos secos para reduzir a magnitude dos déficits e, conseqüentemente, aumentar o número de períodos com falhas para atender altos níveis de demanda. Análises da Figura 12 sugerem que os modelos determinístico e OEI-RNA são bem menos vulneráveis que o SLOP para todos os níveis de demanda.

## 5. CONCLUSÃO

Este estudo teve como principal objetivo a formulação e aplicação de regras operacionais mensais para o reservatório Coremas - Mãe d'Água, localizado no semiárido nordestino. O procedimento consistiu em gerar regras operacionais através de Otimização Estocástica Implícita e Redes Neurais Artificiais.

O modelo OEI-RNA foi aplicado para operar o sistema considerando-se um cenário mensal sintético de seis anos. Os resultados do modelo OEI-RNA foram equivalentes aos resultados obtidos pelo modelo determinístico e superiores aos encontrados pela Política de Operação Padrão (SLOP);

As operações simuladas tiveram seus resultados analisados por critérios de sustentabilidade, representados aqui pelos índices de confiabilidade e vulnerabilidade. Os resultados mostraram que as operações simuladas pelo modelo OEI-RNA e pelo modelo determinístico foram mais confiáveis e menos vulneráveis que o SLOP.

O modelo determinístico apresentou os melhores resultados, porém, é impraticável. Por outro lado, o modelo OEI-RNA mostrou resultados semelhantes e pode ser uma ferramenta útil na tomada de decisão para operação sustentável de sistemas hídricos no semiárido.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

ANA – Agência Nacional de Águas. Disponível em <http://hidroweb.ana.gov.br/>, acessado em 27/09/2010.

ARAÚJO, J. K.; CAMPUS, J. N. B. **Utilização do método dos fragmentos no estudo da disponibilidade hídrica de açudes no semi-árido** in Anais do IX Simpósio Brasileiro de Recursos Hídricos, Rio de Janeiro, Vol. 1. pp. 467-474, 1991.

CELESTE, A. B., CURI, W. F., CURI, R. C.: **Análise de Métodos para Geração Sintética de Vazões, XVII Simpósio Brasileiro de Recursos Hídricos**, 18p. 2007.

CELESTE, A. B., K. SUZUKI., A. KADOTA, V. S. Santos: **Derivation of reservoir operating rules by implicit stochastic optimization**, Annual Journal of Hydraulic Engineering, JSCE, 49(2), pp. 1111–1116, 2005.

CELESTE, A. B., K. SUZUKI., A. KADOTA., C. A. S. FARIAS: **Stochastic generation of inflow scenarios to be used by optimal reservoir operation models**, Annual Journal of Hydraulic Engineering, JSCE, 48(1), pp. 451-456, 2004.

DEMUTH H.; BEALE, M.; HAGAN, M. **Neural Network Toolbox 6: User's Guide**. The MathWorks Inc Natick, USA, 907 p, 2008.

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.

HASHIMOTO, T., J. R. STEDINGER., D. P. LOUCKS: **Reliability, resiliency, and vulnerability criteria for water resource system performance evaluation**, *Water Resources Research*, 18(1), pp. 14-20, 1982.

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

- 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.
- LOUCKS, D. P. **Sustainable water resources management.** Water International, IWRA 25(1), pp. 3-10, 2000.
- LOUCKS, D. P., J. R. STEDINGER., D. A. Haith: **Water Resources Systems Planning and Analysis**, Prentice Hall, Englewood Cliffs, USA, 1981.
- LUDERMIR, T. B; CARVALHO, A. P.; BRAGA, A. de P.: **Redes Neurais Artificiais, Teoria e Aplicações.** 203p. 2º edição, Rio de Janeiro – RJ, Editora LTC, 2007.
- MOLLER, M. F.: **Scaled conjugate gradient algorithm for fast supervised learning**, Neural Networks, Vol. 6 (4), pp. 525-533, 1993.
- REDDY, P. J. **Stochastic Hydrology.** Laxmi Publications, Delhi, Índia, 1987.
- SALAS, J. D.: **Analysis and modeling of hydrologic time series**, in Handbook of Hydrology, edited by D. R. Maidment, Chap. 19, pp. 19.1-19.72, McGraw-Hill Inc., New York, USA, 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.
- SVANIDZE, G. G. **Mathematical Modeling of Hydrologic Series** (for Hydroelectric and Water Resources Computations). Water Resources Publications, Fort Collins, Colorado, 1980.
- THOMAS, H. A.; FIERING, M. B. “**Mathematical synthesis of stream-flow sequences for the analysis of river basins by simulation**”, in **Design of Water Resource Systems.** Org. por Maass *et al.*, Harvard Univ. Press, Cambridge, Massachusetts, pp. 459-493, 1962.
- VAJPEYI, D. K. **Water Resource Management: A Comparative Perspective**, Praeger Publishers, USA, 1998.

WILLIS, R., B. A. FINNEY., W.-S. Chu: **Monte Carlo optimization for reservoir operation**, Water Resources Research, 20(9), pp. 1177-1182, 1984.

YOUNG, G. K., Jr.: **Finding reservoir operating rules**, Journal of the Hydraulic Division, ASCE, 93(HY6), pp. 297-321, 1967.

## ANEXOS

Tabela 7. Dados fluviométricos (m<sup>3</sup>/s) utilizados na pesquisa.

	Emas	Piarcó	Aguiar	Total
jan/63	1,35	0,00	0,00	1,35
fev/63	7,09	0,00	11,74	18,83
mar/63	7,71	0,00	14,82	22,53
abr/63	0,25	0,00	8,87	9,11
mai/63	0,00	0,00	0,20	0,20
jun/63	0,00	0,00	0,00	0,00
jul/63	0,00	0,00	0,00	0,00
ago/63	0,00	0,00	0,00	0,00
set/63	0,00	0,00	0,02	0,02
out/63	0,00	0,00	0,00	0,00
nov/63	3,68	0,00	0,09	3,78
dez/63	1,18	3,49	0,41	5,08
jan/64	8,15	17,10	0,49	25,74
fev/64	13,87	0,00	0,76	14,63
mar/64	20,94	69,90	1,20	92,03
abr/64	0,78	89,10	2,33	92,22
mai/64	0,01	9,24	0,49	9,74
jun/64	0,00	3,15	0,00	3,15
jul/64	0,00	0,11	0,00	0,11
ago/64	0,00	0,00	0,03	0,03
set/64	0,00	0,00	0,02	0,02
out/64	0,00	0,00	0,00	0,00
nov/64	0,00	0,00	0,00	0,00
dez/64	0,00	0,81	0,00	0,81
jan/65	0,00	2,45	0,00	2,45
fev/65	11,75	1,52	0,13	13,41
mar/65	28,77	15,00	0,87	44,64
abr/65	6,36	37,10	3,54	47,00
mai/65	0,27	5,13	0,19	5,59
jun/65	0,02	1,10	0,00	1,12
jul/65	0,00	0,09	0,06	0,15
ago/65	0,00	0,00	0,04	0,04
set/65	0,00	0,00	0,02	0,02
out/65	0,00	0,00	0,00	0,00
nov/65	0,00	0,00	0,14	0,14
dez/65	0,00	0,00	0,00	0,00
jan/66	0,27	0,00	0,00	0,27
fev/66	0,00	1,64	0,55	2,19
mar/66	0,82	1,22	0,11	2,15
abr/66	0,37	0,72	0,12	1,21
mai/66	0,00	0,41	0,09	0,51
jun/66	0,00	0,30	0,00	0,30
jul/66	0,00	0,06	0,04	0,10
ago/66	0,00	0,00	0,05	0,05
set/66	0,00	0,00	0,03	0,03
out/66	0,00	0,00	0,00	0,00
nov/66	0,00	0,00	0,16	0,16
dez/66	0,00	0,11	0,06	0,18
jan/67	8,02	0,39	0,00	8,41
fev/67	11,13	0,19	0,79	12,11
mar/67	28,80	85,80	3,20	117,80
abr/67	10,97	186,00	6,39	203,36
mai/67	0,29	96,40	1,06	97,75
jun/67	0,04	5,07	0,00	5,11
jul/67	0,00	0,47	0,00	0,47
ago/67	0,00	0,05	0,00	0,05
set/67	0,00	0,00	0,05	0,05
out/67	0,00	0,00	0,00	0,00
nov/67	0,00	0,00	0,00	0,00
dez/67	1,42	0,00	0,00	1,42
jan/68	0,81	1,05	0,00	1,86
fev/68	19,16	3,33	0,00	22,49
mar/68	1,43	111,00	1,11	113,54
abr/68	12,76	8,87	0,80	22,42
mai/68	0,54	7,85	0,23	8,62
jun/68	0,16	2,11	0,00	2,27
jul/68	0,01	1,03	0,00	1,04
ago/68	0,00	0,19	0,10	0,29
set/68	0,00	0,00	0,02	0,02
out/68	0,00	0,00	0,00	0,00
nov/68	0,00	0,00	0,00	0,00
dez/68	0,00	0,00	0,00	0,00
jan/69	0,00	0,00	0,02	0,02
fev/69	6,50	7,92	0,02	14,45
mar/69	8,72	0,00	1,10	9,82
abr/69	0,18	0,00	3,71	3,89
mai/69	0,01	2,61	0,19	2,81
jun/69	0,01	1,57	0,00	1,58

Tabela 7. Dados fluviométricos (m<sup>3</sup>/s) utilizados na pesquisa (continuação).

	Emas	Piencó	Aguiar	Total
jul/69	0,00	1,13	0,00	1,13
ago/69	0,00	0,40	0,18	0,58
set/69	0,00	0,00	0,01	0,01
out/69	0,00	0,00	0,00	0,00
nov/69	0,00	0,00	0,00	0,00
dez/69	3,13	0,00	0,00	3,13
jan/70	0,02	5,00	0,04	5,06
fev/70	1,24	0,57	0,00	1,80
mar/70	0,15	31,20	1,06	32,42
abr/70	0,01	2,78	2,32	5,12
mai/70	0,00	0,46	0,20	0,66
jun/70	0,00	0,00	0,00	0,00
jul/70	0,00	0,00	0,00	0,00
ago/70	0,00	0,00	0,00	0,00
set/70	0,00	0,00	0,04	0,04
out/70	0,00	0,00	0,00	0,00
nov/70	0,00	0,00	0,12	0,12
dez/70	0,10	0,00	0,00	0,10
jan/71	0,82	6,24	0,00	7,06
fev/71	2,86	62,50	0,81	66,17
mar/71	16,49	60,80	1,34	78,63
abr/71	0,96	109,00	1,25	111,20
mai/71	2,28	24,80	0,62	27,70
jun/71	0,00	7,07	0,03	7,10
jul/71	0,00	2,39	0,00	2,39
ago/71	0,00	0,74	0,08	0,82
set/71	0,00	0,00	0,00	0,00
out/71	0,00	0,00	0,01	0,01
nov/71	0,00	0,00	0,00	0,00
dez/71	0,01	0,00	0,00	0,01
jan/72	0,48	0,08	0,04	0,60
fev/72	2,51	6,43	1,48	10,42
mar/72	0,57	13,30	2,39	16,25
abr/72	0,00	15,10	4,36	19,46
mai/72	0,00	4,51	0,23	4,74
jun/72	0,00	1,18	0,00	1,18
jul/72	0,00	1,45	0,00	1,45
ago/72	0,00	0,09	0,00	0,09
set/72	0,00	0,01	0,24	0,25
out/72	0,00	0,03	0,00	0,03
nov/72	0,00	0,01	0,10	0,11
dez/72	0,27	0,01	0,00	0,29
jan/73	0,00	8,56	0,15	8,71
fev/73	1,16	10,20	1,01	12,36
mar/73	18,09	16,20	1,59	35,88
abr/73	10,46	111,00	14,87	136,33
mai/73	1,29	20,70	2,89	24,88
jun/73	0,12	6,41	0,56	7,09
jul/73	0,22	1,20	0,07	1,49
ago/73	0,00	0,52	0,00	0,52
set/73	0,13	0,00	0,02	0,15
out/73	0,15	0,00	0,00	0,15
nov/73	0,00	0,00	0,13	0,13
dez/73	4,09	0,21	0,00	4,30
jan/74	20,46	21,80	1,28	43,54
fev/74	20,97	82,80	8,00	111,77
mar/74	21,89	200,00	8,48	230,37
abr/74	8,73	170,00	15,38	194,11
mai/74	0,42	30,00	2,72	33,14
jun/74	0,00	3,93	0,00	3,93
jul/74	0,20	1,42	0,00	1,62
ago/74	0,00	0,25	0,05	0,30
set/74	0,00	0,00	0,00	0,00
out/74	0,11	0,00	0,00	0,11
nov/74	0,84	0,00	0,54	1,38
dez/74	0,47	0,00	0,00	0,47
jan/75	1,72	0,00	0,03	1,75
fev/75	17,80	6,65	7,22	31,67
mar/75	20,40	69,20	15,22	104,82
abr/75	13,59	41,40	10,81	65,81
mai/75	0,69	27,20	0,37	28,26
jun/75	0,63	4,90	0,00	5,53
jul/75	0,12	8,48	0,00	8,60
ago/75	0,07	2,41	0,20	2,68
set/75	0,00	0,55	0,02	0,57
out/75	0,00	0,00	0,00	0,00
nov/75	0,00	0,00	0,00	0,00
dez/75	0,14	0,00	0,00	0,14

Tabela 7. Dados fluviométricos (m<sup>3</sup>/s) utilizados na pesquisa (continuação).

	Emas	Piencó	Aguiar	Total
jan/76	1,23	0,00	0,00	1,23
fev/76	3,11	10,40	0,88	14,39
mar/76	4,32	10,90	4,66	19,88
abr/76	1,21	13,10	0,58	14,89
mai/76	0,00	0,51	0,00	0,51
jun/76	0,00	0,11	0,00	0,11
jul/76	0,00	0,00	0,00	0,00
ago/76	0,00	0,00	0,00	0,00
set/76	0,00	2,28	0,03	2,31
out/76	0,13	0,41	0,00	0,54
nov/76	0,06	0,97	0,10	1,13
dez/76	0,06	0,10	0,07	0,23
jan/77	1,27	2,04	0,00	3,31
fev/77	5,22	7,86	1,24	14,31
mar/77	19,05	20,50	5,84	45,40
abr/77	5,69	63,40	14,51	83,60
mai/77	0,22	72,80	14,32	87,34
jun/77	0,00	3,48	3,55	7,03
jul/77	0,19	0,54	0,17	0,90
ago/77	0,15	0,08	0,00	0,23
set/77	0,00	0,00	0,02	0,02
out/77	0,00	0,00	0,00	0,00
nov/77	0,32	0,00	0,00	0,32
dez/77	0,08	0,00	0,36	0,44
jan/78	0,61	1,82	0,58	3,01
fev/78	1,14	10,50	5,09	16,73
mar/78	1,43	28,10	4,13	33,66
abr/78	0,87	10,80	4,59	16,26
mai/78	0,17	13,50	1,04	14,71
jun/78	0,00	0,59	0,00	0,59
jul/78	0,29	0,11	0,00	0,40
ago/78	0,00	0,09	0,00	0,09
set/78	0,00	0,00	0,02	0,02
out/78	0,00	0,00	0,00	0,00
nov/78	0,10	0,00	0,00	0,10
dez/78	0,00	0,00	0,14	0,14
jan/79	1,25	0,28	0,00	1,53
fev/79	0,75	15,30	9,29	25,34
mar/79	2,02	58,40	15,00	75,42
abr/79	1,47	50,10	6,65	58,22
mai/79	0,08	28,40	0,25	28,73
jun/79	0,00	1,00	0,00	1,00
jul/79	0,00	0,08	0,00	0,08
ago/79	0,00	0,00	0,00	0,00
set/79	0,00	0,00	0,01	0,01
out/79	0,00	0,00	0,00	0,00
nov/79	0,14	0,00	0,05	0,19
dez/79	0,00	0,00	0,03	0,03
jan/80	1,27	0,00	0,00	1,27
fev/80	2,21	32,30	7,11	41,62
mar/80	0,40	89,70	4,21	94,32
abr/80	0,00	0,73	0,30	1,03
mai/80	0,00	0,03	0,00	0,03
jun/80	0,00	0,00	0,00	0,00
jul/80	0,04	0,00	0,00	0,04
ago/80	0,03	0,00	0,00	0,03
set/80	0,00	0,00	0,02	0,02
out/80	0,02	0,00	0,00	0,02
nov/80	0,18	0,13	0,00	0,31
dez/80	0,03	5,73	0,07	5,83
jan/81	0,30	0,07	0,00	0,37
fev/81	4,89	12,30	0,94	18,14
mar/81	2,44	51,50	11,65	65,60
abr/81	0,00	42,90	0,00	42,90
mai/81	0,00	0,18	0,00	0,18
jun/81	0,00	0,00	0,00	0,00
jul/81	0,00	0,00	0,00	0,00
ago/81	0,03	0,00	0,00	0,03
set/81	0,00	0,00	0,02	0,02
out/81	0,00	0,00	0,00	0,00
nov/81	0,03	0,00	0,39	0,42
dez/81	0,09	0,92	0,67	1,68
jan/82	0,00	0,26	0,08	0,34
fev/82	0,00	0,03	0,73	0,77
mar/82	3,34	3,54	0,75	7,63
abr/82	2,69	8,88	3,91	15,48
mai/82	0,14	0,60	0,89	1,63
jun/82	0,00	0,02	0,00	0,02

Tabela 7. Dados fluviométricos (m<sup>3</sup>/s) utilizados na pesquisa (continuação).

	Emas	Piencó	Aguiar	Total
jul/82	0,10	0,00	0,00	0,10
ago/82	0,00	0,00	0,00	0,00
set/82	0,00	0,00	0,02	0,02
out/82	0,00	0,00	0,00	0,00
nov/82	0,00	0,00	0,00	0,00
dez/82	0,00	0,20	0,10	0,30
jan/83	1,22	3,18	0,00	4,40
fev/83	2,04	16,60	0,94	19,58
mar/83	1,20	11,00	2,49	14,69
abr/83	0,00	37,40	2,05	39,45
mai/83	0,00	0,09	0,15	0,24
jun/83	0,00	0,00	0,00	0,00
jul/83	0,00	0,00	0,00	0,00
ago/83	0,16	0,00	0,00	0,16
set/83	0,00	0,00	0,11	0,11
out/83	0,00	0,00	0,00	0,00
nov/83	0,00	0,00	0,00	0,00
dez/83	0,00	0,00	0,00	0,00
jan/84	0,00	0,00	0,00	0,00
fev/84	1,10	2,29	0,67	4,06
mar/84	12,44	14,00	3,22	29,66
abr/84	4,09	113,00	13,35	130,44
mai/84	0,05	6,28	4,54	10,88
jun/84	0,00	0,15	0,17	0,32
jul/84	0,00	0,01	0,00	0,01
ago/84	0,00	0,00	0,00	0,00
set/84	0,00	0,00	0,14	0,14
out/84	0,00	0,00	0,00	0,00
nov/84	0,00	0,00	0,00	0,00
dez/84	0,63	0,00	0,03	0,66
jan/85	39,84	40,30	1,40	81,54
fev/85	6,91	186,00	12,25	205,16
mar/85	20,74	125,00	15,47	161,21
abr/85	4,13	405,00	16,50	425,63
mai/85	17,22	95,30	4,89	117,42
jun/85	0,43	27,70	0,61	28,74
jul/85	0,06	3,95	0,03	4,03
ago/85	0,01	1,50	0,00	1,51
set/85	0,00	0,30	0,10	0,40
out/85	0,00	0,00	0,00	0,00
nov/85	0,03	0,00	0,40	0,44
dez/85	0,03	2,97	0,46	3,45
jan/86	4,55	4,99	0,49	10,03
fev/86	34,69	32,40	9,54	76,63
mar/86	43,84	90,00	13,59	147,44
abr/86	5,90	150,00	0,24	156,14
mai/86	0,44	64,70	0,00	65,14
jun/86	0,19	3,38	0,00	3,57
jul/86	0,06	2,31	0,00	2,37
ago/86	0,01	0,70	0,00	0,71
set/86	0,00	0,01	0,02	0,03
out/86	0,00	0,00	0,00	0,00
nov/86	0,00	2,90	0,00	2,90
dez/86	0,00	0,10	0,00	0,10
jan/87	0,01	1,23	2,26	3,50
fev/87	2,88	2,85	0,00	5,73
mar/87	0,72	9,44	0,00	10,16
abr/87	0,00	14,50	0,00	14,50
mai/87	0,00	1,26	0,00	1,26
jun/87	0,00	0,22	0,00	0,22
jul/87	0,00	0,13	0,00	0,13
ago/87	0,00	0,00	0,00	0,00
set/87	0,00	0,00	0,02	0,02
out/87	0,00	0,00	0,00	0,00
nov/87	0,00	0,00	0,35	0,35
dez/87	0,00	0,41	0,99	1,40
jan/88	0,61	2,38	2,86	5,85
fev/88	4,04	11,30	1,98	17,31
mar/88	39,61	26,00	0,13	65,74
abr/88	2,71	84,00	0,00	86,71
mai/88	0,40	17,60	0,00	18,00
jun/88	0,08	2,00	0,00	2,08
jul/88	0,00	0,75	0,00	0,75
ago/88	0,00	0,72	0,00	0,72
set/88	0,00	1,39	0,02	1,41
out/88	0,00	1,33	0,00	1,33
nov/88	0,00	1,01	0,00	1,01
dez/88	0,00	4,21	0,00	4,21