Campus de São Carlos

**MODELAGEM DE SÉRIES FLUVIOMÉTRICAS
PARA O SEMI-ÁRIDO BRASILEIRO VIA
REDES NEURAIS ARTIFICIAIS**

Fábio Lavor Teixeira

ORIENTADORA: Prof. Luisa Fernanda Ribeiro Reis

UNIVERSIDADE DE SÃO PAULO

**ESCOLA DE ENGENHARIA
DE SÃO CARLOS**

Serviço de Pós-Graduação EESC/USP

EXEMPLAR REVISADO

Data de entrada no Serviço: 27 / 08 / 03

Ass.: *[Assinatura]*

Modelagem de Séries Fluviométricas para o Semi-Árido Brasileiro via Redes Neurais Artificiais

Fábio Lavor Teixeira

Dissertação apresentada à Escola de
Engenharia de São Carlos, da Universidade
de São Paulo, como parte dos requisitos para
obtenção do título de Mestre em Hidráulica e
Saneamento

ORIENTADORA: Prof. Luisa Fernanda Ribeiro Reis

DEDALUS - Acervo - EESC

31100044167

São Carlos
2003

Class. TESE - EESC
Cutt. 59761
Tombo T275103
Sysno 1329811

T266m

Teixeira, Fábio Lavor

Modelagem de séries fluviométricas para o semi-árido brasileiro via redes neurais artificiais / Fábio Lavor Teixeira. -- São Carlos, 2003.

Dissertação (Mestrado) -- Escola de Engenharia de São Carlos-Universidade de São Paulo, 2003.

Área : Hidráulica e Saneamento.

Orientador: Prof^a. Dr^a. Luisa Fernanda Ribeiro Reis.

1. Redes neurais artificiais. 2. Séries fluviométricas. 3. Modelagem de vazões. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **FÁBIO LAVOR TEIXEIRA**

Dissertação defendida e julgada em 28-03-2003 perante a Comissão Julgadora:

Profa. Dra. **LUISA FERNANDA RIBEIRO REIS** (Orientadora)
(Escola de Engenharia de São Carlos/USP)

Aprovado

Prof. Tit. **FAZAL HUSSAIN CHAUDHRY**
(Escola de Engenharia de São Carlos/USP)

APROVADO

Prof. Assoc. **PAULO SÉRGIO FRANCO BARBOSA**
(Universidade Estadual de Campinas/UNICAMP)

aprovado

Profa. Associada **MARIA DO CARMO CALJURI**
Coordenadora do Programa de Pós-Graduação em
Engenharia (Hidráulica e Saneamento) e
Presidente da Comissão de Pós-Graduação

*À minha avó e madrinha Dionéia Teixeira,
pelo enorme carinho a mim dedicado,
por ser meu “anjo-da-guarda”
e para que possa continuar tendo sempre
muito orgulho do seu “doutorzinho”.*

AGRADECIMENTOS

À Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela bolsa de estudo concedida.

Às Secretárias do Departamento de Hidráulica e Saneamento, Pavi, Sá e Rose, pelo carinho sempre demonstrado, atenção e presteza.

Aos professores e funcionários do SHS pelas diversas vezes em que, com muita dedicação, me acompanharam e auxiliaram nas mais diversas etapas deste mestrado. Dentre estes, um agradecimento especial ao Prof. Fazal, pela co-orientação e pelas inúmeras “idéias” lançadas e acompanhadas durante o caminhar da pesquisa e nessa fase final.

Aos amigos do SHS, e também de outros departamentos, em especial à turma do Laboratório de Simulação Numérica, pelo companheirismo e amizade.

Aos amigos da CAGECE, Engesoft e Colégio 7 de Setembro, pelo imenso apoio nas mais diversas horas e formas, além da troca de experiências e conhecimentos.

A todos os meus primos, tios, avós e amigos pelo incentivo, em especial nessa fase final de trabalho, onde ele foi muito importante.

Aos meus irmãos George, Cláudia e Luciana por terem me acompanhado de perto estimulando e acreditando sempre em mim.

À minha namorada Maria Luiza pela compreensão nos momentos de afastamento, pelo encorajamento nas horas difíceis, pelo empenho que me fez ter.

À minha orientadora Profa. Luísa Fernanda Ribeiro Reis todo e qualquer tipo de agradecimento ainda seria insuficiente para externar a minha enorme gratidão, não somente pela orientação acadêmica, mas

também pela paciência, compreensão, o eterno bom-humor, dedicação e a extrema alegria com que ela sempre me recebia, trocava idéias e orientava.

Aos meus pais Lúgia e Luiz Helvécio, pelo amor em que minha vida foi gerada, desenvolvida e acompanhada, pelos exemplos de vida que são e sempre foram, pela importância que têm na minha vida não só durante a fase deste mestrado.

A Deus, por tudo.

Agradeço

SUMÁRIO

<i>Lista de Figuras.....</i>	<i>i</i>
<i>Lista de Tabelas.....</i>	<i>iii</i>
<i>Lista de Abreviaturas e Siglas.....</i>	<i>v</i>
<i>Lista de Símbolos.....</i>	<i>vi</i>
RESUMO.....	1
ABSTRACT.....	2
1. INTRODUÇÃO.....	3
2. OBJETIVOS.....	8
3. REVISÃO BIBLIOGRÁFICA.....	10
4. REDES NEURAIS ARTIFICIAIS.....	29
4.1 INTRODUÇÃO.....	30
4.2 NEURÔNIO BIOLÓGICO.....	32
4.3 NEURÔNIOS ARTIFICIAIS.....	37
4.4 HISTÓRICO.....	40
4.5 COMPONENTES DAS RNAs.....	43
4.6 MODELAGEM ATRAVÉS DE RNAs.....	47
4.7 ALGORITMO BACKPROPAGATION.....	50
4.8 OUTROS TIPOS DE RNAs.....	54
5. SISTEMA E MÉTODOS DE ESTUDO.....	58
5.1 DESCRIÇÃO DO SISTEMA.....	59
5.2 MODELAGEM DE SÉRIES TEMPORAIS.....	69
5.3 MODELAGEM VIA RNAs.....	75
6. RESULTADOS E DISCUSSÕES.....	88
6.1 MODELOS UNIVARIADOS.....	89
6.2 MODELOS MULTIVARIADOS.....	103
6.3 VERIFICAÇÃO DOS MODELOS.....	112
7. CONCLUSÕES.....	116
REFERÊNCIAS BIBLIOGRÁFICAS.....	121
ANEXOS.....	129
APÊNDICES.....	149

LISTA DE FIGURAS

FIGURA 1 – Neurônio Biológico	33
FIGURA 2 – Impulso Nervoso	35
FIGURA 3 – Neurônio Artificial	39
FIGURA 4 – Rede Neural com Quatro Camadas.....	48
FIGURA 5 – Rede Neural com Três Camadas.....	51
FIGURA 6 – Fortaleza e sua Região Metropolitana.....	59
FIGURA 7 - Fluxograma da Modelagem Adotada	85
FIGURA 8 – Auto-correlações Histórica e Modelada – Acarape do Meio	91
FIGURA 9 – Auto-correlações Histórica e Modelada – Gavião	94
FIGURA 10 – Auto-correlações Histórica e Modelada – Sítios Novos	96
FIGURA 11 – Auto-correlações Histórica e Modelada – Choró-Limão.....	99
FIGURA 12 – Séries Histórica e Simulada (modelo univariado) – Acarape do Meio	101
FIGURA 13 – Séries Histórica e Simulada (modelo univariado) – Gavião	101
FIGURA 14 – Séries Histórica e Simulada (modelo univariado) – Sítios Novos	102
FIGURA 15 – Séries Histórica e Simulada (modelo univariado) – Choró-Limão	102
FIGURA 16 – Séries Histórica e Simulada (modelo multivariado) – Acarape do Meio	110
FIGURA 17 – Séries Histórica e Simulada (modelo multivariado) – Gavião ...	110
FIGURA 18 – Séries Histórica e Simulada (modelo multivariado) – Sítios Novos	111
FIGURA 19 – Séries Histórica e Simulada (modelo multivariado) – Choró- Limão	111
FIGURA 20 – Resíduos – Série Afluente ao Reservatório Acarape do Meio ..	113

FIGURA 21 – Resíduos – Série Afluente ao Reservatório Gavião	113
FIGURA 22 – Resíduos – Série Afluente ao Reservatório Sítios Novos	113
FIGURA 23 – Resíduos – Série Afluente ao Reservatório Choró-Limão	114

LISTA DE TABELAS

TABELA 1 – Reservatórios Analisados.....	62
TABELA 2 – Evaporação média em Tanque Classe A	66
TABELA 3 – Açudes Analisados com seus Postos Fluviométricos	68
TABELA 4 – Valores Relevantes para os Modelos Univariados.....	80
TABELA 5 – Nós das Camadas de Entrada – Modelagem Multivariada I.....	81
TABELA 6– Nós das Camadas de Entrada – Modelagem Multivariada II.....	82
TABELA 7– Nós das Camadas de Entrada – Modelagem Multivariada IV	83
TABELA 8 – Médias Mensais	89
TABELA 9 – Desvio-padrão.....	90
TABELA 10 – Valores de X_{MIN} e X_{MAX}	90
TABELA 11 – Auto-correlações Modelada (M) e Histórica (H) – Acarape do Meio	91
TABELA 12 – Melhores Resultados - Acarape do Meio	92
TABELA 13 – Características Estatísticas das Séries Modelada e Histórica – Acarape do Meio	92
TABELA 14 – Auto-correlações Modelada (M) e Histórica (H) – Gavião	93
TABELA 15 – Melhores Resultados - Gavião.....	94
TABELA 16 – Características Estatísticas das Séries Modelada e Histórica – Gavião.....	95
TABELA 17 – Auto-correlações Modelada (M) e Histórica (H) – Sítios Novos .	96
TABELA 18 – Melhores Resultados - Sítios Novos	97
TABELA 19 – Características Estatísticas das Séries Modelada e Histórica – Sítios Novos	97
TABELA 20 – Auto-correlações Modelada (M) e Histórica (H) – Choró-Limão.	98
TABELA 21 – Melhores Resultados – Choró-Limão.....	99

TABELA 22 – Características Estatísticas das Séries Modelada e Histórica - Choró-Limão.....	100
TABELA 23 – Melhores Resultados para a Modelagem Multivariada	104
TABELA 24 - Pesos W_{IJ}	104
TABELA 25 - Pesos W_{JK}	105
TABELA 26 – Biases B2	105
TABELA 27 – Biases B3	105
TABELA 28 – Características Estatísticas das Séries Modelada e Histórica – Acarape do Meio	106
TABELA 29 – Características Estatísticas das Séries Modelada e Histórica – Gavião.....	107
TABELA 30 – Características Estatísticas das Séries Modelada e Histórica – Sítios Novos	108
TABELA 31 – Características Estatísticas das Séries Modelada e Histórica - Choró-Limão.....	109

LISTA DE ABREVIATURAS E SIGLAS

ANNs -	Artificial Neural Networks
ARIMA -	Autoregressive Integrated Moving Average
ARMA -	Autoregressive Moving Average
EP -	Elemento de Processamento
MSE -	Mean Square Error
PSR -	Phase Space Reconstruction
RNSPs -	Redes Neurais sem Pesos
RMF -	Região Metropolitana de Fortaleza
RMSE -	Root Mean Square Error
RNAs -	Redes Neurais Artificiais
SNNS -	Stuttgart Neural Network Simulator
VLSI -	Very Large Scale Integration

LISTA DE SÍMBOLOS

b -	Bias
g -	Coefficiente de distorção
r -	Autocorrelação
x -	Entrada das RNAs, vazão
w -	Pesos sinápticos
y -	Saída das RNAs
φ -	Função de ativação
μ -	Média
σ -	Desvio padrão
ρ -	Autocovariância
θ -	Thresholds
ψ -	Conjunto de funções de base ortogonal

subscrições:

i -	meses, camada de entrada
j -	anos, primeira camada intermediária
k -	camada de saída
z -	segunda camada intermediária
$\max$ -	valor máximo da série
$\min$ -	valor mínimo da série
$'$ -	vazão dessazonalizada
$''$ -	vazão padronizada

RESUMO

Teixeira, F. L. (2003). *Modelagem de séries fluviométricas para o semi-árido brasileiro via redes neurais artificiais*. São Carlos, 162p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo

As Redes Neurais Artificiais (RNAs) vêm sendo empregadas com cada vez mais sucesso em diversas áreas de pesquisa, no campo da engenharia e em outros campos diversos. Neste trabalho foram modeladas séries fluviométricas relativas às afluições a quatro reservatórios, localizados em quatro bacias hidrográficas distintas que compõem a Bacia Metropolitana de Fortaleza, Ceará, Brasil. Tais afluições apresentam peculiaridades relativas à ocorrência de magnitudes nulas, que dificultam sua modelagem através dos convencionais modelos estatísticos da família Box-Jenkins. Neste estudo foram trabalhadas duas abordagens distintas, a primeira univariada, em que cada série era modelada de forma individual, e a segunda multivariada, em que as séries fluviométricas eram modeladas simultaneamente. Os resultados obtidos, segundo ambas as modelagens, demonstram que a técnica apresenta potencial para a aplicação pretendida. Estudos futuros merecem ser desenvolvidos ainda no sentido de verificar a melhor maneira de se enquadrar a componente aleatória nas séries sintéticas produzidas via RNAs.

Palavras-chave: redes neurais artificiais, séries fluviométricas, modelagem de vazões.

ABSTRACT

Teixeira, F. L. (2003). *Discharge time series modeling applied to rivers from Northeast of Brazil using artificial neural networks*. São Carlos, 162p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo

Artificial Neural Networks (ANNs) are being used more and more in many different fields of research, in engineering applications or other applications. This research deals with modeling of inflows to four reservoirs, located in different watersheds that belong to the Metropolitan Watershed of Fortaleza city, Brazil. These discharge sequences have particular characteristics in that they have frequent occurrence of null discharges which makes it difficult to use traditional statistical models such as those Box-Jenkins family. Two different modeling approaches were adopted in this study, the first univariate, in which each time series was modeled individually, and the second multivariate, in which the four time series were modeled simultaneously. The results from the both approaches show that the technique has potential for use in water resources planning and management. Future studies are required to propose better means of incorporating the random component in the generation of synthetic time series through ANNs.

Keywords: artificial neural networks, discharge time series, discharge modeling.

1. INTRODUÇÃO

O Nordeste brasileiro sempre sofreu, e continua sofrendo, com o fenômeno climático das secas. O Ceará, por ter seu território inserido no semi-árido nordestino, não é uma exceção.

Tecnicamente é um equívoco afirmar que chove pouco no Ceará. São poucas as regiões do mundo onde chove em média mais de 1.000 (mil) milímetros. No Litoral e na Ibiapaba a média de chuva é superior a este valor. O Cariri e o Maciço de Baturité têm quase esta pluviosidade. O diagnóstico mais correto é que o Ceará é uma região cuja evaporação é das mais altas do mundo, cerca de 2.000 a 2.500 milímetros por ano, isto é, mais de três vezes a média geral de chuva do Estado, cerca de 750 milímetros. Afora tudo isto, um chão que se assemelha a um piso cimentado, que não permite quase infiltração, obriga a água a descer rapidamente para o mar. (MACEDO, 1996)

Frente a esta realidade, uma quantidade imensa de estudos e inúmeras obras têm sido realizadas no Ceará, visando propiciar um melhor aproveitamento dos Recursos Hídricos face às características naturais e humanas. Dentre as obras mencionadas, pode-se citar a grande quantidade de barragens existentes, em construção e em fase de projeto, merecendo destaque os açudes Orós com capacidade máxima atual de 1,96hm³ (SOUZA FILHO, 1998) e Castanhão com capacidade de projeto de 6,0hm³, as diversas obras de interligação de bacias hidrográficas dentro do Estado e os estudos pertinentes à transposição de águas do rio São Francisco.

Nas últimas décadas, as transferências hídricas (entre bacias) têm sido vistas, cada vez mais, como fontes adicionais para o suprimento de água de sistemas urbanos. Os esforços para adicionar água transferida para tais sistemas são motivados pelos altos custos de expansão das fontes de suprimento tradicionais, aliados ao custo, à inconveniência e às limitações dos altos níveis de qualidade exigidos na conservação de água e ao retorno econômico relativamente baixo de

muitos usos agrícolas da água (LUND & ISRAEL, 1995). Tendo em vista este paradigma que está direcionando os novos planos de gerenciamento de recursos hídricos, o sistema de abastecimento de água de Fortaleza, juntamente com sua região metropolitana, é feito com base em uma infra-estrutura montada sobre um conjunto de reservatórios e de um sistema de canais e adutoras que possibilitam a transposição de águas entre reservatórios, quando necessário. Tal sistema tem reduzido sensivelmente a ocorrência de falhas. Falhas estas que representariam além de indústrias paradas e interrupções na irrigação a paralisação do suprimento de água para o abastecimento humano de mais de 2 (dois) milhões de pessoas que residem na área abastecida.

Além dessa estruturação física, a construção de obras para viabilizar a oferta frente à demanda, requer uma série de estudos no sentido de coletar dados a serem empregados na gestão otimizada desses escassos recursos hídricos regionais. Um destes estudos é o de previsão de vazões. Quando as vazões naturais em uma seção de um curso d'água são insuficientes para atender à demanda, seja para fins de abastecimento, seja para a produção de energia, a construção e operação de reservatórios requerem estudos sobre a seqüência de vazões naturais, que podem ser diárias, semanais, quinzenais, mensais, trimestrais e anuais. A partir de dados observados, procura-se construir um modelo matemático que exprima as principais características hidrológicas dessa série temporal, permitindo, assim, a geração sintética de cenários ou seqüências de vazões possíveis de ocorrer no futuro.

Existem classes de modelos para geração sintética de dados hidrológicos, como vazões naturais nos cursos d'água a partir de dados pluviométricos e fluviométricos, dentre as quais se destacam os modelos Box-Jenkins (1976), já consagrados na área. Sabe-se, entretanto, que os modelos Box-Jenkins não se adequam muito bem às

características das séries temporais de vazões naturais, que são consequência do regime irregular das chuvas no Nordeste brasileiro.

Existe uma tendência atual de modelagem do processo de sucessão de vazões naturais através de Redes Neurais Artificiais (RNAs), que acredita-se ser uma maneira mais eficiente de reprodução desse processo pelo fato de admitirem não-linearidades características do processo, dentre outras vantagens.

De maneira geral, pode-se definir uma Rede Neural Artificial como um sistema constituído por elementos de processamento interconectados, chamados de neurônios, os quais estão dispostos em camadas e são responsáveis pela não-linearidade da rede, através do processamento interno de funções matemáticas. Esta estrutura foi concebida a partir de estudos sobre a fisiologia do cérebro humano e do seu componente primário, o neurônio. As redes neurais são "aproximadores universais de funções", ou seja, conseguem reproduzir o comportamento de, virtualmente, qualquer função matemática. Tal capacidade fez com que as RNAs se popularizassem, rapidamente, como uma ferramenta "caixa-preta" para modelar relações entre variáveis, de modo semelhante aos métodos estatísticos de regressão. Apesar de serem, às vezes, incorretamente utilizadas "às cegas", o projeto adequado e o entendimento correto do seu funcionamento são essenciais para o seu emprego adequado (GALVÃO, 1999).

As RNAs aplicam regras de aprendizagem que são responsáveis pela modificação dos pesos sinápticos a cada ciclo de iteração, de acordo com os exemplos que lhe são apresentados. Assim, pode-se dizer que as RNAs aprendem por exemplos. (VALENÇA, 1999)

Ultimamente, diversos autores têm demonstrado a viabilidade de utilizar redes neurais artificiais para geração sintética de séries temporais (CHAKRABORTY et al, 1992), (ZANDONADE & SOUZA, 1993), (LECHTERMATER, 1992), (TANG et al., 1991). SHARDA e PATIL (1990) mostram que a performance das redes neurais é

comparável a obtida com o método de Box-Jenkins, (apud BALLINI et al, 1997). Na área de recursos hídricos, mais especificamente, as RNAs vêm sendo empregadas com bastante sucesso.

O presente trabalho aplicou a metodologia de modelagem de séries temporais, através do uso de Redes Neurais Artificiais (RNAs), para séries fluviométricas de aflúências a açudes localizados na Região Metropolitana de Fortaleza-Ceará, que apresentam particularidades tais como vazões praticamente nulas durante a estação seca.

O presente texto foi organizado de maneira que no Capítulo 2 são apresentados os Objetivos da pesquisa. No capítulo 3 é descrita a Revisão Bibliográfica, enquanto no capítulo 4 é feita uma abordagem geral sobre o histórico e os diversos tipos de Redes Neurais Artificiais objetos de estudos e pesquisas cujas aplicações já vêm demonstrando sucesso nas diversas áreas de conhecimento. O capítulo 5, Sistema e Métodos de Estudo, discorre sobre as técnicas empregadas nessa pesquisa e a região de estudo, bem como suas características geográficas. No capítulo 6 são apresentados os Resultados juntamente com as discussões advindas dos mesmos, enquanto no capítulo 7 são mostradas as conclusões finais e são sugeridas algumas outras pesquisas, pertinentes ao assunto tratado, que enriqueceriam o tema e complementariam o escopo dessa pesquisa.

2. OBJETIVOS

Face ao exposto no capítulo anterior, definiu-se como objetivo do presente trabalho de pesquisa revisitar a problemática de modelagem de séries temporais de vazões naturais afluentes aos reservatórios dos sistemas das bacias hidrográficas componentes da região metropolitana de Fortaleza (RMF), dada a sua importância como fonte de abastecimento da cidade de Fortaleza, no Estado do Ceará.

Com vistas ao gerenciamento de longo prazo do sistema de abastecimento de Fortaleza, pretende-se, mais especificamente, investigar a viabilidade de emprego das RNAs para:

- Modelar séries temporais univariadas na base mensal para os postos do referido sistema em estudo; e
- Modelar séries temporais multivariadas na base mensal para os postos do mesmo sistema.

3. REVISÃO BIBLIOGRÁFICA

...”Muito do que se fez até agora (no Ceará) em matéria de recursos hídricos não teve critério técnico ou qualquer planejamento hidrológico. As novas obras terão oportunidade de obedecer a um plano mais racional e mais econômico. A nova política de açudagem deve atender mais à hidrologia do que à hidráulica”... Com essas palavras, o então secretário de recursos hídricos do governo do estado do Ceará, Hypérides Macedo, fez uma breve descrição do quadro que se apresentava a todos em 1996. Essa fria realidade se fazia/faz presente não somente no estado do Ceará, mas também em outras regiões do Brasil. Deve-se buscar, nos inúmeros trabalhos e nas experiências já adquiridas, soluções para as dificuldades enfrentadas tanto no contexto da hidrologia, em pauta, quanto nos diversos outros contextos em que já existam tais experiências, sejam elas na forma de *revisões bibliográficas* ou em qualquer outra.

Sobre o sistema em foco, SOUZA FILHO (1998) já realizou um estudo preliminar onde foram levantados diversos dados de demandas atuais e projetadas para o futuro. No mesmo trabalho foram utilizados cenários diferentes com relação à infra-estrutura hidráulica do sistema, ora utilizando apenas a existente e ora utilizando uma série de obras que ainda estavam em fase de construção, como o açude do Castanhão, e/ou em fase de projeto, como um canal de transposição (Eixo Sertão-Central). Para a construção destes cenários foi utilizado o modelo MODSIM, modelo de simulação desenvolvido pelo Prof. Labadi da Colorado State University e interface gráfica desenvolvida na Escola Politécnica da USP pelo Prof. Rubem Porto. Entretanto, segundo relato do próprio autor, as séries que esse estudo preliminar utilizou não são muito consistentes, o que pode ter prejudicado os resultados. Além disso, o MODSIM é de natureza determinística.

VIANA & GONDIM FILHO (1999) também já realizaram estudos sobre o sistema alvo desta pesquisa. Utilizaram previsões

climatológicas, gerando resultados mais consistentes e mais próximos da realidade.

Em outro trabalho, SOUZA FILHO (1999) analisou o impacto de se adicionar novos perímetros de irrigação no sistema e testou a sua garantia.

Acredita-se, entretanto, que as análises de incerteza na operação do sistema, podem ser prejudicadas pela dificuldade de representação de possíveis séries temporais, quer pela inconsistência das séries existentes, quer pela problemática modelagem do processo de sucessão de vazões com características de intermitência.

A modelagem de séries de vazões para múltiplos locais é largamente utilizada no planejamento da operação de sistemas de recursos hídricos de grande porte que usualmente abrangem extensas regiões, contemplando mais de uma bacia hidrográfica. A literatura mostra a existência de um grande número de modelos estocásticos multivariados para séries temporais (PEREIRA, 1984), ainda que para séries temporais sazonais haja um número bem menor de trabalhos, podendo ser destacado o artigo de SALAS & PEGRAM (1977). O motivo da timidez na proposição de modelos multivariados para séries temporais sazonais está em que estes são modelos claramente não-parcimoniosos, que têm identificação complexa e onde a estimação dos parâmetros é sujeita a uma grande imprecisão (VIEIRA et al., 1998).

Ainda segundo SALAS et al. (1980), quando periodicidade, componentes estocásticas e intermitência são fatores presentes em séries multivariadas, a complexidade é tamanha que, para que tenhamos uma descrição estatística confiável e capaz de possibilitar a modelagem destas séries, é necessário que sejam empregadas as mais sofisticadas técnicas de análises. Nas séries analisadas no presente trabalho, tais fatores descritos acima estão presentes.

Uma boa referência sobre o uso de modelos estocásticos multivariados em hidrologia é o trabalho de CAMACHO et al. (1985).

A viabilidade do emprego de Redes Neurais Artificiais, como alternativa eficiente aos modelos clássicos, vem sendo comprovada, principalmente nos últimos anos, no cenário internacional.

LACHTERMACHER & FULLER (1993) utilizaram uma metodologia híbrida, que consistia em usar a metodologia Box-Jenkins em uma fase exploratória para identificar algumas importantes relações nas séries de dados. Baseada nessas informações era definida uma estrutura inicial de pequeno porte para uma rede neural, o que diminuía bastante o tempo de modelagem, reduzindo o número de parâmetros e eliminando, segundo os autores, a principal desvantagem do uso de RNAs, que é a grande quantidade de dados necessários para as fases de treinamento e validação da rede

O procedimento de modelagem foi subdividido então em duas fases, a exploratória, onde eram determinadas as características básicas da série empregada e a fase de modelagem propriamente dita, onde as informações obtidas na fase exploratória eram utilizadas para a obtenção de uma primeira arquitetura da rede.

O processo de treinamento/validação foi baseado na metodologia de Weigend (WEIGEND et al. 1990, 1991). Para evitar a necessidade de usar os dados reais para validação, foi gerada uma série sintética com as mesmas propriedades estatísticas da série original, usando o procedimento de simulação de Waterloo (HIPEL & McLEOD, 1993) para esta validação. A performance da previsão, nessa validação, foi monitorada como sugerido por (WEIGEND et al. 1990, 1991), e o critério de convergência foi baseado nessa performance, tendo sido adotado o RMSE (raiz do erro médio quadrado). Quando o RMSE começava a crescer, ou decrescer, muito lentamente, o processo era interrompido, a fim de se evitar o "superaprendizado" e a conseqüente deterioração das propriedades gerais do modelo resultante.

Foi utilizada uma rede puramente *feedforward*, ou seja, as unidades em uma camada somente influenciavam as unidades mais a frente (mais próximas da camada de saída); com uma camada de entrada, uma camada escondida (intermediária) e uma única unidade de saída. A função de ativação empregada pelos autores foi a função sigmóide (não-linear) e o algoritmo usado foi o de *backpropagation*. O número de neurônios das camadas de entrada e intermediária variaram de acordo com o modelo Box-Jenkins, no caso ARMA, calibrado e com a quantidade de dados disponíveis para a fase de treinamento.

Foram analisadas quatro séries estacionárias distintas. Para os quatro casos estudados pelos autores, o uso desta metodologia se mostrou efetivo, com erros inferiores aos apontados pelas modelagens tradicionais.

TANG et al. (1991) realizaram um estudo comparativo entre modelagem de séries temporais através de RNAs e da metodologia Box-Jenkins. Eles trabalharam com três séries de diferentes complexidades, usando sempre redes do tipo *feedforward*, com o algoritmo *backpropagation*, e as modelagens Box-Jenkins padrão. As séries modeladas eram de dados de passageiros de linhas aéreas internacionais (longa memória), vendas de carros importados nos Estados Unidos (longa memória) e vendas de carros nacionais (curta memória), também dos Estados Unidos. As séries foram modeladas através dos *softwares* TIMESLAB (NEWTON, 1988), para a metodologia Box-Jenkins, e o programa *Back Propagation* (BP) no pacote computacional *Parallel Distributed Processing* de McLelland e Rumelhart (1988).

As redes treinadas tinham todas três camadas, a camada de entrada, uma única camada intermediária e uma camada de saída. O número de neurônios da camada intermediária foi adotado com sendo igual ao da camada de entrada, que foram 1, 6, 12 e 24, correspondendo a um mês, seis meses, um ano e dois anos de dados,

respectivamente. O número de neurônios da camada de saída foi 1, 6, 12 e 24, correspondendo ao período que se desejava prever. Também foi utilizado o termo de *momentum*, como elemento de melhoria na qualidade do algoritmo *backpropagation*.

Para as previsões de 1 mês e 6 seis meses os modelos Box-Jenkins apresentaram resultados superiores aos das RNAs, enquanto que para as previsões de 12 e 24 meses os modelos com metodologia de RNAs forma superiores.

Os experimentos demonstraram que para as séries com longa memória as duas metodologias apresentaram resultados comparáveis. Enquanto que para as séries com curta memória a modelagem através de redes neurais artificiais apresentou resultados superiores. Também foi digno de nota o fato das RNAs serem modelos mais parcimoniosos.

Um outro trabalho de relevância foi desenvolvido por CHAKRABORTY et al. (1992). Eles utilizaram RNAs para realizar uma modelagem multivariada representando o comportamento da variação de preços da farinha de trigo em três cidades, Búfalo, Mineápolis e cidade de Kansas, nos E.U.A., e compararam sua performance com a de um modelo desenvolvido seguindo o proposto por TIAO & TSAY (1989).

As redes eram do tipo *feedforward*, com uso do algoritmo *backpropagation*, incrementado pelo termo adicional de *momentum* e da taxa de aprendizagem adaptativa. O conjunto de dados disponíveis referia-se a dados mensais do período de agosto de 1972 a novembro de 1980, perfazendo um total de 100 dados mensais. O critério de comparação entre as duas modelagens foi o MSE (*Mean Square Error*). Foram feitas previsões do tipo um-passo-a-frente (*lag one*) e do tipo vários-passos-a-frente (*multi-lag*) .

Foi realizada uma transformação logarítmica nos dados antes deles serem apresentados às redes para treinamento. Inicialmente

foram modeladas séries univariadas, para as três cidades, utilizando 90 dados no conjunto de treinamento e os 10 dados restantes no conjunto de validação. Foram feitas simulações com redes de topologias 2-2-1, 4-4-1, 6-6-1 e 8-8-1.

Após os modelos univariados ficarem prontos, foram treinadas, então, as redes que representariam a modelagem multivariada das três séries em questão.

Os resultados obtidos para as modelagens univariadas e multivariadas superaram, em alguns casos até por uma ordem de grandeza, os modelos autoregressivos média-móvel propostos por Tiao e Tsay. Uma outra constatação bem interessante foi o fato dos modelos multivariados terem superado os modelos univariados. Credita-se esse resultado às altas correlações apresentadas entre as três séries, o que significa que os dados de uma determinada série servem para prever não somente valores dessa mesma série, mas também das outras duas, e o fato de se ter mais um conjunto de dados três vezes maior, o que implica num treinamento mais refinado.

Dentro do campo da hidrologia e do gerenciamento de recursos hídricos, diversos autores vêm pesquisando também a aplicação de redes neurais artificiais com bastante sucesso.

SMITH & ELI (1995), MASON et al. (1996), MINNS & HALL (1996), DAWSON & WILBY (1998) e SAJIKUMAR & THANDAVESWARA (1999), aplicaram com sucesso diferentes tipos de RNAs para modelagem do processo de chuva-deflúvio.

SMITH & ELI (1995) aplicaram redes treinadas com o algoritmo *backpropagation*, uso do termo *momentum*, taxa de aprendizagem adaptativa e função sigmóide, implementados em linguagem FORTRAN 77. As redes consistiam de três camadas, 25 neurônios na camada de entrada, a camada intermediária variando de 2 a 50 neurônios e a camada de saída com 1 ou 2 neurônios, dependendo de

se modelar somente a vazão de pico, o horário da vazão de pico, ou os dois valores simultaneamente.

Nos resultados não foram notadas diferenças significativas entre as modelagens das variáveis separadas ou conjuntamente. Os autores imaginavam que com as duas variáveis sendo modeladas simultaneamente os resultados seriam melhores, devido ao fato de se trabalhar com mais informações, mas creditam os resultados à pouca correlação entre as variáveis para implicar em ganho real de reconhecimento de padrão pela rede.

MASON et al. (1996) utilizaram redes com funções de base radial para a modelagem chuva-deflúvio e compararam seus resultados aos obtidos com redes *perceptrons* de múltiplas camadas que usavam o *backpropagation*(BP) através do *Toolbox* específico para redes neurais do MATLAB. Eles concluíram que ao se utilizar o algoritmo BP, conforme sua definição original, os resultados são inferiores aos obtidos com as redes com função de base radial, mas quando o algoritmo BP era implementado através do termo de *momentum* e da taxa de aprendizagem adaptativa os resultados eram bem equivalentes, mas por outro lado o aprendizado era bem mais demorado do que o realizado através das redes com funções de base radial.

O trabalho de MINNS & HALL (1996) utilizou o programa BP-simulator, produzido pela IBP-Pietzsch GmbH de Ettlingen, Alemanha. Foram comparados os valores de redes com 3 e 4 camadas. Os resultados mostraram que as simulações, em relações a critérios estatísticos, média, desvio-padrão, foram bem representados e que, na maioria dos casos, as redes com 4 camadas simularam de uma maneira mais acurada os valores extremos, de máximos e mínimos, do que as de 3 camadas. Mesmo assim, o modelo desenvolvido não conseguiu representar bem estes valores extremos, onde foram constatados os maiores erros.

DAWSON & WILBY (1998) também acharam como resultados para o treinamento de diversas topologias distintas de RNAs que, em muitos casos, elas tendem a minimizar os valores de picos, embora em um caso específico elas tenham chegado a superestimar os valores de descarga máxima.

Recentemente, SIVAKUMAR et al. (2002) compararam duas metodologias do tipo “caixa-preta” para a previsão de vazões em rios. O estudo fez um confronto entre a previsão de séries através de redes neurais artificiais e o modelo *phase-space reconstruction* (PSR), segundo o qual qualquer sistema dinâmico pode ser descrito por um diagrama *phase-space*, que é, essencialmente um sistema de coordenadas. Tais coordenadas são todas as variáveis que entram na formulação matemática do sistema, isto é, as variáveis necessárias para descrever completamente o estado do sistema em qualquer momento. Uma descrição mais detalhada do modelo *phase-space reconstruction* pode ser vista em SIVAKUMAR (2000).

Foram trabalhadas as vazões diárias de um rio da Tailândia e a previsão foi realizada para vazões 1-dia-a-frente e 7-dias-a-frente. São ressaltados, mais uma vez, os cuidados na determinação dos conjuntos de treinamento e validação para ambas as modelagens. Para a modelagem através das RNAs, os dados foram normalizados no intervalo de $[0,1-0,9]$, foram utilizados o algoritmo *backpropagation* com adoção do termo de *momentum* e a taxa de aprendizagem adaptativa, e foi adotado como principal critério de parada o número de iterações.

Como camada de entrada, o estudo começou utilizando o mesmo número de dados para os dois modelos, e tentando ora com apenas uma entrada e ora com sete entradas (todas elas representando as vazões imediatamente anteriores). O melhor resultado obtido com apenas uma entrada não foi comparável ao pior obtido com as sete entradas, evidenciando a necessidade de se fornecer dados suficientes ao

aprendizado, quando foram testadas também simulações com três valores de entrada.

Na fase inicial, as redes eram treinadas durante mil iterações. Para as melhores topologias houve um outro período de treinamento, para se tentar diminuir o valor já encontrado para o erro, de mais quatro mil iterações. O que se constatou foi que o erro decresceu muito pouco, indicando que as mil primeiras iterações já haviam sido suficientes para se chegar a um treinamento satisfatório.

As conclusões gerais indicam que as duas metodologias, RNAs e PSR, chegaram a resultados muito bons mas, segundo os autores, a modelagem através de PSR foi considerada levemente superior.

KARUNANITHI et al. (1994), RAMAN & SUNILKUMAR (1995) e ZEALAND et al. (1999) também trabalharam com previsão de séries fluviométricas através do uso das RNAs e chegaram à conclusão de que elas apresentam resultados tão bons quanto as outras metodologias.

Esta tendência também pode ser comprovada em âmbito nacional, com o crescente número de trabalhos já publicados, além de estudos e pesquisas em andamento.

SOUZA et al. (1995) utilizaram uma arquitetura de redes neurais, estritamente *feedforward*, com o uso do algoritmo *backpropagation*, para a previsão de vazões diárias de um rio em um determinado posto, a partir de postos da mesma bacia situados a montante.

Foram estudadas duas abordagens distintas, a primeira consistia em se fazer a previsão das vazões deste rio no posto P nos dias (t), (t+1), (t+2), ..., (t+r), a partir das vazões do dia (t) em (n) postos situados a montante do posto em questão. A segunda abordagem consistia em se fazer a previsão das vazões diárias deste mesmo posto P para os dias (t), (t+1), (t+2), ..., (t+r), a partir das vazões diárias dos

dias (t) , $(t-1)$, $(t-2)$, ..., $(t-k)$ de (n) postos situados a montante do posto P.

Foi estudada a bacia do Alto Tocantins, com disponibilidade de dez anos de dados, para oito postos fluviométricos. Os seis primeiros anos serviram de dados para os treinamentos das redes, enquanto os últimos quatro anos de dados foram utilizados para a fase de validação dos modelos.

Infelizmente os autores não deixam claro, no trabalho, o critério de convergência do treinamento utilizado, nem os parâmetros de treinamento adotados, como a utilização ou não do termo *momentum*, e nem como é feita a normalização dos dados.

Os resultados obtidos levaram os autores a crer que as RNAs funcionam de modo altamente eficiente para o mapeamento das não-linearidades de um problema, uma grande vantagem em relação aos métodos estatísticos, entretanto, muito do aproveitamento das RNAs é creditado ao modelador, por não haver uma metodologia de determinação da arquitetura ótima das redes.

SARMENTO (1996) reproduziu a relação chuva-vazão para uma bacia localizada na região semi-árida do nordeste brasileiro através de uma RNA. No mesmo trabalho foi investigada a habilidade destas redes para a previsão de vazões médias diárias na bacia do rio Leine, localizada na região central da Alemanha. A arquitetura das redes foi definida por tentativa e erro, tendo o autor sido cuidadoso quanto ao número de neurônios que compôs a camada de entrada (*input*), correspondendo, teoricamente, ao número de variáveis que influenciam no fenômeno em foco. Uma das conclusões do trabalho foi que na aplicação deste método para variáveis hidrológicas, como chuva e vazão, em regiões semi-áridas a extensão da série requerida para a fase de treinamento da rede é bastante superior àquela que seria adequada para bacias de rios perenes, pois tais séries hidrológicas de regiões semi-áridas apresentam uma notória concentração de chuvas e

vazões em um único semestre, enquanto que para o restante do ano observam-se praticamente valores nulos. Estas características são bem semelhantes às da região em estudo.

MAIER e DANDY (1997) também pesquisaram a determinação do número de neurônios das camadas de entrada (*inputs*) para modelagens multivariadas de séries temporais. Eles fizeram um estudo comparativo entre três metodologias distintas, a saber: (1) metodologia de HAUGH & BOX (1977), que analisa os valores da função de correlação-cruzada para determinar a “força” das relações entre as entradas e saídas das séries temporais em diversos *lags*; (2) aproximação através de modelos univariados de redes neurais artificiais para as diversas séries com uma posterior análise de sensibilidade para diversos *lags* e (3) um método empírico onde se utilizava, como fator determinante para a escolha do número de entradas das RNAs, o conhecimento *a priori* das diversas relações entre os processos que influenciam as séries em estudo.

Os estudos mostraram que os resultados das metodologias 1 e 2 foram compatíveis uns com os outros e que ambos eram apropriados para a determinação do número de entradas para modelagens multivariadas.

Entretanto, embora os resultados tenham sido bem próximos, foram apontadas algumas vantagens na utilização da metodologia 2 sobre a metodologia 1:

- Ela pode determinar quais entradas são significantes para a previsão de períodos específicos, conseqüentemente reduzindo o número de entradas, o que reduz o tamanho da rede e o tempo de treinamento;
- Ela pode também providenciar informações valiosas sobre as relações entre as entradas e saídas das séries temporais

- É bem mais simples e rápida de se utilizar, pois dispensa os pré-processamentos dos dados necessários na metodologia 1.

A metodologia 3 apresentou resultados razoáveis, mas não tão bons quanto os apresentados pelas outras duas metodologias. Ainda como sugestão os autores relatam que o conhecimento físico do processo deve ser utilizado sempre que possível no desenvolvimento de modelagens de séries temporais, seja este desenvolvimento através de redes neurais artificiais ou não. Maier e Dandy concluem que onde o conhecimento dos processos físicos está disponível, ele deve ser utilizado como limitante do campo de entradas e *lags* considerados na metodologia 2, gerando uma espécie de mescla entre as metodologias 2 e 3, e para os casos onde este conhecimento não está disponível, a metodologia 2 deve ser utilizada.

VALENÇA (1997) comparou os resultados dos modelos, MOTHSTAR2, modelo hidrológico para o Trópico Semi-Árido, SMAP, que é um modelo determinístico de simulação hidrológica, ambos de simulação do processo chuva x vazão, com os resultados obtidos com o uso de redes neurais artificiais. Foram escolhidas para análise duas bacias hidrográficas do estado da Paraíba, uma do Ceará e uma de São Paulo. No mesmo trabalho é feita uma comparação da modelagem através de redes neurais artificiais com modelagens tradicionais de previsão de vazão x vazão. Os modelos utilizados foram VAZÃO, modelo de regressão múltipla, e PREVAVZ, baseado na metodologia Box-Jenkins.

As redes utilizadas no estudo foram todas do tipo *perceptron* de múltiplas camadas. Para a primeira bacia da Paraíba, bacia do Sumé, utilizou-se um período de três anos de dados, 1978 a 1980, para o treinamento das redes e o período de 1975 a 1976 para a validação. A rede neural que apresentou o melhor resultado era composta de três camadas, com 10 neurônios na camada de entrada, representando a sazonalidade, a evaporação e os últimos cinco meses de chuva, 20

neurônios na camada escondida e neurônio na camada de saída, que representava a vazão desejada. Para a bacia localizada no estado do Ceará, bacia da Juatama, dispunha-se de menos dados, correspondendo ao período de outubro de 1974 a setembro de 1977. A rede adotada era composta de quatro camadas, também com 10 neurônios na primeira camada, novamente representando a sazonalidade, a evaporação e os últimos cinco meses de chuva, 12 neurônios na primeira camada escondida, 10 neurônios na segunda camada escondida e novamente 1 neurônio na camada de saída, representando a vazão desejada. Para a bacia do rio Guarapiranga, no estado de São Paulo, dispunham-se de dados de janeiro de 1970 a dezembro de 1985. O período de 1970 a 1977 foi utilizado para treinamento e o período de 1978 a 1985 foi utilizado para a verificação da rede. A topologia da rede ficou definida com 3 camadas, compostas de 8 neurônios na camada de entrada, sazonalidade, evaporação e os últimos 3 meses de chuva, 16 neurônios na camada intermediária e 1 neurônio na camada de saída. A quarta bacia estudada, bacia do rio Mumbaba, também se localizava na Paraíba. Os dados utilizados correspondiam aos valores mensais de chuva e vazão de janeiro de 1970 a dezembro de 1985. O período de 1970 a 1977 foi utilizado para treinamento e o período de 1978 a 1985 para validação. A rede era composta de três camadas, a camada de entrada com 8 neurônios, a camada intermediária com 16 e 1 neurônio na camada de saída.

As aplicações na previsão vazão x vazão foram trabalhadas com as vazões médias mensais incrementais afluentes ao reservatório de Sobradinho, no período de 1931 a 1994, sendo o período de 1931 a 1990 utilizado para o treinamento da rede e o restante dos dados para a verificação da mesma. Foi construída uma rede neural artificial para cada mês do ano, tendo como elementos de entrada os dois meses anteriores.

O autor conclui que os resultados obtidos com o uso de redes neurais são de ótima qualidade quando comparados com aqueles obtidos através das outras metodologias. Cita ainda que uma das grandes vantagens desta técnica está na versatilidade, devido à sua não-linearidade, de permitir, no processo chuva $\times$ vazão, incorporar a representatividade de cada posto pluviométrico. Outro ponto a se considerar é a possibilidade de regionalização levando-se em conta aspectos diversos das bacias, como área de drenagem, declividade, pluviometria média, coeficientes de forma da bacia, tipo de solo, etc. Nas previsões mensais de vazão $\times$ vazão os resultados também comprovaram a eficiência desta técnica, que neste caso, ainda segundo o autor, já eram esperados, uma vez que as redes neurais podem evoluir para potentes modelos ARMA não lineares englobando os modelos de regressão e Box-Jenkins.

BALLINI et al. (1997) utilizaram duas abordagens para previsão de vazões médias mensais através de redes neurais artificiais com algoritmo *backpropagation* e adição do termo *momentum*. Na primeira, a série original foi padronizada removendo-se a média e o desvio-padrão sazonal, e explorando-se a estrutura das funções de autocorrelação e autocorrelação parcial da série padronizada para determinar as entradas da rede. Na segunda foi explorada a estrutura das funções de autocorrelação e autocorrelação parcial da série original para definir as entradas da rede. Neste caso, a rede foi treinada para aprender também a sazonalidade, supostamente estocástica. Foi feita, então, uma comparação entre as abordagens usando RNAs e os modelos de Box-Jenkins, onde foi destacada a importância da padronização da série, e mostrou-se as vantagens dos modelos de redes neurais artificiais quando esta padronização não é adotada.

A comparação foi feita para três séries de vazões mensais, em Furnas, Itumbiara e Sobradinho. Foram treinadas redes neurais

artificiais com uma e duas camadas intermediárias. Os autores concluíram que a padronização da série deve ser preferível quando modelos de Box-Jenkins são ajustados, porém quando utilizaram redes neurais, a padronização das séries pareceu não afetar o desempenho do modelo.

Uma outra aplicação de redes neurais artificiais na modelagem de questões envolvendo recursos hídricos em clima semi-árido pode ser encontrada em DINIZ (1997). Neste trabalho o autor estuda a demanda hídrica da pecuária do município de Sousa, localizado no Alto Sertão da Paraíba através de uma rede neural artificial do tipo *perceptron* multicamadas, treinada através do algoritmo *backpropagation*. Foram utilizados dados relativos aos anos de 1974 a 1994, levantados anualmente. A rede analisada era composta por três camadas, entrada-intermediária-saída.

Os resultados também indicaram um ótimo aproveitamento das RNAs para esse tipo de modelagem, devido a enorme precisão obtida.

JAIN et al. (1999) aplicaram dois modelos de RNAs para previsão de vazões e operação multiobjetivo de um reservatório no estado de Orissa – Índia, e fizeram uma análise comparativa dos resultados dessas duas redes com os resultados obtidos através de modelos Box-Jenkins, para a geração de séries, e de um modelo resultante de Programação Dinâmica, para a determinação da política ótima de operação do reservatório. Os dados disponíveis eram de afluições mensais durante um período de 32 anos, dos quais os dados referentes aos 28 anos iniciais foram usados para treinamento da rede e os últimos 4 anos de dados foram usados para a validação.

As RNAs treinadas eram do tipo *feedforward*, com uso do algoritmo *backpropagation*, para correção e ajuste dos pesos sinápticos. Jain et. al. (1999) adicionaram o termo *momentum*, para melhorar a performance do algoritmo *backpropagation*. Eles trabalharam com RNAs de três camadas (entrada-escondida-saída).

Como neurônios da camada de entrada (*inputs*) eles começaram adotando 5 nós, a saber: as afluições dos três meses anteriores ao que se desejava obter, a do mesmo mês e a do mês anterior do ano anterior. As redes eram treinadas e eles foram reduzindo gradualmente o número de *inputs*. A camada de entrada que foi adotada nos modelos que apresentaram os melhores resultados eram compostas de apenas três neurônios $X_{i-1,j}$, $X_{i-2,j}$ e $X_{i,j-1}$, onde os índices i e j representam respectivamente o mês e o ano. Se $(i-1) < 1$, então $X_{i-1,j}$ era substituído por $X_{12+i-1,j-1}$, e se $(i-2) < 1$, então $X_{i-2,j}$ era substituído por $X_{12+i-2,j-1}$. Isso indica que eles consideraram as vazões do mês corrente dependentes das vazões dos dois meses anteriores e da vazão do mesmo mês do ano anterior. A camada de saída era composta por somente um neurônio, a vazão do mês corrente que se desejava simular, $X_{i,j}$.

Os neurônios da camada escondida (intermediária) foram determinados por tentativa e erro, variando de 1 a 10. Para a rede que se destinava a geração de vazões a melhor arquitetura encontrada foi uma 3-8-1, que significa uma rede neural artificial composta de três neurônios na camada de entrada, oito neurônios na camada escondida e um neurônio na camada de saída.

O critério para avaliação de performance adotado foi o MSE (*Mean Square Error*), calculado através da equação 1:

$$MSE = \frac{1}{N} \sum_{p=1}^N (T_p - O_p)^2 \quad (1)$$

onde: T_p =resposta desejada para a entrada de ordem p ,

O_p =resposta fornecida pela RNA para a entrada de ordem p

N =número total de entradas.

Para tecer comparações com o modelo desenvolvido através de RNAs, um modelo ARIMA foi ajustado paralelamente. Os autores concluíram que os períodos de vazões pequenas eram melhores simulados pelo modelo ARIMA, enquanto os períodos com grandes vazões eram melhores representados pelo modelo gerado através das RNAs. Além disso a média mensal dos desvios de todos os valores individuais foi menor no modelo de RNAs.

Uma das principais desvantagens da aplicação de redes neurais na previsão de vazões de rios é o fato de, muitas vezes, ela não ter habilidade para prever valores que não foram adequadamente apresentados no período de treinamento. Face a esta limitação, IMRIE et al. (2000) propuseram um método para melhorar a generalização durante a fase de treinamento através do uso do algoritmo *cascade-correlation*, proposto por FAHLMAN & LEBIERE (1991), apud IMRIE et al. (2000).

Foi utilizado, neste trabalho, para treinamento e validação das RNAs o *software*, *Stuttgart Neural Network Simulator* (SNNS), que está disponível na internet (ZELL, 1995), e também é baseado no algoritmo *backpropagation*, com a adição do termo *momentum* e taxa de aprendizagem adaptativa. Os dados utilizados referiam-se a vazões horárias de 5 postos fluviométricos nos anos de 1996 a 1998, para dois rios do Reino Unido. O escopo era realizar previsões 12 horas-a-frente e 4 horas-a-frente através de modelos multivariados. Para entrada de dados as vazões foram ajustadas para o intervalo [0,2-0,8], o que garantiu um conjunto de treinamento com picos de máximos e mínimos inferiores aos do conjunto de validação.

Para a determinação da quantidade de neurônios a compor a camada de entrada foi utilizada a função de correlação-cruzada, mas não foi mencionado o critério de adoção através dessa função, como um valor limite acima do qual seria considerado significativo.

Os resultados mostraram a metodologia muito eficiente, e também foi concluído, pelos autores, que redes neurais treinadas através do algoritmo *cascade-correlation* apresentam a vantagem de dispensarem muita experiência do modelador, pois a topologia da rede também é definida durante a modelagem.

Os rios da região do Nordeste brasileiro, onde se localiza o caso em estudo, apresentam um coeficiente de variação dos deflúvios anuais (C_v) muito alto, em torno de 1,4 (CAMPOS, SOUZA FILHO & ARAÚJO, 1997). Característica esta que demonstra o quanto tais rios são marcados por incertezas e erros nas análises das estimativas da variabilidade das vazões regularizadas por reservatórios superficiais, motivando ainda mais a necessidade do estudo proposto.

4. REDES NEURAS ARTIFICIAIS

4.1 INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) são modelos computacionais de processamento paralelo inspirados no mecanismo de funcionamento do cérebro humano. Simulam através de algoritmos, as propriedades biológicas do cérebro humano.

Infelizmente, o conhecimento que se tem sobre o cérebro humano ainda está distante do que seria necessário efetivamente para a elaboração de um algoritmo detalhado e 100% eficiente para a sua “reprodução” por vias computacionais. Os pesquisadores devem, conseqüentemente, transcender essa carência de detalhes em seus modelos, o que termina por gerar expectativas irreais e posterior desapontamento, como o criado nos anos 60, em que se passou um período significativo sem que houvesse pesquisas importantes no campo das RNAs, período esse chamado de eclipse nessa área.

As RNAs são treinadas com base em exemplos previamente apresentados, para captar características essenciais das entradas e oferecer respostas a padrões distintos daqueles incluídos no conjunto de treinamento.

As principais propriedades úteis e capacidades oferecidas pelas RNAs são citadas por HAYKIN (1994) com sendo as seguintes:

- **Não-linearidade** – Um neurônio artificial pode ser linear ou não-linear. Uma rede neural artificial, constituída por conexões de neurônios não-lineares é ela mesma não-linear;
- **Mapeamento de entrada-saída** – Como a rede “aprende” por exemplos, ao serem fornecidas as respostas desejadas para um sinal de entrada único, é realizado um mapeamento de entrada-saída para cada problema considerado;
- **Adaptabilidade** – A RNA apresenta a capacidade inata de adaptar seus pesos sinápticos a modificações do meio-ambiente.

Uma rede neural artificial treinada para operar em ambiente específico pode ser retreinada para lidar com pequenas modificações nas condições operativas do ambiente;

- **Resposta a evidências** – No contexto de classificação de padrões, uma rede neural pode ser projetada para fornecer informação não somente sobre qual padrão particular selecionar, mas também sobre a confiança na decisão tomada;
- **Informação contextual** – O conhecimento é representado pela própria estrutura e estado de ativação de uma rede neural. Cada neurônio da rede é potencialmente afetado pela atividade de todos os neurônios da rede;
- **Tolerância a falhas** – Uma rede neural, tem o potencial de ser inerentemente tolerante a falhas, ou seja, capaz de realizar avaliação robusta, no sentido de que seu desempenho se degrada suavemente sob condições de operações adversas. Por exemplo, se um neurônio ou suas conexões são danificados a recuperação de um padrão armazenado é prejudicada em qualidade, entretanto, devido à natureza distribuída da informação armazenada na rede, o dano deve ser extenso para que a resposta global da rede seja degradada seriamente;
- **Implementação em VLSI** – Graças a sua natureza maciçamente paralela as RNAs são adequadas para a implementação utilizando tecnologia de integração em escala muito ampla, uma virtude para a tecnologia VLSI (*very-large-scale-integration*) que fornece um meio de capturar comportamentos realmente complexos de forma hierárquica;
- **Uniformidade de análise de projeto** – Por desfrutarem de universalidade como processadores de informação, a mesma notação é utilizada em todos os domínios envolvendo aplicação de redes neurais;

- **Analogia neurobiológica** – O projeto de uma rede neural artificial é motivado pela analogia com o cérebro, que é uma prova viva de que o processamento paralelo tolerante a falhas é não somente possível fisicamente mas também é rápido e poderoso.

Entretanto, um longo caminho deve ser ainda percorrido antes que possa ser construída, se efetivamente um dia isto ocorrer, uma estrutura computacional capaz de emular o complexo mecanismo do cérebro humano.

4.2 NEURÔNIO BIOLÓGICO

O cérebro humano é formado por algo em torno de 10^{11} neurônios interligados por, aproximadamente, 10^{15} interconexões. Cada neurônio possui capacidade singular de receber, processar e transmitir sinais eletroquímicos através das sinapses neurais que compreendem o sistema de comunicação cerebral. Os principais componentes de um neurônio biológico são (GUYTON, 1988):

1. Corpo Celular - É a região de onde se diferenciam todas as outras partes do neurônio. Também, o corpo celular é necessário para a continuidade da vida de todo o neurônio, mede, em média, apenas alguns milésimos de milímetro.

2. Dendritos – São os prolongamentos múltiplos e ramificados, com origem no corpo celular, medindo alguns milímetros de comprimento. Constituem as partes receptoras principais do neurônio. Isto é, a maior parte dos sinais que devem ser transmitidos ao neurônio chega a ele por meio dos dendritos, embora alguns sinais cheguem diretamente pela superfície do corpo celular. Os dendritos de cada neurônio, em geral, recebem sinais de muitos milhares de pontos de contato com

outros neurônios, as sinapses. Também aqui a informação é processada e novos impulsos são gerados.

Figura 1 – Neurônio Biológico

3. Axônio – Cada neurônio possui um axônio. Essa é a parte do neurônio que é chamada de fibra nervosa. Seu comprimento pode ser de apenas alguns milímetros, como acontece com os axônios dos neurônios pequenos do cérebro, ou pode atingir até um metro, como no caso dos axônios que partem da medula para inervar os pés. Os axônios transmitem os sinais neurais para a célula seguinte no cérebro ou na medula espinhal, ou para músculos e glândulas nas regiões periféricas do corpo.

4. Terminais Axônicos e Sinapses – Próximos a seus términos, todos os axônios ramificam-se extensamente, com o número total dessas ramificações podendo atingir os milhares. Na extremidade de cada uma dessas ramificações existe uma terminação neural especializada que, no sistema nervoso central, é chamada de pé ou botão sináptico, devido a sua semelhança com o pé de um móvel. Por sua vez, esse botão sináptico fica situado sobre a superfície da membrana de um dendrito ou do corpo celular de outro neurônio. Esse ponto de contato entre o botão sináptico e a membrana neuronal é a sinapse. É através das sinapses que os neurônios são unidos funcionalmente, formando

assim as redes neurais, e os sinais são transmitidos de um neurônio a outro. Quando estimulado, o botão sináptico libera quantidade diminuta de um hormônio, chamado substância transmissora, no espaço entre o botão e a membrana do neurônio, e a substância transmissora estimula este neurônio.

Reafirmando o que já foi mencionado anteriormente, a sinapse é a junção entre dois neurônios, e é através dela que os sinais são transmitidos de um neurônio para outro. Entretanto, a sinapse tem a capacidade de transmitir alguns sinais e de refugar outros, o que a torna elemento de extrema valia para o sistema nervoso, na seleção de qual a conduta a ser seguida. É devido a essa transmissão variável dos sinais que a sinapse talvez seja o determinante único mais importante da função do sistema nervoso central.

A transmissão de sinais dos botões sinápticos ocorre através da secreção de substâncias transmissoras excitatórias ou inibitórias; portanto, alguns terminais excitam o neurônio enquanto outros o inibem.

Um dos aspectos importantes de entendimento do funcionamento do neurônio biológico é aquele relacionado com a Lei do Tudo ou Nada. No estado de repouso, a concentração de íons K^+ , no interior da célula, é menor do que a quantidade de íons Na^+ fora da célula, de tal forma que a face externa da membrana torna-se positiva e a face interna negativa, como pode ser visto na Figura 2. A carga negativa é formada, basicamente, de íons fosfato e íons orgânicos que se encontram em maior quantidade no interior da célula. Essa diferença de potencial é da ordem de 70milivolts (mV), sendo este estado chamado de potencial de repouso. Entretanto, quando esta membrana sofre um estímulo elétrico, químico ou uma simples pressão, ocorre uma deformação temporária que facilita a entrada do íon Na^+ por difusão. Logo, durante um curto espaço de tempo, a entrada de sódio provoca uma inversão da carga elétrica da membrana, que se torna

negativa por fora e positiva por dentro. Essa alteração da carga elétrica é chamada de potencial de ação e se propaga ao longo do neurônio com uma velocidade que varia de 1 a 100m/s. Esta sequência de cargas elétricas que se propaga através do neurônio é o que chamamos de impulso nervoso (VALENÇA & LUDERMIR, 1999).

Figura 2 – Impulso Nervoso (Valença & Ludermir, 1999)

Ressalta-se que só os estímulos com uma mínima intensidade, a partir de um certo limiar, chamado limiar excitatório, são capazes de provocar impulsos. Portanto, se o estímulo for muito pequeno, isto é, se a sua intensidade for inferior ao limiar excitatório, não ocorrerá nenhum impulso nervoso. Por outro lado, passado esse limiar, o potencial de ação do neurônio será sempre o mesmo, qualquer que seja a intensidade do estímulo; em outras palavras, o neurônio segue a Lei do Tudo ou Nada. Esta estabelece, portanto, que o neurônio responde ao estímulo com capacidade máxima ou não há qualquer resposta. Essa lei leva a uma pergunta bastante simples: como o sistema nervoso é capaz de distinguir uma pancada leve de um toque? A resposta é que quando o estímulo é fraco, o número de neurônios estimulados é menor do que quando o estímulo é forte, além do que o tempo de duração do estímulo forte é maior, o que aumenta a frequência de impulsos enviados ao cérebro. Esse impulso nervoso, ao atingir as ramificações finais do axônio, provoca o esvaziamento de várias vesículas que armazenavam substâncias químicas, as quais se

difundem pela sinapse e se unem às proteínas dos dendritos do outro neurônio, de tal forma que a membrana torna-se mais permeável ao sódio, surgindo daí o potencial de ação que se propaga ao longo do neurônio estimulado. Quando liberadas, elas são, posteriormente, destruídas por enzimas, parando, então, o estímulo. Essas substâncias recebem o nome de neurotransmissores, mensageiros químicos, etc. (VALENÇA & LUDERMIR, 1999)

Existem em torno de 100 tipos diferentes de neurotransmissores. O tipo de neurotransmissor liberado determinará a polarização ou a despolarização do corpo do neurônio seguinte. De acordo com o tipo de neurotransmissor liberado a sinapse poderá ser inibitória ou excitatória. A contribuição de todos os neurônios pré-sinápticos na polarização do neurônio pós-sináptico determinará se este irá ou não gerar um impulso nervoso. Depois de gerar um impulso, o neurônio entra em um período de refração, período em que axônio não pode ser novamente estimulado, durante o qual retorna ao seu potencial de repouso enquanto se prepara para a geração de um novo impulso (BRAGA et. al., 2000).

Tipicamente, os neurônios são de cinco a seis ordens de grandeza mais lentos que as portas lógicas em silício; os eventos em um circuito de silício acontecem na ordem de nanossegundos (10^{-9} s), enquanto que eventos neurais acontecem na ordem de milissegundos (10^{-3} s) (HAYKIN, 1994). Entretanto, o cérebro compensa a taxa de operação relativamente lenta de um neurônio pelo número espantoso de células nervosas com conexões maciças entre si.

A capacidade de realizar funções complexas surge com a operação em paralelo de todos os 10^{11} neurônios componentes do cérebro humano.

4.3 NEURÔNIOS ARTIFICIAS

As RNA's buscam simular as características de 1ª (primeira) ordem do neurônio biológico. Um conjunto de entradas é aplicado, cada uma delas representando a saída de um outro neurônio; cada entrada é então multiplicada por um peso, que tem como analogia a força sináptica, gerando valores que são então somados para determinar o nível de ativação do neurônio. O fato que mais gera interesse na aplicabilidade das RNAs é o poder de que elas possuem de modificar seu comportamento em resposta ao meio, ou seja, a capacidade delas se auto-ajustarem, em função de um conjunto de treinamento apresentado, para produzir respostas consistentes. Existe uma diversidade de paradigmas que norteiam as pesquisas nesse campo, mas quase todos foram moldados sobre essa configuração.

O modelo artificial de neurônio, também chamado de neurônio matemático, não leva em conta *time-delays*, que afetam significativamente a dinâmica do sistema nervoso, implicando em entradas gerando saídas imediatas. Mais importante do que isso, ele não inclui os efeitos de sincronismo ou da função *frequency-modulation* do neurônio biológico, características estas que alguns pesquisadores tomam como cruciais e capazes de refletirem no aproveitamento ou não do modelo. Apesar disso as RNAs, compostas com esse tipo de neurônios, exibem atributos que são fortemente remanescentes do sistema biológico (WASSERMAN, 1989).

Os neurônios artificiais baseiam-se no modelo proposto por McCULLOCH & PITTS (1943), que, logicamente, é uma simplificação do que se sabia então a respeito do neurônio biológico. Sua descrição matemática resultou em um modelo com n terminais de entrada $x_1, x_2, \dots, x_n$ (que representam os dendritos) e apenas um terminal de saída y (representando o axônio). Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados $w_1, w_2, \dots, w_n$, cujos valores podem ser positivos ou negativos, dependendo de as

sinapses correspondentes serem excitatórias ou inibitórias. O efeito de uma sinapse particular i no neurônio pós-sináptico é dado por $x_i w_i$. Os pesos determinam “em que grau” o neurônio deve considerar sinais de disparo que ocorrem naquela conexão.

O neurônio biológico dispara quando a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação (*threshold*). O corpo do neurônio, por sua vez, é emulado por um mecanismo simples que faz a soma dos valores $x_i w_i$ recebidos pelo neurônio (soma ponderada) e decide se o neurônio deve ou não disparar (saída igual a 1 ou 0) comparando a soma obtida ao limiar ou *threshold* do neurônio. No modelo original de neurônio de McCulloch e Pitts, a ativação do neurônio é obtida através da função de ativação, que ativa ou não a saída, dependendo do valor da soma ponderada das suas entradas, descrita na equação 2. (BRAGA et. al., 2000).

$$\sum_{i=1}^n x_i w_i \geq \theta \quad (2)$$

O neurônio matemático é constituído, basicamente, de uma função de combinação (ou regra de propagação) e uma função de transferência (ou função de ativação, ou ainda regra de ativação). A função de combinação, como o próprio nome diz, é responsável por compor a informação de entrada do neurônio. No caso dela ser linear, passa a representar uma soma de entradas, ponderadas pelos respectivos pesos. Estes pesos das conexões são, muitas vezes, chamados de pesos sinápticos, em analogia com o neurônio biológico, e representam, matematicamente, a importância de cada informação, com relação a um dado neurônio. A função de ativação é responsável pela intensidade do sinal a ser transmitido pelas conexões para os neurônios das camadas adjacentes. Tipicamente, o intervalo da amplitude normalizada de resposta de um neurônio está no intervalo

fechado $[1,0]$ ou, alternativamente, $[-1,1]$. Várias funções são utilizadas com essa finalidade; entre as mais utilizadas, citam-se a sigmóide, a gaussiana e a rampa. Ela é responsável pela não-linearidade da rede, o que torna essa ferramenta poderosa (VALENÇA & LUDERMIR, 1999). Os neurônios podem também ter um *bias*, que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente. Na Figura 3, observa-se a representação de um neurônio matemático.

Figura 3 – Neurônio Artificial (Haykin, 1994)

Os neurônios artificiais utilizados para a construção de redes neurais são realmente primitivos em comparação com aqueles encontrados no cérebro. As redes neurais atualmente projetadas são comparativamente tão primitivas quanto os circuitos locais e inter-regionais do cérebro. O que pode ser considerado gratificante, e ao mesmo tempo estimulante, é o progresso notável alcançado em várias frentes durante as duas últimas décadas. Com a analogia neurobiológica como fonte de inspiração e com a riqueza das ferramentas teóricas e tecnológicas que têm-se acumulado, pode-se ter

como certo que em mais uma década a compreensão das redes neurais artificiais será muito mais sofisticada do que ela o é atualmente (HAYKIN, 1994).

4.4 HISTÓRICO

Alguns autores consideram o início da era moderna das redes neurais com o trabalho pioneiro de McCulloch, um psiquiatra e neuroanatomista, e Pitts, um príncipe matemático, em (1943), em que descrevem um cálculo lógico das redes neurais que unificava os estudos de neurofisiologia e da lógica matemática. Eles assumiam que o modelo formal de um neurônio seguia uma lei “tudo ou nada”. Com um número suficiente dessas unidades simples e conexões sinápticas ajustadas apropriadamente e operando de forma síncrona, McCulloch e Pitts mostraram que uma rede assim constituída realizaria, a princípio, a computação de qualquer função computável. Este era um resultado muito significativo e com ele é geralmente aceito o nascimento das disciplinas de redes neurais e inteligência artificial (HAYKIN, 1994).

Outros autores afirmam que o marco inicial para o desenvolvimento de algoritmos norteadores dos estudos e análises sobre RNAs foi a publicação da Lei do Aprendizado, postulada por D. O. Hebb em 1949, o que para o primeiro grupo de autores, este seria somente o segundo desenvolvimento significativo. Nas décadas de 50 e 60 diversos pesquisadores, de diferentes áreas, combinaram então características biológicas e psicológicas dos neurônios para produzir as primeiras Redes Neurais Artificiais, implementadas, originalmente, como um circuito eletrônico, de onde depois se refinou para simulação computacional (WASSERMAN, 1989).

Inicialmente as redes pesquisadas eram todas do tipo Perceptrons ou *single layer networks*, ou seja, redes que eram

compostas de uma única camada escondida. Suas primeiras aplicações foram nos ramos de previsão do tempo, análise de eletrocardiograma e visão artificial, todas elas ainda na década de 50.

Essa nova abordagem computacional causou certo furor no meio científico, fazendo com que muitos pesquisadores acabassem por vislumbrar esse tipo de mecanismo como a maneira de resolver qualquer tipo de problema. Após essa fase de enorme euforia inicial começaram a aparecer as primeiras falhas. Os perceptrons da época não estavam sendo capazes de realizar tarefas bastante simples, dando margem a inúmeras críticas que não tinham como ser contestadas. Em meio a esse contexto Marvin Minsky e Seymour Papert publicam o livro *Perceptrons* no ano de 1969, onde eles demonstram que, teoricamente, as RNA's eram incapazes de resolver muitos problemas simples.

Os dois parágrafos abaixo são extraídos do livro *Perceptrons*:

O Perceptron tem se mostrado merecedor de estudos apesar de (e mesmo por causa disso!) suas inúmeras limitações. Ele tem muitas características que atraem a atenção: sua linearidade, seu fascinante teorema de aprendizagem, sua clara simplicidade paradigmática como um tipo de computação baseada em processamento paralelo. Não existe razão para se supor que alguma dessas virtudes seja transportada para a versão com mais camadas. Todavia, nós consideramos isto como sendo um importante problema a ser pesquisado para esclarecer (ou rejeitar) nosso julgamento intuitivo de que a extensão é estéril.

Talvez algum poderoso teorema de convergência seja desenvolvido, ou alguma razão séria para a falha na produção de um “teorema de aprendizagem” que seja interessante para redes multicamadas seja descoberta. (pg 231-32)

Os anos 70 e o começo dos anos 80 foram marcados por um certo hiato no desenvolvimento do campo das RNAs. Alguns poucos

cientistas ainda realizavam trabalhos na área, mas tinham dificuldade tanto para financiar suas pesquisas como para publicar seus trabalhos. O excesso de euforia do início dos anos 50 transformou-se num forte desinteresse.

Entretanto, os poucos trabalhos que estavam sendo produzidos foram, gradualmente, solidificando uma base teórica forte, na qual está alicerçada a construção dos modelos de múltiplas camadas. Houve um ressurgimento do interesse na aplicação da computação a campos antes improváveis, restritos somente à inteligência humana

A evolução desse tipo de rede sugeriu a utilização de arquiteturas mais robustas, onde são utilizadas mais camadas intermediárias. Esse tipo de rede, com múltiplas camadas (*multilayers networks*) requerem uma maior capacidade computacional, entretanto são capazes de grandes ganhos, em comparação com as do tipo camada única (*single-layer networks*), através da adoção de uma função de ativação que seja do tipo não-linear.

Embora as RNAs possam ser, teoricamente, construídas em qualquer configuração imaginável, vêm sendo utilizadas, preferencialmente, as dispostas em camadas, por simularem efetivamente a estrutura de partes do cérebro.

A “inteligência” exibida pela RNA mais sofisticada está ainda longe de ser comparada com reais “inteligências”. Mas, de forma alguma, pode deixar de ser reconhecido o seu valor, que aponta para um número de aplicações que já são desenvolvidas com sucesso e para uma enorme quantidade de campos que ainda podem ser explorados ou, pelo menos, aperfeiçoados.

4.5 COMPONENTES DAS RNAS

De acordo com RUMELHART & McCLELLAND (1986), apud. VALENÇA & LUDERMIR(1999) os modelos de RNAs, de maneira geral, apresentam 8 (oito) componentes principais:

- Um conjunto de elementos de processamento;
- Um estado de ativação;
- Uma função de saída para cada elemento de processamento;
- Um padrão de interconexão entre os elementos de processamento;
- Uma regra de propagação;
- Uma regra de ativação;
- Uma regra de aprendizado;
- Uma representação do ambiente onde o sistema deve operar.

4.5.1 ELEMENTOS DE PROCESSAMENTO

Os elementos de processamento (EP) são os próprios neurônios artificiais, já descritos anteriormente. São também chamados de nós, nodos ou unidades de processamento.

4.5.2 ESTADO DE ATIVAÇÃO

Cada elemento de processamento, em uma rede neural, tem associado um estado de ativação. A representação do estado de ativação do sistema é um vetor de ativação cujos elementos estabelecem a ativação de todas as unidades de um dado grupo. A

escolha do estado de ativação a ser utilizado para o elemento de processamento é função do que se procura representar com o modelo. O estado de ativação pode ser contínuo (limitado ou ilimitado) ou discreto (binário ou múltiplo).

4.5.3 FUNÇÃO DE SAÍDA DO ELEMENTO DE PROCESSAMENTO

Desde que a ativação do elemento de processamento seja conhecida, ele produzirá um sinal de saída relacionado com sua ativação por uma função de transferência conhecida como função de saída. Esta função de saída pode ser, por exemplo, a função identidade (sinal de saída igual ao estado de ativação) ou uma função do tipo porteira (patamar, limiar) em que a emissão do sinal só ocorre quando a ativação é superior a um dado limite.

4.5.4 PADRÃO DE INTERCONEXÃO ENTRE OS ELEMENTOS DE PROCESSAMENTO

Essa representação é feita através de uma matriz de pesos e define o conhecimento do sistema. As conexões com pesos positivos representam conexões excitatórias (reforço na ativação do neurônio) e as com pesos negativos conexões inibitórias (inibição da ativação do neurônio).

Os pesos das conexões, chamados muitas vezes de pesos sinápticos, representam, matematicamente, a importância de cada informação com relação a um dado neurônio. O principal propósito do treinamento de uma RNA é, pois, determinar o melhor conjunto de pesos capaz de representar um dado problema. Existem inúmeros métodos de utilizados com esse objetivo; entretanto, um tornou-se bastante popular, a ponto de as redes treinadas com essa regra de aprendizagem serem chamadas de redes neurais *backpropagation*. Esse termo está relacionado, na realidade, à propagação recursiva dos erros, como será visto mais adiante.

4.5.5 REGRA DE PROPAGAÇÃO

Trata-se de uma regra que combina os valores de entrada de um EP com os respectivos valores da matriz de pesos para produzir uma entrada líquida. Uma das regras de propagação mais simples é aquela na qual o sinal líquido é uma soma de cada entrada ponderada pelo respectivo peso que chega a um dado EP, como aquela já apresentada juntamente com o modelo de neurônio de McCulloch e Pitts.

4.5.6 REGRA DE ATIVAÇÃO

Também chamada de função de ativação, denotada doravante de $\varphi(v)$, sendo v a entrada líquida definida anteriormente pelo somatório de cada entrada que chega ao elemento de processamento, multiplicada pelo seu respectivo peso, tem por finalidade calcular um novo estado de ativação do EP. Existem diversas funções de ativação, dentre as quais podem ser destacadas:

✓ Função Sigmóide

$$\varphi(v) = \frac{1}{1 + e^{-v}}$$

✓ Função rampa

$$\varphi(v) = \begin{cases} 1, \forall v \geq 1 \\ v, \forall |v| \geq 1 \\ -1, \forall v \leq -1 \end{cases}$$

✓ Função degrau

$$\varphi(v) = \begin{cases} 1, \forall v \geq 0 \\ 0, \forall v < 0 \end{cases}$$

- ✓ Função gaussiana

$$\varphi(v) = e^{-v^2}$$

- ✓ Função tangente hiperbólica

$$\varphi(v) = \tanh(v)$$

- ✓ Função linear

$$\varphi(v) = k \cdot v, \text{ em que } k = \text{constante}$$

A adoção de uma determinada função de ativação depende das características dos dados de entrada e do problema a ser modelado.

4.5.7 REGRA DE APRENDIZADO

Durante a fase de treinamento de uma RNA pode ocorrer a modificação do seu padrão de interconexão, através do estabelecimento de novas conexões, da eliminação de conexões que existiam a princípio e/ou da modificação dos pesos inicialmente adotados para as conexões.

As regras de aprendizado das RNAs podem se classificar como sendo de aprendizado supervisionado, onde o treinamento da rede é feito com o conhecimento prévio do resultado desejado, desta forma são fornecidos para a rede o conjunto de dados de entrada e as respectivas respostas, e como de aprendizado não supervisionado, onde a rede é treinada somente com os dados de entrada. Segundo (VALENÇA, 1999), dentre as diferentes regras de aprendizado, merece destaque a regra de Hebb, uma vez que as outras regras podem ser vistas como uma variação dessa. A regra de Hebb pode ser enunciada da seguinte forma:

"Se um neurônio recebe um estímulo de outro neurônio, e se ambos são altamente ativos, o peso entre estes neurônios deve ser fortalecido".

Além desta, outras regras bastante utilizadas são:

Regra Delta - onde os pesos sinápticos são modificados de modo que o erro entre a saída desejada e a fornecida pela rede é minimizado;

Regra de Hopfield - que diz que se a saída e a entrada são ambas ativas ou inativas, deve-se incrementar o peso pela taxa de aprendizado, do contrário diminui-se o mesmo;

Regra de Kohonen - baseada no processo de competição, de tal forma que só o neurônio mais ativo, dito vencedor, fornece uma saída, e só ele e seus vizinhos têm os pesos ajustados.

Para outros tipos de regras de aprendizagem e maiores detalhes sobre as mesmas pode ser consultado HAYKIN (1994).

4.6 MODELAGEM ATRAVÉS DE RNAs

A modelagem feita com redes neurais segue os passos dos modelos estatísticos, e é baseada num processo iterativo, cujas etapas podem ser resumidas da seguinte forma:

I) Análise preliminar e identificação do modelo - onde será definida a topologia da rede. Tal definição é um processo subjetivo que depende de fatores como complexidade do fenômeno a ser modelado e disponibilidade de dados para o estudo. Esta escolha da arquitetura da rede é feita, geralmente, de forma empírica, pois não se dispõe de regras que permitam o estabelecimento dela, a priori.

II) Treinamento da Rede - depois de terminada a fase inicial (I), segue-se à fase de treinamento da rede, onde são ajustados os pesos. Deve-se, nesta fase, evitar o *overfitting*, ou seja, o superajustamento (número de parâmetros elevado). Um número

elevado de elementos de processamento pode fazer com que a rede ajuste-se muito bem aos dados de treinamento e perca sua capacidade de generalização, ou seja, oferecer respostas razoáveis a padrões de entrada diferentes daqueles contidos no conjunto de treinamento.

Para evitar que isso ocorra, faz-se uso de um conjunto de teste para a validação ou da técnica de validação cruzada (*cross-validation*), onde o conjunto de dados é dividido aleatoriamente em um conjunto de treinamento e um conjunto de teste. O conjunto de treinamento é então dividido novamente em dois subconjuntos disjuntos, um de estimação e outro de validação, forçando o modelo a ser validado com um conjunto de dados diferentes daquele usado para estimar os parâmetros (HAYKIN, 1994).

III) Verificação da Rede - é feita utilizando-se um conjunto de dados que não foi empregado durante o treinamento. Logicamente, esse conjunto deve ser uma amostra representativa do problema em estudo. Caso o resultado obtido não seja satisfatório, uma nova topologia para a rede é escolhida, e o ciclo é repetido (VALENÇA, 1999).

Figura 4 – Rede neural com quatro camadas

É mostrado na Figura 4 um exemplo de uma rede neural artificial com 4 (quatro) camadas, onde a camada de entrada (i) é a camada da esquerda e a camada de saída (k) é a camada da direita. Neste exemplo a rede possui ainda duas camadas intermediárias (j e z). Cada neurônio, ou elemento de processamento (EP), aqui representado pelos círculos, de uma camada se conecta com os outros neurônios da camada seguinte através de arcos, sendo que a cada arco está associado um peso (w). Os pesos das conexões, chamados muitas vezes de pesos sinápticos, representam, matematicamente, a importância de cada informação com relação a um dado neurônio. São fornecidas entradas (informações) para a rede, estas informações são processadas nos neurônios, que transformam o sinal recebido e o retransmitem, através de um conjunto formado por parâmetros conjugados com uma função de ativação, geralmente não linear. Essas informações transmitidas entre os neurônios através das ligações ponderadas, geram os valores de saída, os quais podem ser fornecidos ou não. Nos casos, em que as saídas desejadas são fornecidas à rede, o aprendizado é do tipo supervisionado. Ao conjunto que contém todos os pares de entrada/saída de uma rede dá-se o nome de conjunto de treinamento.

Para a modelagem de séries temporais, a(s) camada(s) intermediária(s) deve(m) ser suficientemente parcimoniosa(s) a fim de se evitar a tendência de reprodução da componente estocástica.

O principal propósito do treinamento de uma RNA é determinar o melhor conjunto de pesos capaz de representar um dado problema. É importante salientar que nem todos os pesos precisam ser variáveis, qualquer número de pesos pode ser fixado, neste caso os pesos fixos não são modificados durante o processo de treinamento da rede.

4.7 ALGORITMO BACKPROPAGATION

A invenção do algoritmo *backpropagation*, em 1986 por RUMELHART e McCLELAND, alavancou o interesse nas RNAs. *Backpropagation* é um método sistemático para o treinamento de redes neurais artificiais multi-camadas, possuindo uma fundamentação matemática forte. Este método expandiu o campo de problemas onde as RNAs podem ser aplicadas.

O *backpropagation* ou algoritmo de propagação regressiva dos erros corrige iterativamente os pesos W com base no erro entre os valores calculados e observados. Trata-se de um algoritmo do tipo gradiente descendente para o qual o processo de busca do ponto de mínimo parte de um ponto aleatoriamente escolhido e usa para as iterações seguintes o gradiente da função objetivo para identificar a sua direção de maior crescimento.

Durante o treinamento da rede, o sistema usa o vetor de entrada para produzir a saída calculada e então compara com a saída desejada, ou alvo. A cada par de exemplos, entrada/saída, denomina-se padrão. Os pesos são então reavaliados a fim de minimizar os desvios entre a saída desejada e a resposta calculada pela rede, através de um método tipo gradiente.

Considerar uma topologia de rede como a apresentada na Figura 5, onde as unidades de saída são denotadas por O_i (e os respectivos *thresholds* θ_i), as unidades ocultas por V_j (e os respectivos *thresholds* θ_j), e as entradas por I_k . Existem conexões w_{jk} das entradas para as unidades ocultas, e w_{ij} das unidades ocultas para as unidades de saída. Notar que o índice i sempre se refere a uma unidade de saída, j a uma unidade oculta e k a uma unidade de entrada.

Figura 5 – Rede neural com três camadas

Dado um padrão μ , a unidade oculta j recebe uma entrada

$$d_j^\mu = \sum_k w_{jk} I_k^\mu - \theta_j \quad (3)$$

e produz como saída

$$H_j^\mu = g(d_j^\mu) = g\left(\sum_k w_{jk} I_k^\mu - \theta_j\right) \quad (4)$$

a unidade de saída recebe então

$$d_i^\mu = \sum_j w_{ij} H_j^\mu - \theta_i = \sum_j w_{ij} g\left(\sum_k w_{jk} I_k^\mu - \theta_j\right) - \theta_i \quad (5)$$

e produz a saída final

$$O_i^\mu = g(d_i^\mu) = g\left(\sum_j w_{ij} H_j^\mu - \theta_i\right) = g\left(\sum_j w_{ij} g\left(\sum_k w_{jk} I_k^\mu - \theta_j\right) - \theta_i\right) \quad (6)$$

Definindo-se como medida usual de erro (E)

$$E = \frac{1}{2} \sum_{\mu i} [T_i^\mu - O_i^\mu]^2 \quad (7)$$

onde T_i^μ = alvo para o padrão μ , relativo à saída i
que equivale a

$$E = \frac{1}{2} \sum_{\mu i} [T_i^\mu - g(\sum_j w_{ij} g(\sum_k w_{jk} - \theta_j) - \theta_i)]^2 \quad (8)$$

Para as conexões camada oculta - camada de saída, a aplicação da regra do gradiente produz

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \sum_{\mu} \delta_i^\mu H_j^\mu \quad (9)$$

e

$$\Delta \theta_i = -\eta \frac{\partial E}{\partial \theta_i} = -\eta \frac{\partial E}{\partial d} \frac{\partial d}{\partial \theta_i} = -\eta \sum_{\mu} \delta_i^\mu \quad (10)$$

$$\text{onde: } \delta_i^\mu = g'(d_i^\mu) [T_i^\mu - O_i^\mu] \quad (11)$$

η = coeficiente de treinamento (ou aprendizagem) da rede

Para as conexões camada oculta - entrada

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = \eta \sum_{\mu} \delta_j^\mu T_k^\mu \quad (12)$$

$$\Delta \theta_j = -\eta \frac{\partial E}{\partial \theta_j} = -\eta \frac{\partial E}{\partial d} \frac{\partial d}{\partial \theta_j} = -\eta \sum_{\mu} \delta_j^\mu \quad (13)$$

$$\text{onde: } \delta_j^\mu = g'(d_j^\mu) [w_{ij} - \delta_i^\mu] \quad (14)$$

É usual empregar-se a função sigmóide como função de ativação $g(d)$

$$g(d) = \frac{1}{1 + e^{-d}} \quad (15)$$

a derivada $g'(d) = g(1-g)$.

A substituição da eq. (15) em (11) resulta em:

$$\delta_i'' = O_i''(1 - O_i'')(T_i'' - O_i'') \quad (16)$$

Funções objetivo multimodais podem apresentar muitos mínimos locais. Assim, os métodos de busca do tipo gradiente descendente podem tornar-se ineficientes na propagação regressiva dos erros. Convém neste caso a aplicação de métodos de otimização mais eficientes, como por exemplo, os métodos de gradiente conjugado, métodos dos anéis simulados ou métodos baseados em otimização genética (SARMENTO, 1996).

Depois do treinamento e da verificação, a rede está pronta para ser utilizada, consistindo numa poderosa e ágil ferramenta, pois todas as informações da amostra utilizada no treinamento ficaram armazenadas nos neurônios após os ajustes de seus pesos sinápticos. (VALENÇA, 1999)

Com a criação do modelo, o comportamento do sistema será simulado através de programas computacionais existentes no mercado e com as regras de operação dos reservatórios empregadas pelo órgão gestor encarregado desse plano.

4.8 OUTROS TIPOS DE RNAs

Além das “populares” redes neurais artificiais do tipo *Perceptron* multicamadas, outras topologias são aplicadas a diferentes modelos adotados nas mais diversas áreas de pesquisa, dentro e fora do campo da Engenharia, tais como:

Redes de Jordan e Elman - são consideradas como uma extensão das redes *Perceptron* de múltiplas camadas. Possuem unidades de contexto, que são elementos de processamento que relembram atividades passadas, unidades estas importantes quando o processo de aprendizagem dos exemplos ocorre ao longo do tempo, ou seja, sempre que os valores passados da rede influenciam os valores presentes.

Redes com Função de Base – foram projetadas por Qian e Lee (1990) apud. VALENÇA & LUDERMIR (1999) e são variações das redes *perceptrons* multicamadas que utilizam um conjunto de funções de base ortogonal, isto é, a saída da rede sendo expressa como:

$$\hat{f}(x) = \sum_i w_i(x) \psi_i(x) \quad (17)$$

na qual: w_i é o vetor de pesos e ψ_i representa o conjunto de funções de base ortogonal. Se $f(x)$ é a função de saída desejada e N_v é o número de elementos nos vetores de entrada para treinamento, então a melhor aproximação é obtida através da minimização da função erro E , ou seja:

$$E = \frac{1}{2} \sum_{j=1}^{N_v} (f(x^j) - \hat{f}(x^j))^2 \quad (18)$$

O somatório nesta equação pode ser aproximado por uma integração quando o conjunto de treino contém uma grande quantidade de vetores.

$$E \approx \frac{1}{2} \int (f(x) - \hat{f}(x))^2 \tilde{p}(x) dx = \frac{1}{2} \langle (f(x) - \hat{f}(x))^2 \rangle \quad (19)$$

Aqui, $\tilde{p}(x)$ é a distribuição de probabilidade de x . O problema, segundo VALENÇA & LUDERMIR (1999) é de como definir o conjunto de funções de base ortogonal. Para o caso de uma dimensão, Qian e Lee propuseram algumas soluções, entretanto os resultados obtidos são difíceis de serem estendidos para o caso de dimensão elevada.

Redes GMDH - São implementadas com termos polinomiais nos nós e um critério de seleção para decidir quantas camadas serão construídas. Na sua formulação original, cada elemento de processamento recebe duas entradas e tem como função de ativação um polinômio de segundo grau. Através da combinação desses elementos de processamento, será gerada uma função de saída polinomial cuja complexidade será função do número de camadas, de tal forma que a função polinomial terá grau $2M$, onde M é o número de camadas. Desta forma, as redes GMDH são chamadas de redes polinomiais, pois o modelo que resulta é uma função polinomial padrão.

Redes Compostas por Blocos de Sigmóides Auto-Organizáveis (SSBN) - Nesta classe de redes, um algoritmo de abordagem indutiva é utilizado para incrementar a estrutura da rede, partindo-se de uma pequena estrutura, até que se atinja uma estrutura de tamanho ótimo, segundo critérios estatísticos de seleção adequados. A proposta do modelo SSBN é de se construir a rede por blocos de polinômios

homogêneos, utilizando uma função de ativação adequada para os neurônios escondidos. Quanto aos neurônios de saída, estes têm uma ativação mais complexa, uma vez que realizam uma regressão logística não-linear com relação à saída de neurônios ocultos. Desta forma, as redes SSBN podem aproximar, uniformemente, qualquer função contínua definida em um conjunto compacto limitado e também lidar com a realização de funções booleanas, o que não é possível com os algoritmos tradicionais do grupo GMDH. (VALENÇA, 1999)

Redes Neurais sem Pesos (RNSPs) – Esta classe de RNAs começou a ser estudada na década de 60, motivada pelas dificuldades enfrentadas pela comunidade para a implementação em *hardware* dos pesos das conexões de nodos do tipo McCulloch-Pitts. As RNSPs têm sua origem no método das n-útuplas de BLEDSOE & BROWNING (1959), (apud. BRAGA et. al. 2000), que propuseram representar a presença de uma combinação qualquer em partes e um padrão binário através de um valor lógico (sim ou não). Em 1965, Igor Aleksander, um dos pioneiros na pesquisa de RNSPs, propôs um modelo de nó totalmente digital, baseado em dispositivos de memória de acesso randômico. O modelo, que podia ser utilizado para implementar em *hardware* o método das n-útuplas, foi batizado inicialmente de SLAM (*Stored Logic Adaptive Microcircuit*), passando depois a ser conhecido mais popularmente como RAM (do original *Random Access Memory*) (ALEKSANDER, 1966, apud. BRAGA et. al. 2000). Ainda segundo Braga et. al. (2000) a principal diferença entre as RNAs convencionais e as RNSPs é a forma de armazenar a informação. No modelo com pesos, a informação fica armazenada nos pesos das ligações entre os diversos nodos da rede, enquanto nas RNSPs a informação fica armazenada na memória dos dispositivos, em tabelas-verdade. Em vez de ajuste de pesos, o aprendizado em uma RSP geralmente consiste em modificar o conteúdo das memórias das tabelas-verdade, o que resulta

em algoritmos de aprendizado rápidos e flexíveis. Existem outras diferenças importantes entre as redes neurais artificiais e as redes neurais sem pesos: (1) nas primeiras, é possível se ter entradas, saídas e pesos assumindo qualquer valor real, enquanto as RNSPs são essencialmente discretas; (2) os nodos das RNAs computam apenas funções linearmente separáveis, enquanto os nós das RNSPs computam todas as funções booleanas de suas entradas; e (3) o nó com pesos é capaz de “generalizar” o conhecimento ensinado, enquanto o nó sem peso, individualmente, não.

5. SISTEMA E MÉTODOS DE ESTUDO

5.1 DESCRIÇÃO DO SISTEMA

O sistema objeto do presente estudo se refere a bacias hidrográficas constituintes da Região Metropolitana da cidade de Fortaleza (RMF), Ceará, denominadas Bacias Metropolitanas.

Figura 6 – Fortaleza e sua Região Metropolitana

Foram escolhidos quatro açudes, pertencentes a quatro bacias distintas, a saber: açude **Acarape do Meio** (bacia do rio Pacoti), açude **Choró-Limão** (da bacia do rio Choró), açude **Gavião** (bacia do rio Cocó) e açude **Sítios Novos** (bacia do rio São Gonçalo).

Está localizado na **Bacia do rio Pacoti** o principal manancial da Região Metropolitana de Fortaleza, o rio Pacoti, que nasce na Serra de Baturité e percorre 112,5km, em geral no sentido sudoeste/nordeste, dos quais o primeiro terço com declividade acentuada, da ordem de 2,0%. Na parcela de jusante, como reflexo do relevo muito suave que atravessa, sua declividade gira em torno de 0,1%.

Apresentando uma configuração longilínea e rede de drenagem predominantemente dendrítica, o rio Pacoti drena uma área de 1.257km², se desenvolvendo no sentido sudoeste/nordeste ao longo de 112,5km. Conta com elevado índice de compacidade (1,97) e fator de forma reduzido (0,10).

Sem nenhuma afluência significativa pela margem direita, o Pacoti possui dois contribuintes pela margem esquerda, os riachos Baú e Água Verde. Verifica-se, ainda, em seu baixo curso a presença de lagoas perenes e intermitentes. Todos os cursos d'água da bacia apresentam fluviometria intermitente, na região de baixo curso, sofrendo a influência das marés, apresentando um estuário composto por 160ha de manguezais (CEARÁ, 1999).

A configuração espacial da **Bacia do rio Choró** é bem regular, de forma retangular definida, onde o comprimento do rio, de 200km, é praticamente igual ao da bacia, e a largura que chega, em alguns pontos, a ultrapassar 45km, tem um valor médio de 23km. Esta geometria se reflete em um índice de compacidade muito elevado (1,94) e reduzido fator de forma de 0,12.

Apresenta relevo movimentado no seu terço inicial, atingindo declividades muito altas na origem do rio, na zona montanhosa das serras do Estevão, da Palha e Conceição. A partir da metade do talvegue observa-se o desenvolvimento de um relevo suave de cotas baixas, resultando numa declividade média inferior a 0,1%. A região centro-norte da bacia abrange uma grande parte da formação montanhosa da serra de Baturité.

O próprio formato da bacia é indicador da pouca representatividade dos seus afluentes, que são pouco significantes pela margem direita, destacando-se pela margem esquerda apenas os riachos Cangati, Castro e Aracoiaba, este último, de caráter semi-perene. Os demais cursos d'água da bacia apresentam caráter intermitente, com o rio Choró, próximo ao litoral, sofrendo influência

das marés, apresentando um pequeno estuário composto por 25ha de manguezais.

A bacia hidrográfica do rio Choró constitui-se como uma das alternativas para o reforço do sistema de abastecimento da Região Metropolitana de Fortaleza por ser a maior daquelas que compõem as Metropolitanas (CEARÁ, 1999).

A **bacia hidrográfica do rio Cocó** corresponde a uma área de 304,6 km². O rio Cocó se desenvolve no sentido sul/norte por longo trecho de seu percurso, formando em direção a foz uma acentuada curva de sudoeste para leste. Sua confluência com o rio Coaçu, seu principal afluente, se dá bastante próximo do litoral, fazendo que estes praticamente apresentem comportamento de bacias independentes.

Com o comprimento do talvegue de 42,5km, o rio Cocó apresenta uma configuração longilínea, que se traduz no elevado índice de compacidade de 1,60 e fator de forma reduzido (0,17). Por sua vez, o rio Coaçu se desenvolve ao longo de 32,5km, drenando uma área de 194,8km², apresentando índices de compacidade de 1,35 e fator de forma de 0,18.

Todos os cursos d'água da bacia apresentam caráter intermitente, permanecendo secos durante a maior parte do ano, exceto próximo ao litoral onde os rios Cocó e Coaçu se tornam semi-perenes. Ocorrem, ainda, em seu baixo e médio curso a presença de lagoas perenes e intermitentes, com destaque no eixo do rio Coaçu para as lagoas da Precabura, Sapiranga, Messejana, dos Pássaros e Parnamirim, estas três últimas situadas na malha urbana das cidades de Fortaleza e Eusébio, respectivamente. Ao longo do rio Cocó merecem destaque as lagoas da Maraponga, da Itaoca, do Opaia e do Papicu, e outras de menor porte todas situadas no núcleo urbano de Fortaleza. O Cocó sofre influência das marés, que adentram no seu leito por aproximadamente 13km, formando um estuário alongado e estreito, composto por 210ha de manguezais (CEARÁ, 1999).

Drenando uma área de 1.332,3km², a **Bacia do rio São Gonçalo** apresenta forma retangular longilínea, comprimento do talvegue de 90,0km, índice de compacidade igual a 1,68 e fator de forma de 0,16, com o curso principal se desenvolvendo no sentido sul-norte. Toda a drenagem da bacia apresenta um arranjo de padrão espacial dendrítico, desenvolvido em rochas de diferentes resistências litológicas.

O rio São Gonçalo não possui afluentes de importância, destacando-se apenas o rio Anil e o riacho do Amanari pela margem direita, enquanto que na margem esquerda aparecem os riachos Pau d'Óleo e do Mocó. Todos os afluentes apresentam caráter intermitente permanecendo secos durante a maior parte do ano, exceto próximo ao litoral onde o rio São Gonçalo sofre a influência das marés. Ao longo da bacia surgem diversas lagoas perenes e intermitentes, observando-se na região de baixo curso, próximo ao litoral, a formação de uma extensa lagoa de caráter perene, a Lagoa dos Talos (CEARÁ, 1999).

As características dos reservatórios analisados são apresentadas na TABELA 1 (CEARÁ, 1999).

TABELA 1 – Reservatórios analisados

Reservatório	Município	Rio barrado	Bacia hidrográfica(km ²)	Volume (hm ³)
Acarape do Meio	Redenção	Pacoti	205,00	33,30
Gavião	Pacatuba	Gavião	95,00	29,50
Sítios Novos	Caucaia	São Gonçalo	442,90	123,20
Choró-Limão	Quixadá	Choró	320,00	143,00

De modo geral, o clima das Bacias Metropolitanas se apresenta bastante homogêneo. As variações climáticas registradas são diretamente associadas ao regime pluviométrico e decorrem, fundamentalmente, das seguintes condições (CEARÁ, 1999):

- proximidade do litoral, quando os índices pluviométricos são mais elevados e as temperaturas mais estáveis;

- relevo acidentado, onde ocorrem precipitações orográficas que se somam a temperaturas mais baixas em decorrência da altitude.

Com exceção dos microclimas bem definidos das áreas altas da Serra de Guaramiranga e Baturité, o clima predominante é quente e estável, de elevadas temperaturas e reduzidas amplitudes, com acentuada taxa de insolação, forte poder evaporante e, acima de tudo, com um regime pluviométrico marcadamente irregular.

Esta última particularidade, que também se observa nas zonas de microclima, se constitui, realmente, na característica climática básica.

O regime pluviométrico da região é caracterizado pela heterogeneidade temporal, verificando-se uma concentração da precipitação no primeiro semestre do ano, e uma forte variação inter-anual. Geralmente a estação chuvosa tem início no mês de janeiro e se prolonga até junho. Dentro do primeiro semestre, o trimestre mais chuvoso é o de fevereiro/abril ou o de março/maio, respondendo por 65,0 a 70,0% da precipitação anual. No semestre janeiro/junho este índice supera 90,0% (CEARÁ, 1999).

A análise da distribuição interanual da precipitação revela a ocorrência de anos muito secos, quando o índice de precipitação se reduz a menos de 1/4 ou 1/5 da média anual, com uma frequência estimada de 10,0 a 20,0% sobre períodos longos. Por outro lado, os anos com pluviometria elevada não são muito raros, ocasionando enchentes, e gerando problemas, principalmente em áreas urbanizadas das bacias dos sistemas Ceará/Maranguape e Cocó/Coaçu (CEARÁ, 1999).

Como já citado, o relevo e a proximidade do litoral, exercem apreciável influência sobre os totais anuais, através de suas características de altitude e exposição aos ventos.

Assim, na área de estudo, a distribuição espacial da pluviosidade apresenta a seguinte configuração: (CEARÁ, 1999)

– com exceção das regiões do médio curso do rio São Gonçalo e do Alto/Médio Choró, as demais áreas apresentam índices pluviométricos superiores a 1.000mm anuais. Os maiores índices de precipitação são verificados no litoral de Fortaleza e nas serras de Maranguape, Aratanha e Baturité, onde a ocorrência de chuvas orográficas nestas últimas, induz a índices pluviométricos significativos, acima de 1.400mm, e a ocorrência de microclima;

– nas áreas interioranas das Bacias Metropolitanas, os índices pluviométricos se reduzem ao valor de 800mm, mais especificamente no médio curso do rio São Gonçalo e no alto/médio curso do rio Choró. Índices pluviométricos inferiores a 800mm são verificados nos territórios das referidas bacias, nas regiões de Pentecoste, Canindé, Choró, Quixadá, Ibaretama e Morada Nova.

No que se refere à temperatura, na região vizinha ao litoral a média oscila de 26°C a 27°C, alcançando o patamar de 28°C para as zonas interiores mais centrais; somente nas regiões altas com microclimas, a temperatura média torna-se mais amena e decai para 25°C, atingindo valores inferiores a 22°C no ápice da Serra de Baturité. Por sua vez, as médias das temperaturas máximas e mínimas refletem a estabilidade do regime térmico: em geral, nas regiões mais quentes elas ficam em torno de 33°C a 34°C para as primeiras, e de 22°C a 23°C para as segundas. Nas zonas litorâneas a redução se observa mais na temperatura máxima, que se situa com maior freqüência entre 31°C a 32°C.

Em termos absolutos, as temperaturas podem atingir patamares superiores a 38°C e, somente naquelas áreas altas, as mínimas absolutas diminuem abaixo de 17°C, situando-se na faixa dos 20°C com maior predominância (CEARÁ, 1999).

A umidade relativa do ar, bem como praticamente todos os parâmetros climáticos, está intimamente ligada com a pluviosidade. No período de chuvas ela supera, freqüentemente, a 80%, sendo que, nas regiões litorâneas, alcança valores próximos de 90%, sendo o trimestre março/maio o período mais úmido. Na estiagem, a umidade reduz-se principalmente nas regiões mediterrâneas, mais áridas, e atinge a faixa de 50%. No litoral tal diminuição é menor, situando-se, geralmente, entre 60% e 65%. O período crítico abrange os meses de setembro a novembro. Na média a umidade relativa do ar nas regiões mais secas é de 60% a 65%, e nas úmidas ultrapassa 70%. Quando da ocorrência de anos secos, os valores da umidade variam muito menos e se mantêm em níveis mais reduzidos (CEARÁ, 1999).

Uma das principais características do clima regional diz respeito à favorável insolação. Espacialmente o número médio de horas de insolação altera-se pouco na área, sendo de cerca de 2.650 horas/ano a quase 3.000 horas/ano. Além do mais, no decorrer do ano, a duração de incidência de luz solar apresenta variações moderadas, atingindo os menores valores nos meses de maior pluviometria, em torno de 6,0 horas/dia, e, no auge da estiagem, atinge cerca de 9,0 horas/dia (CEARÁ, 1999).

O mesmo comportamento se observa com a nebulosidade, mais do que qualquer outro parâmetro diretamente dependente da pluviosidade. Em geral, no período chuvoso o índice observado é, freqüentemente, superior a 6,0 décimos, atingindo valores superiores aos 7,5 décimos. Na estiagem, a nebulosidade diminui bastante permanecendo entre 2 décimos e 4 décimos, em especial no trimestre agosto/outubro.

Os ventos só têm maior representatividade nas regiões litorâneas ou nos trechos finais dos vales. Apresentam velocidades maiores no segundo semestre, quando a velocidade média predominante é de 3,0m/s a 4,0m/s. No primeiro semestre, em especial antes do início da

época das chuvas mais abundantes, reduzem-se bastante (CEARÁ, 1999).

No conjunto, as condições climáticas favorecem sobretudo o fenômeno da evaporação, provocando, em consequência, perdas hídricas consideráveis, mormente no que concerne aos volumes acumulados em superfícies livres.

Como tais condições de evaporação são mais intensas durante a estiagem, os índices de evaporação estão implicitamente relacionados com os de pluviometria, quando a ausência de chuvas contribui para o acréscimo das perdas por evaporação. Não há grande variação das taxas de evaporação na área, a não ser nas regiões elevadas de microclima que apresentam taxas mais reduzidas. Em geral, as alturas médias anuais de evaporação medidas em tanques evaporimétricos “Classe A” das estações meteorológicas nas Bacias Metropolitanas variam de 562 mm, na Serra de Guaramiranga, até 1.649 mm em Fortaleza. Apresentam-se na TABELA 2 além dos valores de evaporação mensal e anual para as estações de Fortaleza e Guaramiranga, os valores para outras estações do estado do Ceará (CEARÁ, 1999).

TABELA 2 – Evaporação Média em Tanque Classe A (mm/ano)

Estação	Jan.	Fev.	Mar.	Abr.	Maio	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.	Total Anual
Fortaleza	149	109	85	74	85	95	123	173	193	197	185	181	1.649
Crateús	250	147	112	97	134	188	275	327	358	395	372	334	2.989
Sobral	158	105	75	71	78	108	154	199	215	247	220	210	1.840
Acaraú	202	184	116	91	111	154	192	262	282	291	284	258	2.427
Guaramiranga	51	35	25	25	26	29	40	58	67	70	70	66	562
MÉDIA	162	116	83	72	87	115	157	204	223	240	226	210	1.893

O trimestre úmido março/maio é freqüentemente o de menor índice evaporimétrico, correspondendo, em média, a 15% da evaporação anual, enquanto o de setembro/novembro concentra quase 1/3 do total. A taxa média diária de evaporação em Tanque Classe A é da ordem de 3,5mm/dia a 4,5mm/dia nos meses mais frios, alcançando a faixa de 12mm/dia nos meses quentes nas zonas mais áridas. Quando da ocorrência de anos secos, as alturas totais de evaporação aumentam consideravelmente, podendo superar os 3.300mm/ano, nestes casos, a diferença entre as taxas dos dois semestres reduz-se acentuadamente (CEARÁ, 1999).

O balanço hídrico sazonal segundo o método de Thornthwaite & Mather revela que para as áreas litorâneas a deficiência hídrica tem início no mês de julho prolongando-se até janeiro, com índices situados entre 600 e 750mm anuais. No trimestre úmido, nos anos de pluviometria média ou acima observam-se excedentes hídricos, geralmente inferiores a 100mm, apresentando o litoral de Fortaleza índices próximos a 400mm.

Nas áreas serranas (maciços orográficos), as deficiências hídricas apresentam valores bastante variáveis, como demonstram os índices obtidos nas serras de Baturité (45mm) e Maranguape (705mm). Por sua vez, os excedentes hídricos também apresentam valores variáveis se elevando de cerca de 380mm, na serra de Maranguape, para 780mm na região serrana de Baturité. Na zona do sertão semi-árido as altas taxas de evaporação potencial situadas próximo de 1.650mm, explicam a inexistência de excedentes hídricos, bem como os elevados déficits hídricos dessas áreas, com valores em torno de 850mm (CEARÁ, 1999).

Os açudes, com seus respectivos postos fluviométricos que serviram de base para a geração das séries pseudo-históricas, utilizados nesse estudo estão apresentados na TABELA 3.

TABELA 3 – Açudes analisados com seus postos fluviométricos

Açude	Posto Fluviométrico	Código do Posto
Acarape do Meio	Arariús	35263000
Gavião	Baú	35760000
Sítios Novos	Sítios Novos	35650000
Choró-Limão	Caio Prado	35830000

As séries utilizadas foram geradas através do MODHAC, que é um modelo matemático de simulação da fase superficial do ciclo hidrológico, para utilização no Plano Estadual de Recursos Hídricos do Estado do Ceará. Conhecidas séries simultâneas das variáveis motoras desse processo, chuva e evapotranspiração potencial, o modelo computa o armazenamento e a abstração da água na bacia. Trata-se do que é chamado no jargão hidrológico de modelo globalizado e que tem como mais notável característica a possibilidade de ter seus parâmetros calibrados automaticamente de forma a aprimorar um índice de aderência entre as vazões observadas e calculadas.

A característica que mais diferencia o MODHAC dos demais modelos é que sua modelagem é realizada sobre dois intervalos de tempo, denominados de computação e de simulação. Nos intervalos de computação os cálculos anteriormente descritos são realizados. Um típico exemplo é o intervalo diário. Os escoamentos gerados ao longo dos intervalos de computação são acumulados em intervalos de simulação, por exemplo, em intervalos mensais.

Isto possibilita a análise da propagação das vazões na bacia, atributo dos modelos com largos intervalos de tempo (diários), sem

deixar de considerar a distribuição temporal das chuvas, já que as avaliações podem ser realizadas em pequenos intervalos (horários). A consideração desta distribuição temporal das chuvas é particularmente relevante em climas semi-áridos e de transição para o semi-árido, onde as chuvas de natureza convectiva respondem por parte substancial dos eventos pluviais.

Uma particularidade também notável do MODHAC é que seus parâmetros mais sensíveis, e que respondem pela parte substancial do ajuste das vazões calculadas às observadas, podem ser relacionados a características climatológicas e fisiográficas da bacia. Isto permite a extrapolação dos parâmetros a bacias próximas da região de ajuste, propriedade que deve ser utilizada no estudo.

As séries utilizadas neste trabalho podem ser vistas, de uma forma completa, no Anexo A.

5.2 MODELAGEM DE SÉRIES TEMPORAIS

A caracterização hidrológica das vazões de um curso d'água envolve a análise de dados observados em seções de interesse, com o objetivo de quantificar as magnitudes das vazões mensais, as vazões máximas, as vazões mínimas, as durações das cheias, as durações dos períodos de estiagens, as frequências com que ocorrem cheias, etc.

Várias abordagens podem ser adotadas para a análise das vazões observadas. A escolha da técnica mais adequada é função dos objetivos a serem alcançados, os quais podem envolver questões de engenharia hidráulica, de geografia física, de meio-ambiente, de abastecimento de água, de desenvolvimento regional, dentre outros. Dentre estas, a modelagem de séries temporais desempenha papel de destaque.

A modelagem de séries temporais tem duas principais aplicações no campo da hidrologia e dos recursos hídricos: geração de séries

sintéticas e previsão de futuras séries hidrológicas, cada uma delas com suas aplicações específicas.

A geração de séries sintéticas é utilizada para dimensionamento de reservatórios, determinação do risco de falha de um sistema de irrigação ou hidroelétrico, para estudos de planejamento de futuras operações de reservatórios, planejamento da capacidade de expansão de um sistema de abastecimento de água, dentre outras aplicações, enquanto a previsão de séries é necessária para determinação de políticas de curto prazo para usos de reservatórios, operações em tempo real em bacias hidrográficas, planejamento de políticas durante eventos extremos, como secas, enquanto elas ocorrem, etc. Uma discussão detalhada sobre este assunto pode ser encontrada em SALAS et. al.(1980).

A modelagem de séries temporais pode ser processo simples ou complexo, depende fortemente das características das séries analisadas, do tipo de modelo a ser utilizado e das técnicas de modelagem selecionadas (SALAS et. al., 1980).

Em geral, o processo de modelagem das séries temporais pode ser organizado nos seguintes estágios (BOX & JENKINS, 1976):

- 1) seleção do tipo de modelo;
- 2) identificação da forma do modelo;
- 3) estimativa dos parâmetros do modelo e
- 4) validação do modelo.

O primeiro estágio se refere à seleção do tipo de modelo entre os diversos tipos disponíveis para o analista, por exemplo, dois tipos comuns de representação para a dependência de séries temporais são o modelo da Cadeia Markoviana e o modelo auto-regressivo. Para um caso particular o modelador pode ter que escolher entre esses dois tipos. Uma vez selecionado o tipo de modelo, o próximo estágio é

identificar a forma ou ordem do modelo. Por exemplo, se o modelo escolhido no primeiro estágio for o autoregressivo, então é necessário identificar a ordem deste modelo autoregressivo, que pode ser ordem um (um coeficiente autoregressivo e um parâmetro), ordem dois, etc. Esse procedimento é geralmente feito com base na análise das funções de autocorrelação e autocorrelação parcial. O terceiro estágio consiste em estimar os parâmetros do modelo, identificado no estágio dois, tendo-se como finalidade a minimização de alguma função custo (objetivo), como por exemplo o erro médio quadrático. O estágio final da modelagem implica em que seja feita a validação do modelo, para verificar a adequabilidade do modelo, ou seja, investigar se ele realmente se aplica para o que se deseja modelar. A visão geral do processo de modelagem de séries temporais é, de fato, um processo iterativo através da análise de cada uma das etapas acima mencionadas isoladamente e em conjunto (SALAS et. al., 1980).

Seqüências caracterizadas por propriedades estatísticas são chamadas de processos estocásticos. Um processo estocástico é uma abstração matemática de um processo empírico, cujo desenvolvimento é regido por leis probabilísticas. Aproximadamente todos os processos hidrológicos podem ser caracterizados como estocásticos, ou uma combinação de processos determinísticos e estocásticos (YEVJEVICH, 1972).

As vazões são analisadas como variáveis aleatórias de um processo estocástico, pois a ocorrência de um determinado valor para a vazão em um determinado instante ou intervalo de tempo é função de valores de variáveis determinísticas e de variáveis aleatórias que influem no processo de ocorrência de vazões, como armazenamento da água em lençóis subterrâneos, ocorrência de precipitações, teor de umidade da água no solo de superfície da bacia hidrográfica etc. Nos processos estocásticos, admite-se que a natureza gere vazões sujeitas a distribuições de probabilidade (RIGHETTO, 1998).

Uma série temporal pode possuir três componentes principais, isto é, um componente de tendência, um de periodicidade e um aleatório. O componente de tendência descreve qualquer aumento ou diminuição dos valores de vazão com o tempo. O componente de periodicidade descreve as variações sazonais das vazões em função das condições climáticas e o componente aleatório descreve a aleatoriedade de ocorrência das precipitações e, conseqüentemente, das magnitudes das vazões.

Os modelos são construídos, então, para reproduzir as principais características estatísticas da série histórica representativa do evento hidrológico que se deseja analisar.

O que os hidrólogos não são capazes de definir com precisão é quais são as principais características a serem reproduzidas pelo modelo e como essas características devem ser interpretadas e entendidas.

Infelizmente, não existe uma resposta rápida e única para responder o questionamento feito. Em primeiro lugar, as verdadeiras características estatísticas da série hidrológica nunca são conhecidas, pois o que é observado, ou medido, é simplesmente um número (N) de anos finito (amostra) e, como resultado, as características estatísticas obtidas através dessa amostra são apenas estimativas das verdadeiras características, que na realidade são desconhecidas. Essas estimativas são consideradas incertas, pois se não tivéssemos uma amostra de N anos de observação e sim uma outra amostra de N' de dados, as características estimadas seriam diferentes das encontradas tomando como base as do registro de N anos. Pode ser dito que as características obtidas através de uma amostra qualquer representam apenas uma das possibilidades dentre diversas outras, isto é, representações de uma variável aleatória, conseqüentemente incertas. Tais incertezas devem ser incorporadas no processo de modelagem da série hidrológica (SALAS et. al., 1980).

Além do problema relacionado às incertezas das características estatísticas de uma dada amostra de uma série temporal, existem também as questões da definição e interpretação dessas características obtidas por essa amostra. As principais são **média** (μ) (equação 20), **desvio padrão** (σ) (equação 21), **coeficiente de assimetria** (g) (equação 22) e **autocorrelação** (r) (equação 24). Geralmente a média e o desvio padrão são as que menos apresentam incertezas. Conseqüentemente não se questiona sua representatividade para o modelo. A assimetria é altamente incerta, se o modelo é capaz ou não de reproduzir precisamente, depende muito do tamanho da amostra e do quão é importante a assimetria para a aplicação. A auto-correlação apresenta também alto grau de incerteza, especialmente para pequenas amostras. Sua interpretação normalmente influencia no tipo de modelo a ser adotado, bem como na sua forma (SALAS et. al., 1980).

As equações abaixo podem ser encontradas em SALAS et al. (1980):

$$\mu = \frac{\sum_{i=1}^n x_i}{n} \quad (20)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{(n-1)}} \quad (21)$$

$$g = \frac{n \cdot \sum_{i=1}^n (x_i - \mu)^3}{(n-1) \cdot (n-2) \cdot \sigma^3} \quad (22)$$

A série temporal hidrológica pode ser dita **univariada**, ou unidimensional, quando é uma representação de uma específica característica hidrológica em um único ponto (local), como uma série

que representa a pluviometria em um determinado posto, ou denominada **multivariada**, ou multidimensional, quando representa diversas séries hidrológicas em diversos pontos, casos de diversas séries, todas elas pluviométricas, em diversos postos de diferentes locais, ou séries de diferentes características hidrológicas em um mesmo ponto, série pluviométrica, série fluviométrica e série representativa da qualidade da água para um único ponto.

As séries univariadas são descritas por suas características estatísticas, características estas já mencionadas, enquanto as séries multivariadas requerem, além das características estatísticas individuais para cada série, de coeficientes que expressem as inter-relações entre as séries.

Tanto as séries univariadas quanto as multivariadas são estudadas, na grande maioria dos casos, como séries discretas de vários intervalos. Estes intervalos podem ser anuais, mensais, semanais, etc.

Dentro da modelagem de séries temporais a **função de autocorrelação** representa uma importante medida de dependência linear entre o valor da variável aleatória no tempo t e seu valor no tempo $t-k$, em que k é o *lag* (retardo). A autocorrelação nada mais é do que a autocovariância padronizada dividida pelo desvio-padrão. No caso de $k = 5$, o grau de dependência linear de uma vazão que ocorreu há cinco semanas é medido por essa função. A autocovariância ρ_k entre Z_t e Z_{t-k} pode ser definida por (VALENÇA, 1999):

$$\rho_{k,m} = \frac{1}{N} \cdot \sum_{t=1}^N (Z_t - \mu_m) \cdot (Z_{t-k} - \mu_{m-k}) \quad (23)$$

em que N é o número de anos; k é o *lag*; μ_m é uma estimativa da média periódica e m é o período considerado (semanal, mensal).

Logo, a autocorrelação r_k pode ser determinada por:

$$r_{k,m} = \frac{1}{N} \cdot \sum_{t=1}^N (Z_t - \mu_m) \cdot (Z_{t-k} - \mu_{m-k}) / (\sigma_m - \sigma_{m-k}) \quad (24)$$

e σ_m é uma estimativa do desvio-padrão para o período m .

Quando se analisam séries de vazões intra-anuais, isso é, mensais e semanais, deve-se incorporar o efeito da sazonalidade. Uma forma de se identificar a sazonalidade é através da análise da função de autocorrelação que deve apresentar valores altos em *lags* sazonais (VALENÇA, 1999).

De um modo geral, no início de qualquer processo de modelagem de séries temporais hidrológicas, deve ser decidido se o modelo a ser adotado será univariado, multivariado, ou uma combinação desses modelos, dependendo dos tipos de séries temporais utilizadas no mesmo. Essa decisão se refere à composição do modelo e depende das características do sistema em estudo, da série hidrológica e dos dados utilizados pelo projetista.

Convém ressaltar que para a modelagem de séries hidrológicas através de RNAs, há a necessidade de se dispor de séries de tempo que envolvam eventos hidrológicamente diversificados. A ocorrência de eventos extremos no período de validação sem par no período de calibração, ou vice-versa, conduz a erros consideráveis, visto que se a rede não foi treinada com aquele tipo de situação ela não poderá reproduzi-la com acerto.

5.3 MODELAGEM VIA RNAs

Os modelos de previsão de séries temporais podem ser divididos em dois grupos básicos: os modelos univariados e os modelos multivariados, conforme definição anterior.

Neste trabalho foram desenvolvidos modelos univariados para as séries fluviométricas de cada um dos quatro açudes em estudo, de modo independente, e também um modelo multivariado em que as séries pseudo-históricas dos quatro açudes foram trabalhadas simultaneamente.

Para a modelagem com RNAs, foi utilizado o MATLAB, que é um pacote computacional para computação numérica científica e de engenharia. O MATLAB integra análise numérica, cálculo de matrizes, processamento de sinais e construção de gráficos em um desenvolvimento de fácil utilização onde problemas e soluções são expressados exatamente como eles são escritos matematicamente sem programação tradicional.

O nome MATLAB vem de MATrix LABoratory, pois ele é um sistema interativo onde o elemento básico é uma matriz. Isto permite resolver muitos problemas numéricos em um tempo bem menor do que se levaria para escrever um programa em linguagens convencionais tais como Fortran ou C.

No desenvolvimento de pesquisas, o MATLAB tem se tornado uma ferramenta padrão para cursos introdutórios em álgebra linear aplicada e para cursos avançados em outras áreas. Na indústria, o MATLAB é usado para pesquisas e para resolver problemas de engenharia e matemática.

O MATLAB apresenta ainda diversos *toolboxes*, para o desenvolvimento de atividades específicas, dentre eles um *toolbox* próprio para treinamento, validação e simulação de RNAs, o *Neural Network Toolbox*, que foi adotado no presente trabalho.

Em todos os modelos as redes neurais artificiais utilizadas eram do tipo *feedforward* que adotavam o algoritmo *backpropagation* como método sistemático de correção iterativa dos erros e minimização do somatório do erro quadrático como função objetivo.

O primeiro passo foi criar os pesos e *biases* para as redes, o que é feito no MATLAB, através da função *initff*. Esta função toma uma matriz de vetores de entrada **X**, além das funções de transferência de cada camada, e retorna os pesos **W** e os *biases* **b** para cada camada.

Após os pesos e os *biases* terem sido criados, o próximo passo é realizar o treinamento propriamente dito da rede. Esse treinamento pode ser realizado, dentro do MATLAB, através de três funções diferentes, a saber: *trainbp*, *trainbpx* e *trainlm*. A função *trainbp* utiliza o algoritmo *backpropagation* de modo direto, usando sua definição original. A função *trainbpx* usa técnicas chamadas *momentum* e *taxa de aprendizagem adaptativa*, que aumentam a velocidade do *backpropagation*.

O termo *momentum* diminui a sensibilidade do algoritmo *backpropagation* a pequenos detalhes na superfície do erro. Isto ajuda a rede a evitar ficar “estacionada” em pontos de mínimos locais, que impediriam a rede de encontrar uma solução com erro bem menor.

A *taxa de aprendizagem adaptativa* reduz o tempo de treinamento, pois ela, como o próprio nome sugere, modifica a taxa de aprendizagem tornando o “passo” maior enquanto se caminha numa direção em que o erro está diminuindo e tornando-a novamente pequena quando se avança num sentido que tenha causado um acréscimo no erro.

A função de treinamento *trainlm* usa a otimização de Levenberg-Marquardt para tentar reduzir mais ainda o tempo de treinamento, entretanto, como ela requer muito mais memória computacional do que o *trainbpx*, nos casos em estudo ela se tornava bem mais demorada do que a outra função na convergência para a solução de erro mínimo, fato este creditado às configurações do micro-computador utilizado nas modelagens.

Foi utilizada, então, nas modelagens, para o treinamento das redes, a função *trainbpx*.

Após a fase de treinamento da rede, isto é, após terem sido definidos seus pesos e *biases*, a próxima etapa foi simular o comportamento da rede através da função *simuff* que retorna valores para novas entradas apresentadas à rede.

No presente trabalho, após o treinamento das redes que foi realizado com apenas uma parte dos valores da série, as mesmas eram simuladas, e verificados os seus ajustes para todos os valores apresentados pela série, tanto os utilizados para treinamento como os que não haviam sido utilizados, estes últimos valores representando assim as situações para as quais as redes ainda não haviam sido apresentadas.

Podem ser vistos no Anexo B dois modelos das rotinas utilizadas para treinamento e simulação das Redes Neurais Artificiais durante a pesquisa, um modelo para redes com uma camada intermediária e outro para redes com duas camadas intermediárias.

5.3.1 PADRONIZAÇÃO DAS SÉRIES

Antes de serem simuladas através do MATLAB, as séries pseudo-históricas passaram por um tratamento onde sofreram algumas operações matemáticas. O primeiro processo foi o de dessazonalização, onde foram “removidos” os efeitos da média e do desvio-padrão sazonais através da operação apresentada na equação 25:

$$x'_i = \frac{x_i - \mu_i}{\sigma_i} \quad (25)$$

onde x'_i representa o valor dessazonalizado da vazão, x o valor original, μ_i a média relativa ao mês i , e σ_i o desvio-padrão desse mesmo mês.

Os novos valores dessazonalizados foram então ajustados para o intervalo fechado $[0,1]$. A importância desse procedimento advém do fato das *funções de ativação* utilizadas nos períodos de treinamento e validação das Redes Neurais Artificiais serem do tipo *sigmóide*, funções estas que apresentam intervalo de saída restrito ao intervalo $[0,1]$. Dos valores dessazonalizados foi então subtraído o menor valor encontrado (x_{min}), o que garantiu que toda a série estivesse então com valores maiores ou iguais a zero. Nesse estágio todos os pontos da série foram divididos pelo maior valor (x_{max}), conforme apresentado na equação 26:

$$x_i'' = \frac{x_i' - x_{min}}{x_{max}} \quad (26)$$

Com as duas operações descritas acima, a série agora estava restrita ao intervalo fechado $[0,1]$, o que permitiu a sua posterior comparação com os resultados obtidos pela simulação através das RNAs.

5.3.2 ESCOLHA DA TOPOLOGIA E TREINAMENTO DAS RNAs

Não existe ainda uma padronização no processo para a escolha da topologia de rede a ser utilizada em cada situação. Compete ao hidrólogo se valer de sua experiência e de diversas tentativas para a escolha da topologia mais adequada ao problema em mãos.

Como norteadoras do critério de determinação do número de neurônios da camada de entrada foram utilizadas as funções de autocorrelação e correlação cruzada, cujos valores são apresentados no capítulo 6, Resultados e Discussões, na forma de tabelas.

Para análise dos modelos univariados, utilizaram-se apenas os valores obtidos com a função de autocorrelação. Para cada uma das séries em estudo, os meses que apresentaram correlação maior ou igual

a 0,35 foram então considerados relevantes e serviram como nós de entrada para as redes a serem treinadas.

Os valores relevantes para as quatro séries de afluições analisadas, com os respectivos meses, estão destacados na TABELA 4 abaixo.

TABELA 4 – Valores relevantes para os modelos univariados

Série	Autocorrelação	Variável Padronizada (x'')
Acarape do Meio	0,660	$X_{i-1,j}$
	0,363	$X_{i+1,j-1}$
	0,464	$X_{i,j-1}$
	0,357	$X_{i-1,j-1}$
Gavião	0,613	$X_{i-1,j}$
	0,372	$X_{i+1,j-1}$
	0,497	$X_{i,j-1}$
	0,359	$X_{i-1,j-1}$
Sítios Novos	0,530	$X_{i-1,j}$
	0,436	$X_{i,j-1}$
Choró-Limão	0,538	$X_{i-1,j}$
	0,336*	$X_{i,j-1}$

Os índices i e j nas afluições indicam, respectivamente, o mês e o ano, assim, o valor $X_{i,j}$ representa o mês i do ano j , o qual se deseja obter como saída da rede; o valor $X_{i-1,j}$ representa o mês anterior ao mês i do mesmo ano j , e assim sucessivamente.

*Pode ser observado que para o açude Choró-Limão, foi utilizada uma entrada para a rede com valor de autocorrelação inferior a 0,35. Isto decorre do fato de não ser recomendado se trabalhar com somente um nó na camada de entrada das RNAs, fato este que ocorreria caso o critério de escolha permanecesse fixo em 0,35.

Para os modelos multivariados foi utilizada a correlação cruzada, correlação entre os quatro postos, dois a dois, para a determinação dos valores relevantes para servirem como nós da camada de entrada, além dos valores obtidos pela função de autocorrelação. Nesta modelagem, pela maior complexidade física da representação, foram trabalhadas diversas possibilidades para as camadas de entrada, todas tomando como base as funções de autocorrelação e correlação cruzada.

A primeira modelagem funcionou utilizando o mesmo critério aplicado na modelagem univariada, ou seja, empregando como nós constituintes da camada de entrada, os meses que tiverem valor de correlação maior ou igual a 0,35. Nesse caso, foram trabalhadas redes com 06 (seis) nós de entrada, nós estes que podem ser vistos na TABELA 5.

TABELA 5 – Nós das camadas de entrada – Modelagem Multivariada I

Série	Variável Padronizada (x'')
Acarape do Meio	$X_{i-1,j}$
	$X_{i,j-1}$
Gavião	$X_{i-1,j}$
	$X_{i,j-1}$
Sítios Novos	$X_{i-1,j}$
Choró-Limão	$X_{i-1,j}$

A segunda modelagem trabalhou com um valor limite de correlação para o emprego dos meses um pouco menor, de tal forma que fossem analisadas redes com mais neurônios na camada de entrada. Foi utilizado o valor de 0,30, ao invés de 0,35. Nesse caso foram testadas redes com 09 (nove) nós na camada de entrada. A motivação dessa idéia de trabalhar com um número maior de nós nas camadas de entrada, foram os resultados obtidos através das tentativas

com apenas seis neurônios terem sido bem inferiores aos obtidos nas modelagens univariadas, como é mostrado no Capítulo 6 Resultados e Discussões. Os meses que serviram como camada de entrada para essa modelagem são mostrados na TABELA 6.

TABELA 6– Nós das camadas de entrada –Modelagem Multivariada II

Série	Variável Padronizada (x'')
Acarape do Meio	$X_{i-1,j}$
	$X_{i+1,j-1}$
	$X_{i,j-1}$
Gavião	$X_{i-1,j}$
	$X_{i,j-1}$
Sítios Novos	$X_{i-1,j}$
	$X_{i,j-1}$
Choró-Limão	$X_{i-1,j}$
	$X_{i,j-1}$

A terceira modelagem multivariada utilizou os mesmos meses aplicados nas modelagens univariadas como entradas. Com essa técnica foram utilizados os mesmos 12 (doze) meses já empregados nas modelagens univariadas, que podem ser vistos na Tabela 4.

A quarta, e última, modelagem multivariada adotou um critério mais empírico. Como, à medida em que se aumentava o número de neurônios nas camadas de entrada, até então, os resultados obtidos ficavam melhores, aumentou-se, então, o número de nós dessas camada através da adição de um nó relativo a cada série fluviométrica, o que levou o número de nós desta camada para 16 (dezesesseis), como pode ser visto na Tabela 7

TABELA 7– Nós das camadas de entrada –Modelagem Multivariada IV

Série	Variável Padronizada (x'')
Acarape do Meio	$X_{i-1,j}$
	$X_{i+1,j-1}$
	$X_{i,j-1}$
	$X_{i-1,j-1}$
	$X_{i,j-2}$
Gavião	$X_{i-1,j}$
	$X_{i+1,j-1}$
	$X_{i,j-1}$
	$X_{i-1,j-1}$
	$X_{i,j-2}$
Sítios Novos	$X_{i-1,j}$
	$X_{i-2,j}$
	$X_{i,j-1}$
Choró-Limão	$X_{i-1,j}$
	$X_{i-2,j}$
	$X_{i,j-1}$

O número de neurônios das camadas intermediárias não obedeceu a nenhum critério matemático ou estatístico, simplesmente foram treinadas diversas redes com diferentes quantidades de nós na(s) camada(s) intermediária(s). As RNAs utilizadas eram compostas de uma ou duas camadas intermediárias, haja visto que as experiências mostram que redes com estas arquiteturas são capazes de representar sistemas desse porte, como em SIVAKUMAR et al. (2002), MINNS & HALL (1996), BALLINI et al. (1997) entre outros.

Os nós da camada de saída, que são as respostas apresentadas pela rede, representavam a vazão no mês que se buscava prever. Esta camada tinha, então, um único nó nas modelagens univariadas, pois se referia a somente uma série de afluições, e quatro nós nas modelagens multivariadas, pois se referia às quatro séries de afluições.

Como critérios de convergência foram adotados dois métodos, o primeiro seria um erro máximo tolerado, no caso o erro adotado foi de 1,0 (em função dos primeiros resultados satisfatórios encontrados) e o segundo um número máximo de ciclos, adotado como 5.000.

Na Figura 7 é apresentado um fluxograma ilustrativo da modelagem adotada nesse estudo.

Como as séries continham dados referentes a 85 anos de vazões mensais, durante a *fase de treinamento*, foram apresentados à rede dados relativos a 75 anos e durante a *fase de simulação* eram apresentados tanto os outros 10 anos de dados como eram feitas as simulações também para os dados anteriormente apresentados à rede para treinamento, ou seja, a simulação era feita com os 85 anos da série.

Durante a fase de *validação do modelo (no fluxograma)* eram feitas as análises gráficas das séries simulada e histórica, análises do erro total obtido pelo modelo durante a simulação e análises de correlação.

Figura 7 – Fluxograma do processo de modelagem adotada

5.3.3 CONCEPÇÃO DOS MODELOS E GERAÇÃO DE SÉRIES SINTÉTICAS PARA VERIFICAÇÃO

Os modelos de séries temporais possuem uma componente aleatória, que, no caso, pode ser assumida como a parcela que resulta os resíduos dos modelos. Os desvios de cada posto foram ordenados em ordem decrescente, aos quais foram atribuídas ordens m de 1 a n (comprimento da série). As probabilidades de ocorrência $(1-F)$ foram então calculadas, de acordo com o método de Kimbal, como:

$$1-F = 1 - \frac{m}{n+1} \quad (27)$$

Assim, foram construídas as curvas de probabilidade de ocorrência de resíduos de magnitudes diversas (Desvio $\times (1-F)$).

Aos valores produzidos via modelos de RNAs, números aleatórios gerados em conformidade com essas funções de distribuição de probabilidades devem ser adicionados. Números aleatórios uniformemente distribuídos na faixa de 0 a 1 eram gerados e as magnitudes dos desvios correspondentes a essas probabilidades de ocorrência para cada posto eram então obtidas das respectivas curvas. Tais valores eram somados àqueles produzidos via RNAs e serviam para “realimentar” o processo como novos dados de entrada para a geração sintética via RNAs.

As séries assim produzidas tiveram seus valores submetidos ao processo inverso da padronização para que fosse realizada a comparação de suas características com as séries originais. Assim, cada valor foi multiplicado pelo mesmo valor que havia sido dividido anteriormente ($x_{\max}$) e, em seguida, somado ao menor valor da série ($x_{\min}$) o qual tinha sido subtraído, operações inversas às que haviam sido realizadas anteriormente com o intuito de deixar os valores da série dentro do intervalo $[0, 1]$. Finalmente estes valores foram então

multiplicados pelo desvio-padrão sazonal e somados à média sazonal. Convém ressaltar que a média e o desvio-padrão eram os mensais, enquanto que os valores máximo e mínimo, que foram respectivamente multiplicados e subtraídos, se referiam aos valores máximo e mínimo de toda a série.

O escopo original desta pesquisa visava fazer um estudo comparativo entre os resultados obtidos com a modelagem através das RNAs e uma outra modelagem através da metodologia empregada por BOX & JENKINS (1976). Entretanto, deparou-se com dificuldades relacionadas à normalização das séries, desejável para que fosse realizada a modelagem do tipo BOX-JENKINS, apesar das diversas tentativas, que incluíram dessazonalização simples, transformações BOX-COX, transformações logarítmicas e aproximações estatísticas. Atribui-se tal característica, ao fato do grande número de vazões nulas (vazão = 0) ou muito baixas, existentes em todas as séries, principalmente nas séries representativas das afluições aos açudes Choró e Sítios Novos, com respectivamente 440 e 162 registros de afluição mensal nula.

Face a esta característica das séries em estudo, restringiu-se a modelagem via Redes Neurais Artificiais.

6. RESULTADOS E DISCUSSÕES

A apresentação dos resultados foi dividida em duas partes, acompanhando a seqüência em que foram efetivamente desenvolvidos os modelos. Inicialmente são apresentados e discutidos os resultados obtidos com a modelagem das séries afluentes aos quatro reservatórios independentemente uns dos outros, os **modelos univariados**. Em seguida é apresentada a modelagem das afluições aos quatro reservatórios simultaneamente, os **modelos multivariados**.

Em todos os casos são apresentados os três melhores resultados, obtidos no treinamento com as RNAs, em tabelas que indicam a topologia utilizada para obter o resultado indicado e o erro obtido no treinamento.

São apresentadas também as principais características estatísticas das séries modeladas para serem comparadas às mesmas características das séries originais.

6.1 MODELOS UNIVARIADOS

Conforme apresentado no item 5.3, **Modelos Aplicados na Modelagem**, a modelagem univariada consistiu em simulações através de RNAs para as quatro séries alvo deste estudo padronizadas em relação às médias, desvios padrão, e $x_{\min}$, $x_{\max}$, indicados nas Tabelas 8, 9 e 10. Nas Tabelas 8 e 9, as séries 1, 2, 3 e 4 correspondem, respectivamente às séries de afluições aos reservatórios Acarape do Meio, Gavião, Sítios Novos e Choró-Limão.

Tabela 8 – Médias mensais (m^3/s)

Série	jan	fev	mar	abr	maio	jun	jul	ago	set	out	nov	dez
1	0,384	1,770	7,079	10,843	9,006	4,233	1,725	0,615	0,537	0,442	0,306	0,228
2	0,154	0,838	2,949	4,618	3,304	1,317	0,544	0,271	0,168	0,112	0,065	0,131
3	0,137	1,283	6,911	12,094	6,649	1,311	0,471	0,309	0,184	0,052	0,002	0,003
4	0,912	2,628	17,695	28,801	21,024	7,646	4,087	1,259	0,081	0,000	0,000	0,003

Tabela 9 – Desvio-padrão

Série	jan	fev	mar	abr	maio	jun	jul	ago	set	out	nov	dez
1	0,970	2,923	7,019	8,384	7,770	4,444	2,497	0,211	0,174	0,178	0,141	0,117
2	0,660	1,746	3,667	4,139	3,361	1,937	0,984	0,451	0,095	0,072	0,044	0,828
3	0,971	3,607	9,626	10,867	8,951	2,102	0,901	0,758	0,525	0,197	0,006	0,007
4	5,987	7,507	31,664	39,951	30,838	11,409	6,245	2,936	0,516	0,000	0,001	0,014

Tabela 10 – Valores de x_{min} e x_{max}

Série	x_{min}	x_{max}
Acarape do Meio	-2,900	8,380
Gavião	-1,768	10,872
Sítios Novos	-1,113	10,087
Choró-Limão	-0,721	9,832

Foram trabalhadas diversas topologias diferentes para que fossem adotadas aquelas que mais representavam as características das séries, redes com uma e duas camadas intermediárias, cujo número de neurônios variava de 2 até 50, por camada intermediária. Os componentes das camadas de entrada foram tomados com base nos respectivos correlogramas, conforme discutido no item **5.3 Modelos Aplicados na Modelagem**.

6.1.1 ACARAPE DO MEIO

Para a série de aflúências ao reservatório Acarape do Meio, as auto-correlações históricas e simuladas são apresentadas na TABELA 11 e na Figura 08, e as melhores topologias, dentre as redes treinadas, são mostradas na TABELA 12.

TABELA 11 – Auto-correlações modelada (M) e histórica (H) –
Acarape do Meio

LAG	CORREL. (M)	CORREL. (H)
0	1,000	1,000
1	0,660	0,694
2	0,296	0,268
3	-0,019	-0,082
4	-0,167	-0,255
5	-0,216	-0,310
6	-0,225	-0,320
7	-0,219	-0,312
8	-0,186	-0,264
9	-0,074	-0,113
10	0,125	0,171
11	0,363	0,487
12	0,464	0,636
13	0,357	0,487
14	0,134	0,161
15	-0,084	-0,122
16	-0,186	-0,266
17	-0,225	-0,317
18	-0,231	-0,325
19	-0,228	-0,319
20	-0,200	-0,274
21	-0,109	-0,137
22	0,069	0,124
23	0,273	0,423
24	0,334	0,539

Figura 8 – Auto-correlações histórica e modelada – Acarape do Meio

TABELA 12 – Melhores resultados - Acarape do Meio

TOPOLOGIA	SSE
4-12-1	5,667
4-10-1	5,981
4-08-1	6,025

Na TABELA 13 são apresentadas as principais características estatísticas das séries modelada, através da rede que apresentou o melhor resultado, e histórica.

TABELA 13 – Características estatísticas das séries modelada e histórica – Acarape do Meio

MÊS	Média (M) (m ³ /s)	Média (H) (m ³ /s)	Desvio Padrão (M)	Desvio Padrão (H)	Coef. de Variação (M)	Coef. de Variação (H)
JANEIRO	0,385	0,384	0,405	0,970	1,052	2,526
FEVEREIRO	1,695	1,770	1,784	2,923	1,053	1,651
MARÇO	7,007	7,079	4,855	7,019	0,693	0,992
ABRIL	10,763	10,843	5,975	8,384	0,555	0,773
MAIO	8,897	9,006	5,427	7,770	0,610	0,863
JUNHO	4,195	4,233	3,046	4,444	0,726	1,050
JULHO	1,698	1,725	1,412	2,497	0,832	1,448
AGOSTO	0,620	0,615	0,162	0,211	0,261	0,343
SETEMBRO	0,542	0,537	0,147	0,174	0,271	0,324
OUTUBRO	0,444	0,442	0,147	0,178	0,331	0,403
NOVEMBRO	0,307	0,306	0,111	0,141	0,362	0,461
DEZEMBRO	0,225	0,228	0,094	0,117	0,418	0,513

6.1.2 GAVIÃO

Para a série de aflúências ao reservatório Gavião, as auto-correlações históricas e simuladas são apresentadas na TABELA 14 e na Figura 09, e as melhores topologias, dentre as redes treinadas, são mostradas na TABELA 15.

TABELA 14 – Auto-correlações modelada (M) e histórica (H) – Gavião

LAG	CORREL. (M)	CORREL. (H)
0	1,000	1,000
1	0,613	0,678
2	0,287	0,249
3	0,029	-0,079
4	-0,113	-0,233
5	-0,160	-0,289
6	-0,175	-0,305
7	-0,169	-0,292
8	-0,137	-0,243
9	-0,049	-0,111
10	0,119	0,168
11	0,372	0,546
12	0,497	0,710
13	0,359	0,517
14	0,147	0,166
15	-0,038	-0,113
16	-0,132	-0,244
17	-0,170	-0,295
18	-0,180	-0,309
19	-0,177	-0,298
20	-0,141	-0,247
21	-0,072	-0,126
22	0,073	0,130
23	0,245	0,446
24	0,295	0,586

Figura 9 – Auto-correlações histórica e modelada – Gavião

TABELA 15 – Melhores resultados - Gavião

TOPOLOGIA	SSE
4-09-1	6,542
4-15-1	6,771
4-12-1	6,846

Na TABELA 16 são apresentadas as principais características estatísticas das séries modelada, através da rede que apresentou o melhor resultado, e histórica.

TABELA 16 – Características estatísticas das séries modelada e histórica – Gavião

MÊS	Média (M) (m ³ /s)	Média (H) (m ³ /s)	Desvio Padrão (M)	Desvio Padrão (H)	Coef. de Variação (M)	Coef. de Variação (H)
JANEIRO	0,132	0,154	0,248	0,660	1,879	4,286
FEVEREIRO	0,779	0,838	0,881	1,746	1,131	2,084
MARÇO	2,870	2,949	2,082	3,667	0,725	1,243
ABRIL	4,669	4,618	2,490	4,139	0,533	0,896
MAIO	3,293	3,304	2,057	3,361	0,625	1,017
JUNHO	1,286	1,317	1,080	1,937	0,840	1,471
JULHO	0,518	0,544	0,487	0,984	0,940	1,809
AGOSTO	0,262	0,271	0,128	0,451	0,489	1,664
SETEMBRO	0,170	0,168	0,063	0,095	0,371	0,565
OUTUBRO	0,113	0,112	0,046	0,072	0,407	0,643
NOVEMBRO	0,065	0,065	0,029	0,044	0,446	0,677
DEZEMBRO	0,110	0,131	0,195	0,828	1,773	6,321

6.1.3 SÍTIOS NOVOS

Para a série de afluições ao reservatório Sítios Novos, as auto-correlações históricas e simuladas são apresentadas na TABELA 17 e na Figura 10, e as melhores topologias, dentre as redes treinadas, são mostradas na TABELA 18.

TABELA 17 – Auto-correlações modelada (M) e histórica (H) – Sítios Novos

LAG	CORREL. (M)	CORREL. (H)
0	1,000	1,000
1	0,530	0,583
2	0,159	0,112
3	-0,039	-0,123
4	-0,101	-0,197
5	-0,127	-0,222
6	-0,133	-0,231
7	-0,130	-0,226
8	-0,120	-0,206
9	-0,084	-0,146
10	0,048	0,059
11	0,314	0,482
12	0,436	0,683
13	0,294	0,446
14	0,060	0,068
15	-0,076	-0,141
16	-0,117	-0,205
17	-0,132	-0,225
18	-0,137	-0,231
19	-0,137	-0,227
20	-0,129	-0,209
21	-0,094	-0,152
22	0,014	0,037
23	0,193	0,372
24	0,294	0,563

Figura 10 – Auto-correlações histórica e modelada – Sítios Novos

TABELA 18 – Melhores resultados - Sítios Novos

TOPOLOGIA	SSE
3-15-1	6,597
3-10-1	6,713
3-08-1	6,788

Na TABELA 19 são apresentadas as principais características estatísticas das séries modelada, através da rede que apresentou o melhor resultado, e histórica.

TABELA 19 – Características estatísticas das séries modelada e histórica – Sítios Novos

MÊS	Média (M) (m ³ /s)	Média (H) (m ³ /s)	Desvio Padrão (M)	Desvio Padrão (H)	Coef. de Variação (M)	Coef. de Variação (H)
JANEIRO	0,136	0,137	0,213	0,971	1,566	7,088
FEVEREIRO	1,352	1,283	1,923	3,607	1,422	2,811
MARÇO	7,494	6,911	6,572	9,626	0,877	1,393
ABRIL	13,255	12,094	7,521	10,867	0,567	0,899
MAIO	7,140	6,649	5,686	8,951	0,796	1,346
JUNHO	1,455	1,311	1,539	2,102	1,058	1,603
JULHO	0,546	0,471	0,769	0,901	1,408	1,913
AGOSTO	0,363	0,309	0,633	0,758	1,744	2,453
SETEMBRO	0,206	0,184	0,391	0,525	1,898	2,853
OUTUBRO	0,062	0,052	0,157	0,197	2,532	3,788
NOVEMBRO	0,002	0,002	0,003	0,006	1,500	3,000
DEZEMBRO	0,003	0,003	0,004	0,007	1,333	2,333

6.1.4 CHORÓ-LIMÃO

Para a série de afluições ao reservatório Choró-Limão, as auto-correlações históricas e simuladas são apresentadas na TABELA 20 e na Figura 11, e as melhores topologias, dentre as redes treinadas, são mostradas na TABELA 21.

TABELA 20 – Auto-correlações modelada (M) e histórica (H) – Choró-Limão

LAG	CORREL. (M)	CORREL. (H)
0	1,000	1,000
1	0,538	0,589
2	0,256	0,222
3	0,068	-0,036
4	-0,032	-0,169
5	-0,091	-0,238
6	-0,112	-0,259
7	-0,107	-0,246
8	-0,083	-0,195
9	-0,028	-0,093
10	0,054	0,099
11	0,232	0,408
12	0,336	0,574
13	0,252	0,417
14	0,095	0,124
15	-0,034	-0,096
16	-0,085	-0,197
17	-0,107	-0,246
18	-0,117	-0,261
19	-0,116	-0,251
20	-0,101	-0,206
21	-0,065	-0,114
22	-0,002	0,061
23	0,117	0,329
24	0,162	0,455

Figura 11 – Auto-correlações histórica e modelada – Choró-Limão

TABELA 21 – Melhores resultados – Choró-Limão

TOPOLOGIA	SSE
2-10-10-1	8,194
2-14-14-1	8,356
2-08-08-1	8,278

Na TABELA 22 são apresentadas as principais características estatísticas das séries modelada, através da rede que apresentou o melhor resultado, e histórica.

TABELA 22 – Características estatísticas das séries modelada e histórica -
Choró-Limão

MÊS	Média (M) (m ³ /s)	Média (H) (m ³ /s)	Desvio Padrão (M)	Desvio Padrão (H)	Coef. de Variação (M)	Coef. de Variação (H)
JANEIRO	0,774	0,912	2,290	5,987	2,959	6,565
FEVEREIRO	2,696	2,628	4,345	7,507	1,612	2,857
MARÇO	19,129	17,695	19,219	31,664	1,005	1,789
ABRIL	30,484	28,801	22,732	39,951	0,746	1,387
MAIO	22,033	21,024	16,823	30,838	0,764	1,467
JUNHO	7,940	7,646	6,212	11,409	0,782	1,492
JULHO	4,407	4,087	3,680	6,245	0,835	1,528
AGOSTO	1,338	1,259	1,668	2,936	1,247	2,332
SETEMBRO	0,067	0,081	0,207	0,516	3,090	6,370
OUTUBRO	0,000	0,000	0,000	0,000	-	-
NOVEMBRO	0,000	0,000	0,000	0,001	-	-
DEZEMBRO	0,003	0,003	0,005	0,014	1,667	4,667

Acarape do Meio

FIGURA 12 - Séries Histórica e Simulada (modelo univariado) - Acarape do Meio

Gavião

FIGURA 13 - Séries Histórica e Simulada (modelo univariado) - Gavião

Sítios Novos

FIGURA 14 - Séries Histórica e Simulada (modelo univariado) - Sítios Novos

Choró-Limão

FIGURA 15 - Séries Histórica e Simulada (modelo univariado) - Choró-Limão

6.2 MODELOS MULTIVARIADOS

Conforme apresentado no item 5.3, **Modelos Aplicados na Modelagem**, a modelagem multivariada consistiu em simulações através de RNAs para as quatro séries tratadas no escopo deste estudo simultaneamente. A rede aplicada nessa modelagem tinha sua camada de entrada composta por dados provenientes das quatro séries de afluições, e a sua camada de saída composta por quatro neurônios, cada um deles representando um valor de saída modelado para cada uma das séries.

Foram trabalhadas diversas topologias diferentes para que se fossem adotadas aquelas que mais representavam as características das séries, redes com uma e duas camadas intermediárias, cujo número de neurônios variava de 2 até 50, por camada intermediária. Os componentes das camadas de entrada obedeceram a mesma sistemática já estabelecida de investigação da estrutura de correlações.

Para a modelagem multivariada, as melhores topologias, dentre as possibilidades investigadas, são mostradas na TABELA 23, enquanto os pesos e *biases* referentes a essa mesma arquitetura de rede são apresentados nas TABELAS 24, 25, 26 e 29. Nas tabelas 24 e 25, os nós de cada camada são enumerados em ordem crescente do posto 1 ao 4 e, para cada posto, da defasagem menor para a maior

As auto-correlações e correlações cruzadas das séries históricas e modeladas podem ser vistas no ANEXOS C.

TABELA 23 – Melhores resultados para a modelagem multivariada

TOPOLOGIA	SSE
12-20-4	23,411
12-24-4	25,752
8-2-2-4	29,164

TABELA 24 - Pesos W_{ij} – da informação do nó i da primeira camada a ser processada pelo nó j da segunda camada -modelo multivariado

	ACARAPE DO MEIO				GAVIÃO				S. NOVOS		C. - LIMÃO	
j/i	1	2	3	4	5	6	7	8	9	10	11	12
1	-0,2280	0,3340	-1,0221	0,4366	-0,7399	0,3956	-0,5573	0,2509	1,5196	1,4418	-1,0403	-1,0316
2	0,1907	-0,1943	0,7749	-0,2172	-0,6912	0,6312	0,1985	0,3910	-1,0832	-0,0185	-0,0674	-0,3888
3	0,7956	0,3146	-0,3852	0,1793	-0,3454	-0,5264	0,2775	0,2593	-1,6086	-1,6199	-1,1908	0,3433
4	0,3300	0,9101	-0,5563	-0,1002	-0,1217	0,0945	-0,3993	-0,3245	-0,1500	0,0034	0,5845	0,1016
5	-1,9607	-0,5662	0,3064	-0,0389	-0,5270	-0,4373	-0,2339	-0,1672	-1,0579	-0,0872	0,8197	-0,0152
6	-0,9270	-0,1522	0,4073	-0,7733	-0,9632	-0,0042	0,5367	-0,7898	-1,3974	0,4619	-0,4005	-0,5105
7	-0,9691	-0,1235	0,5693	0,5263	-0,2292	0,9618	0,8418	-0,0086	-0,1077	-0,2081	0,9722	-0,4292
8	1,6294	0,5885	-0,0171	0,8151	0,3135	-0,0766	0,8930	-0,3650	0,2731	0,5583	1,4185	-0,5512
9	-0,7881	-0,8189	-0,3219	-0,3894	-1,3062	-1,0510	-0,5162	0,6468	0,3559	0,0059	0,3942	0,7321
10	0,9342	0,8917	-0,3984	-0,4310	1,1239	-0,4310	0,8408	-0,2326	-0,4567	0,4805	0,9701	0,1978
11	-0,8142	-0,9267	0,3494	0,6754	-0,0044	-0,2287	-0,7963	-0,1066	-0,1110	-0,0061	-0,1743	-0,9869
12	-1,6467	0,6326	-0,1362	0,5490	-2,0412	-0,1641	0,6278	-0,1837	-2,3090	0,0645	-1,9128	-0,7071
13	0,6932	-0,0417	-0,9515	-0,5132	-0,0288	0,7378	0,2100	0,8736	-0,0896	0,9338	-1,1151	0,3335
14	0,0736	0,1393	-0,4548	0,7752	-0,2114	-0,5180	-0,8695	0,2940	-0,6267	-0,1920	-0,5328	0,4256
15	-0,5030	0,8617	-0,3728	0,1794	-0,8165	-0,4824	0,0924	-0,8257	-0,6902	-0,5194	-1,1590	0,7656
16	0,4664	0,2166	-1,3640	-0,0513	0,8637	-1,0084	-0,7120	0,0447	-0,1038	0,2299	-0,4319	-0,0041
17	0,5232	-0,3523	0,2293	-0,4763	0,3174	0,2825	-0,9407	-0,9305	-0,8007	-0,8957	-0,0284	-0,6017
18	0,2837	-0,0257	0,1038	-0,3866	1,0070	-0,5315	0,8625	-0,1715	-0,0809	-0,7055	0,9529	0,9343
19	1,0534	-0,3839	0,7923	-0,2910	0,7413	0,1067	0,7207	0,4538	-1,2085	-0,0609	-0,1659	-0,5460
20	-0,6024	0,3659	0,2346	0,0259	-1,2107	-0,7586	0,8747	0,5726	0,2678	0,5088	-1,3732	0,0080

TABELA 25 - - Pesos W_{jk} – da informação do nó j da segunda camada a ser processada pelo nó k da terceira camada -modelo multivariado

k / j	1	2	3	4	5	6	7	8	9	10
1	0,2803	-0,6156	1,0348	0,2649	-1,5389	-0,6191	-1,2792	1,2785	-0,6585	0,2166
2	0,2569	0,1956	0,4313	-0,7783	-0,4686	-0,3833	0,0984	0,0440	-1,2392	0,3140
3	2,1455	-0,6552	-1,8097	-0,8400	-1,1627	-1,1116	-0,4700	0,0304	0,1357	0,3087
4	-1,3288	-0,8025	-0,8451	0,8641	-0,1162	-1,2622	0,4800	1,0035	0,0319	1,1515

cont. TABELA 25 - Pesos W_{jk} – da informação do nó j da segunda camada a ser processada pelo nó k da terceira camada -modelo multivariado

k / j	11	12	13	14	15	16	17	18	19	20
1	-0,0599	-1,4174	0,2023	-0,2141	0,0458	-0,7388	-0,1651	-0,4451	1,1112	-1,0090
2	-1,1846	-1,3740	0,1891	-0,3503	-0,9075	1,1583	-0,0159	0,6881	0,0393	-0,5005
3	-0,1054	-1,7560	0,9736	-0,8806	-0,6952	0,7273	-0,5600	-0,2285	-1,0398	0,3027
4	-0,3792	-1,5284	-0,8418	-0,6520	-1,0103	-0,6882	0,1219	0,1860	-0,0383	-1,3498

TABELA 26 – Biases B_2 – relativos aos neurônios da segunda camada – modelo multivariado

j / i	1	2	3	4	5	6	7	8	9	10
	-0,3555	-0,8460	0,0977	0,1937	-0,1263	-0,2117	-0,2222	-0,2190	0,1766	-0,0225

cont. TABELA 26 – Biases B_2 – relativos aos neurônios da segunda camada – modelo multivariado

	11	12	13	14	15	16	17	18	19	20
	-0,2111	-0,2073	0,6794	0,5520	-0,4166	-0,2610	0,0145	0,1266	-0,6453	-0,4711

TABELA 27 – Biases B_3 – relativos aos neurônios da terceira camada – modelo multivariado

	1	2	3	4
	-0,1252	-0,8635	-0,3412	-1,0348

Obs: Os biases B_2 e B_3 , na realidade, correspondem a dois vetores-coluna, foram apresentados como vetores linha para melhor representação.

Após a modelagem foram geradas séries sintéticas para que se fossem comparadas algumas das suas características, tais como autocorrelação e correlação-cruzada, média e desvio padrão, com as das séries históricas.

6.2.1 ACARAPE DO MEIO

Na TABELA 28 são apresentadas as principais características estatísticas das séries modelada, através da rede que apresentou o melhor resultado, e histórica.

TABELA 28 – Características estatísticas das séries modelada e histórica – Acarape do Meio

MÊS	Média (M) (m ³ /s)	Média (H) (m ³ /s)	Desvio Padrão (M)	Desvio Padrão (H)	Coef. de Variação (M)	Coef. de Variação (H)
JANEIRO	0,345	0,384	0,619	0,970	1,794	2,526
FEVEREIRO	2,358	1,770	2,060	2,923	0,874	1,651
MARÇO	7,212	7,079	5,314	7,019	0,737	0,992
ABRIL	11,581	10,843	5,030	8,384	0,434	0,773
MAIO	9,094	9,006	4,767	7,770	0,524	0,863
JUNHO	4,305	4,233	3,215	4,444	0,747	1,050
JULHO	1,722	1,725	1,699	2,497	0,987	1,448
AGOSTO	0,647	0,615	0,138	0,211	0,213	0,343
SETEMBRO	0,580	0,537	0,123	0,174	0,212	0,324
OUTUBRO	0,475	0,442	0,107	0,178	0,225	0,403
NOVEMBRO	0,342	0,306	0,084	0,141	0,246	0,461
DEZEMBRO	0,232	0,228	0,080	0,117	0,345	0,513

6.2.2 GAVIÃO

Na TABELA 29 são apresentadas as principais características estatísticas das séries modelada, através da rede que apresentou o melhor resultado, e original.

TABELA 29 – Características estatísticas das séries modelada e histórica – Gavião

MÊS	Média (M) (m ³ /s)	Média (H) (m ³ /s)	Desvio Padrão (M)	Desvio Padrão (H)	Coef. de Variação (M)	Coef. de Variação (H)
JANEIRO	0,158	0,154	0,447	0,660	2,829	4,286
FEVEREIRO	1,249	0,838	1,280	1,746	1,025	2,084
MARÇO	3,076	2,949	2,792	3,667	0,908	1,243
ABRIL	4,980	4,618	2,657	4,139	0,534	0,896
MAIO	3,460	3,304	2,148	3,361	0,621	1,017
JUNHO	1,367	1,317	1,504	1,937	1,100	1,471
JULHO	0,544	0,544	0,679	0,984	1,248	1,809
AGOSTO	0,337	0,271	0,299	0,451	0,887	1,664
SETEMBRO	0,191	0,168	0,067	0,095	0,351	0,565
OUTUBRO	0,127	0,112	0,042	0,072	0,331	0,643
NOVEMBRO	0,076	0,065	0,026	0,044	0,342	0,677
DEZEMBRO	0,192	0,131	0,537	0,828	2,797	6,321

6.2.3 SÍTIOS NOVOS

Na TABELA 30 são apresentadas as principais características estatísticas das séries modelada, através da rede que apresentou o melhor resultado, e histórica.

TABELA 30 – Características estatísticas das séries modelada e histórica –
Sítios Novos

MÊS	Média (M) (m ³ /s)	Média (H) (m ³ /s)	Desvio Padrão (M)	Desvio Padrão (H)	Coef. de Variação (M)	Coef. de Variação (H)
JANEIRO	0,124	0,137	0,625	0,971	5,040	7,088
FEVEREIRO	1,946	1,283	2,441	3,607	1,254	2,811
MARÇO	6,830	6,911	6,497	9,626	0,951	1,393
ABRIL	12,575	12,094	6,921	10,867	0,550	0,899
MAIO	6,804	6,649	5,469	8,951	0,804	1,346
JUNHO	1,315	1,311	1,621	2,102	1,233	1,603
JULHO	0,441	0,471	0,590	0,901	1,338	1,913
AGOSTO	0,364	0,309	0,525	0,758	1,442	2,453
SETEMBRO	0,267	0,184	0,360	0,525	1,348	2,853
OUTUBRO	0,076	0,052	0,110	0,197	1,447	3,788
NOVEMBRO	0,003	0,002	0,003	0,006	1,000	3,000
DEZEMBRO	0,004	0,003	0,004	0,007	1,000	2,333

6.2.4 CHORÓ-LIMÃO

Na TABELA 31 são apresentadas as principais características estatísticas das séries modelada, através da rede que apresentou o melhor resultado, e original.

TABELA 31 – Características estatísticas das séries modelada e histórica - Choró-Limão

MÊS	Média (M) (m ³ /s)	Média (H) (m ³ /s)	Desvio Padrão (M)	Desvio Padrão (H)	Coef. de Variação (M)	Coef. de Variação (H)
JANEIRO	1,392	0,912	3,631	5,987	2,608	6,565
FEVEREIRO	4,546	2,628	4,953	7,507	1,090	2,857
MARÇO	20,099	17,695	21,310	31,664	1,060	1,789
ABRIL	33,017	28,801	23,191	39,951	0,702	1,387
MAIO	23,826	21,024	17,886	30,838	0,751	1,467
JUNHO	8,446	7,646	7,834	11,409	0,928	1,492
JULHO	4,275	4,087	3,821	6,245	0,894	1,528
AGOSTO	1,722	1,259	1,780	2,936	1,034	2,332
SETEMBRO	0,200	0,081	0,322	0,516	1,610	6,370
OUTUBRO	0,000	0,000	0,000	0,000	-	-
NOVEMBRO	0,000	0,000	0,000	0,001	-	-
DEZEMBRO	0,004	0,003	0,008	0,014	2,000	4,667

FIGURA 16 - Séries Histórica e Simulada (modelo multivariado) - Acarape do Meio

FIGURA 17 - Séries Histórica e Simulada (modelo multivariado) - Gavião

Sítios Novos

FIGURA 18 - Séries Histórica e Simulada (modelo multivariado) - Sítios Novos

Choró-Limão

FIGURA 19 - Séries Histórica e Simulada (modelo multivariado) - Choró-Limão

6.3 VERIFICAÇÃO DOS MODELOS

A etapa de verificação dos modelos das séries temporais univariadas e multivariada obtidos via RNAs compreendeu: a análise visual das séries geradas sinteticamente e históricas plotadas simultaneamente, verificação de propriedades estatísticas das séries geradas sinteticamente tais como médias, desvios padrão e estrutura de correlações.

6.3.1. ANÁLISE VISUAL DAS SÉRIES

Através da análise das séries plotadas nas Figuras 12, 13, 14, 15, 16, 17, 18 e 19 pode-se perceber claramente que os grandes picos de vazão não foram bem reproduzidos. Performance semelhante foi obtida também por MINSS & HALL (1996), quando os autores atribuíram tais resultados ao fato de haver um número pequeno de “picos altos” quando comparados com o número total de observações empregadas no estudo. A mesma situação ocorre neste trabalho. Em todas as séries existe um número muito reduzido de picos de vazão, não permitindo assim que a rede seja capaz de “aprender” e emular o seu comportamento. A rede indicava *quando* iria ocorrer uma vazão acima, ou abaixo, da média, mas o *valor quantitativo* dessa vazão não foi bem simulado todas as vezes.

6.3.2. VERIFICAÇÃO DE PROPRIEDADES ESTATÍSTICAS DAS SÉRIES GERADAS SINTETICAMENTE

Para que se procedesse à geração sintética de vazões através do modelo de RNAs, foi necessária a análise dos resíduos produzidos pelo mesmo. Essa análise, conforme explicitação do capítulo anterior,

deu origem às funções de distribuição de probabilidade bem delineadas, conforme podem ser observadas nas Figuras 20, 21, 22 e 23.

Figura 20 – Resíduos – Série afluyente ao reservatório Acarape do Meio

Figura 21 – Resíduos – Série afluyente ao reservatório Gavião

Figura 22 – Resíduos – Série afluyente ao reservatório Sítios Novos

Figura 23 – Resíduos – Série afluyente ao reservatório Choró-Limão

A cada valor modelado via RNA era somado um desvio aleatório de propriedade determinada pelas curvas de probabilidade de ocorrência de resíduos acima estabelecidas. Devido à natureza da curva de probabilidade, foram ajustadas duas equações, uma exponencial e uma logarítmica, para estimação das magnitudes dos desvios aleatórios (t) correspondentes às diversas probabilidades (p) de ocorrência na forma:

$$y = 0,381 \cdot e^{12,703t} \quad (28)$$

$$y = 0,1435 \ln(t) + 1,1963 \quad (29)$$

Onde a equação 28 foi utilizada para valores menores do que 0,440, e a equação 29 para valores maiores do que 0,440.

Os valores assim produzidos, acrescidos dos resíduos, foram então “despadronizados” gerando uma série cujas características foram comparadas às das séries históricas.

As séries geradas sinteticamente foram verificadas quanto às suas propriedades estatísticas: média, autocorrelação e correlação cruzada, as RNAs reproduziram com muita similaridade, justificando o

seu emprego. Entretanto, os valores do desvio padrão ficaram muito aquém dos valores obtidos para a série histórica.

Durante a modelagem univariada da série afluenta ao açude Choró-Limão, diversas topologias não conseguiam convergir para um ajuste de pesos satisfatório, e o erro era praticamente constante ao longo de todo este treinamento. Era atingido o número total de épocas (ciclos) e não se conseguia um ajuste capaz de reproduzir as características da série, levando a crer que, dependendo da topologia e, principalmente, dos pesos iniciais gerados, o algoritmo teria condições ou não de convergir para um ponto de erro mínimo.

Comportamento semelhante ocorreu na modelagem multivariada, porém com uma frequência muito menor.

7. CONCLUSÕES

Considerando que os recursos hídricos estão se tornando cada vez mais escassos, o gerenciamento dos mesmos deve ser capaz de lidar com as diversas questões apresentadas pelas diferenças regionais e humanas, através de uma política otimizada que saiba trabalhar as potencialidades dentro de cada contexto individual. Dentro desse paradigma, o desenvolvimento de metodologias, com graus cada vez maiores de confiabilidade, para a modelagem de séries fluviométricas, assume papel de importância crescente, pois com o aumento constante da demanda, seja para uso humano ou para atividades agropecuárias e industriais, eles se denotam o elemento-chave de qualquer estudo hidrológico.

Através da análise dos resultados obtidos nas modelagens podemos concluir que as Redes Neurais Artificiais (RNAs) têm potencial para realizar modelagens de séries fluviométricas, apresentando resultados satisfatórios, sendo também modelos bastante parcimoniosos quando comparados com os tradicionais modelos Box-Jenkins.

Tanto os neurônios da camada de entrada quanto os neurônios das camadas intermediárias (escondidas) afetam sensivelmente a habilidade de previsão das RNAs. Entretanto, o número de neurônios da camada de entrada possui efeito mais forte do que o número de neurônios das camadas intermediárias. Isto implica que os usuários devem ser bastante cautelosos na escolha do número de nós desta camada, além da determinação de quais devem ser as características a serem empregadas nesta camada.

As redes neurais artificiais foram capazes de trabalhar muito bem com as características não-lineares do sistema em estudo, o que já era de um certo modo esperado pela sua própria natureza comprovadamente versátil.

A maioria das séries univariadas analisadas, três de um total de quatro, foi melhor representada por redes com apenas uma camada escondida, que são simples de se modelar e requerem bem menos tempo computacional nos seus processos de treinamento e validação, além de exigir menos experiência do modelador. Isto representa uma grande vantagem em relação a outras modelagens, em que são necessárias diversas análises matemáticas e estatísticas prévias e ao longo da modelagem, tornando o processo bem mais demorado e complexo.

Na modelagem univariada foi necessária a aplicação de um modelo com duas camadas escondidas, no caso da série de afluências ao reservatório Choró-Limão. Credita-se tal fato à grande quantidade de vazões nulas existentes, indicando uma necessidade de maior grau de liberdade para a rede na fase de treinamento.

A modelagem multivariada foi capaz de incorporar a representatividade de cada série fluviométrica, não só para se modelar a própria série, mas também para estabelecer comportamentos comuns às quatro séries, onde cada série funcionava então como novos dados às demais séries, possibilitando uma modelagem mais refinada e robusta.

Praticamente todas as características analisadas tiveram uma melhoria quando se adotou o modelo multivariado ao invés do modelo univariado.

Entretanto, o comportamento das vazões de extremas não foi completamente bem representado em nenhuma das modelagens, seja a univariada ou a multivariada, como já mencionado no **capítulo 7, Resultados e Discussões**. Atribui-se tal fato ao pequeno número de ocorrências destes eventos nas quatro séries estudadas. Este comportamento sugere que sejam tomadas precauções extras quando ao emprego de tais séries visando estudos de cheias ou secas.

Mais pesquisas devem ser realizadas na determinação das topologias a serem adotadas nas RNAs e no desenvolvimento da melhor metodologia a ser seguida, pois embora atualmente não exista uma regra geral para a modelagem de séries temporais, de um modo geral, diversos estudos, inclusive este, vêm demonstrando a enorme capacidade de representação das RNAs em previsões destas séries.

Uma abordagem que pode gerar uma melhoria nos resultados é a inclusão de dados pluviométricos da própria bacia analisada, nos modelos univariados, e de todas as bacias analisadas, nos modelos multivariados, como informações complementares a serem fornecidas para as redes neurais através da adição de um, ou mais, neurônio(s) específico(s) desta característica na camada de entrada.

Um outro aspecto que deve ser mencionado é sobre a quantidade de elementos variáveis constituintes das RNAs. Além da determinação da topologia não possuir uma metodologia definida, existem ainda, por exemplo, a taxa de aprendizado, os diversos tipos de funções de ativação, além dos próprios diversos modelos de RNAs existentes, o que implica numa série de fatores a serem determinados pelo modelador, sem uma regra específica, indicando que todos estes parâmetros requerem análises mais detalhadas.

Mais pesquisas devem ser realizadas com as RNAs no campo de previsões com mais de um passo a frente, para que seja testada a sua aplicabilidade ou não.

Devem ser analisadas ainda as conseqüências, vantagens e desvantagens, de se trabalhar com séries não padronizadas, ou ainda com séries padronizadas e restritas a intervalos que não sejam necessariamente $[0, 1]$; como o uso do intervalo $[0,1, 0,9]$ ou ainda $[0,2, 0,8]$, para que sejam estudadas as repercussões destas mudanças no comportamento da rede, de um modo geral, e principalmente, na modelagem dos picos de vazão, tanto os picos de máximo quanto os picos de mínimo, picos estes considerados insatisfatórios na presente

modelagem e que, conseqüentemente, necessitam de mais análises e posteriores ajustes.

Modificações na escolha das funções de ativação devem ser também analisadas com o intuito de se obter uma melhor modelagem de vazões extremas.

Recomendam-se, também, mais pesquisas sobre o uso conjunto de metodologias distintas, como o uso de Algoritmo Genético, visando facilitar a escolha da topologia da rede.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALEKSANDER, I. (1966) Self-adaptive universal logic circuits. *Electronics Letters*, 2:231.
- BARTH, F.T. et al. (1987). Modelos para gerenciamento de recursos hídricos. São Paulo, Nobel/ABRH. Coleção ABRH de Recursos Hídricos; 1.
- BALLINI, R. et al (1997) Modelos de Redes Neurais & Box-Jenkins para previsão de vazões médias mensais, XII Simpósio Brasileiro de Recursos Hídricos, Vitória, Artigo Científico.
- BLEDSON, W. & BROWING, I. (1959) Pattern recognition and reading by machine. In *Proceedings Eastern Joint Computer Conference*, pages 225-232, Boston.
- BOX, G. E. P., JENKINS, G. M. (1976) *Time Series Analysis - forecasting and control*. Holden-Day Inc., California
- BRAGA, A. P., LUDEMIR, T. B., CARVALHO, A. C. P. L. F., (2000) *Redes Neurais Artificiais, Teoria e aplicações*. Livros Técnicos e Científicos Editora S.A., Rio de Janeiro.
- CAMACHO, F., McLEOD, A. I., HIPEL, K. W. (1985). Developments in multivariate ARMA modeling in hydrology, *Int. Symp. On Multivariate Analysis of Hydrologic Processes*, Colorado State University, Fort Collins, CO, USA.
- CAMPOS, J. N. B., SOUZA FILHO, F.A., ARAÚJO, J. C. (1997) Incertezas na Regularização de Vazões, XII Simpósio Brasileiro de Recursos Hídricos, Vitória, Artigo Científico.
- CEARÁ. Secretaria dos Recursos Hídricos. Companhia de Gestão dos Recursos Hídricos (1998). *Plano de Gerenciamento das Águas das Bacias Metropolitanas*. Fortaleza.
- CHAKRABORTY, K., MEHROTRA, K., MOHAN, C. K. & RANKA, S. (1992) Forecasting the Behavior of Multivariate time series using Neural Networks, in *Neural Networks*, vol. 5, pp 961-970

DAWSON, C., W. & WILBY, R. (1998) An artificial neural network approach to rainfall-runoff modelling, *Journal of Hydrological Sciences*, vol. 43, nº 1 p. 47-66.

DINIZ, L., S. (1997) Avaliação da demanda hídrica para pecuária usando redes neurais, XII Simpósio Brasileiro de Recursos Hídricos, Vitória, Artigo Científico.

FAHLMAN, S., E. & LEBIERE, C. (1991) The cascade-correlation learning architecture. Carnegie Mellon University Technical Report CMU-CS-90-100.

GALVÃO, C. O., (1999) Apresentação, in *Sistemas Inteligentes - Aplicações a Recursos Hídricos e Ciências Ambientais*. Porto Alegre: Ed. Universidade/ UFRGS/ABRH. Coleção ABRH de Recursos Hídricos, 7.

GUYTON, A. C., (1988) *Fisiologia Humana*, Rio de Janeiro: Editora Guanabara.

HAUGH, L., D. & BOX, G., E., P. (1977) Identification of dynamic regression (distributed lag) models connecting two time series, *Journal of the American Statistical Association*, 72, (397), p.121-30

HAYKIN, S., (1994) *Neural Networks – A Comprehensive Foundation*. Prentice Hall

HIPEL, K. W. & McLEOD, A. I. *Time Series Modelling of Water Resources and Environmental Systems*, a ser publicado pela Elsevier, Amsterdam, The Netherlands, 1993. (ap ud LECHTERMATTER. & FULLER 1993)

IMRIE, C. E., DURUCAN, S. KORRE, A. (2000) River flow prediction using neural networks: generalization beyond the calibration range, *Journal of Hydrology*, vol 233, pp 138-153

JAIN, S., K., DAS, A. & SRIVASTAVA, D., K. (1999) Application of ANN for reservoir inflow prediction and operation, *Journal os Water Resources Planning and Management*, vol.125, nº 5, september/october.

KARUNANITHI, N., GRENNEY, W., J., WHITLEY, D. & BOVEE, K. (1994) Neural Networks for River Flow Prediction, *Journal of Computing in Civil Engineering*, vol. 8, nº 2, p.201-220.

LECHTERMATER, G. (1992) Sistemas de Previsão de Séries Temporais Utilizando Redes Neurais, *Redes Neurais*, vol. 12, no2, Dezembro

LECHTERMATTER, G. & FULLER, J. D. (1993) Backpropagation in Hydrological Time Series Forecasting, Waterloo, Canadá, Faculty of Engineering, University of Waterloo. Trabalho apresentado na Conferência Internacional "Stochast and Statistical Methods in Hydrology and Environmental Engineering". Realizado em Waterloo, junho de 1993

LUND, J. R. & ISRAEL, M. (1995). Optimization of transfers in urban water supply planning. *Journal of Water Resources Planning and Management*, v.121, n.1, p.41-48, Jan/Feb.

MACEDO, H. P. (1996). A chuva e o chão na terra do sol. São Paulo: Maltese.

MAIER, H. R., & DANDY, G. C. (1997) Determining inputs for neural networks models of multivariate time series. *Microcomputers in Civil Engineering*, 12, p.353 - 368

MASON, J., C., TEM'ME, A. & PRICE, R., K. (1996) A neural network model of rainfall-runoff using radial basis functions, *Journal of Hydraulic Research*, vol. 34, nº 4, p. 537-548.

McLELLAND, J. L. & RUMELHART, D. E. (1988) *Explorations in Parallel Distributed Processing*, MIT Press, Cambridge, Massachusetts.

McCULLOCH, W. S. & PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:113-133, 1943.

MINNS, A., W. & HALL, M., J. (1996) Artificial neural networks as rainfall-runoff models, *Journal of Hydrological Sciences*, vol. 41, nº 3, p. 399-417.

NEWTON, H. J. (1988) TIMESLAB: A Time Series Analysis Laboratory, Wadsworth & Brooks/Cole Publishing Company, California.

PEREIRA, B. B. (1984). Séries temporais multivariadas. Instituto de Matemática. UFRJ, Rio de Janeiro.

RAMAN, H. & SUNIKULMAR, N. (1995) Multivariate modelling of water resources time series using artificial neural networks, Journal of Hydrological Sciences vol. 40, nº 2, p 145-163.

RIGHETTO, A. M. (1998). Hidrologia e recursos hídricos. São Carlos, EESC-USP.

RUMELHART, D. E. & McCLELLAND, J. (1986) Parallel Distributed Processing: Explorationing the Microestruture of Cognition, 1, 2, 3. Cambridge: Bradford Book - MIT Press.

SAJIKUMAR, N. & THANDAVESWARA, B., S. (1999) A non-linear rainfall-runoff model using an artificial neural network, Journal of Hydrology, vol. 216, p. 32-55

SALAS, J. D. & PEGRAM, G. G. S. (1977). A seasonal mulivariate multilag autoregressive model in hydrology, Proc. Third Int. Symp. on Theoretical and Apllied Hydrology, Colorado State University, Fort Collins, CO, USA.

SALAS, J. D., DELLEUR, J. W., YEVJEVICH, V. & LANE, W. L., (1980) Applied modeling of hydrologic time series, Water Resources Publications, Littleton, Colorado, USA.

SARMENTO, F. J. (1996) Modelagem de Séries Hidrológicas Através de Redes de Neurônios Revista Brasileira de Recursos Hídricos, vol. 1, no 2, julho/dezembro de 1996

SHARDA, R. & PATIL, R. (1990) Neural Networks as Forecasting Experts: Na Empirical Test, in International Joint Conference on Neural Networks. Vol. 1, pp. 491-494. Washington, DC. IEEE.

SIVAKUMAR, B. (2000) Chaos theory in hydrology: important issues and interpretations, *Journal of Hydrology*, vol. 227, (1-4), p. 1-20.

SIVAKUMAR, B., JAYAWARDENA, A., W. & FERNANDO, T., M., K., G. (2002) River flow forecasting: use of phase-space reconstruction and artificial neural networks approaches, *Journal of Hydrology*, vol. 265, p. 225-245.

SMITH, J. & ELI, R., N. (1995) Neural-Network models of rainfall-runoff process, *Journal of Water Resources Planning and Management*, vol. 121, nº 6, November/December, p.499-508.

SOUZA, M. S., MACHADO, D., MARTINO, M. B., (1995) Determinação de Vazões Utilizando Redes Neurais, XI Simpósio Brasileiro de Recursos Hídricos, Artigo Científico.

SOUZA FILHO, F. A. (1998). Estudo preliminar da operação conjunta do sistema Jaguaribe e sistema metropolitano. Fortaleza. /Relatório técnico COGERH-SRH-CE/

SOUZA FILHO, F. A. (1999). Análise preliminar do impacto de novas áreas irrigadas na garantia do abastecimento do sistema Jaguaribe-Metropolitano. Fortaleza. /Relatório técnico COGERH-SRH-CE/

TANG, Z.; ALMEIDA, C. & FISHWICK, P.A. (1991) Time Series Forecasting Using Neural Networks vs. Box-Jenkins Methodology , in *Simulations*, pp. 303-310. Simulations Councils, Inc., November.

TIAO, G. C. & TSAY, R. S. (1989) Model specification in multivariate time series. *Journal of the Royal Statistical Society*, B 51, 157-213.

TUCCI, C. E. M., Modelos Hidrológicos - Ed Universidade/UFRGS/ABRH, Porto Alegre

UNIVERSIDADE DE SÃO PAULO. Escola de Engenharia de São Carlos. Serviço de Biblioteca (1996). Diretrizes para elaboração de dissertações e teses na EESC-USP. 2.ed. São Carlos.

- VALENÇA, M. J. S. & LUDERMIR, T. B. (1999) Introdução às Redes Neurais, in *Sistemas Inteligentes - Aplicações a Recursos Hídricos e Ciências Ambientais*. Porto Alegre: Ed. Universidade/ /UFRGS/ABRH. Coleção ABRH de Recursos Hídricos, 7
- VALENÇA, M. J. S., (1999) Aplicação de Redes Neurais, in *Sistemas Inteligentes - Aplicações a Recursos Hídricos e Ciências Ambientais*. Porto Alegre: Ed. Universidade/ /UFRGS/ABRH. Coleção ABRH de Recursos Hídricos, 7
- VALENÇA, M. J. S., (1997) Aplicação de Redes Neurais na Área de Recursos Hídricos, XII Simpósio Brasileiro de Recursos Hídricos, Vitória, Artigo Científico.
- VIANA, F. L.; GONDIM FILHO, J. G. (1999). Utilização de previsões climatológicas no gerenciamento dos recursos hídricos do Ceará. O caso do abastecimento de água da região metropolitana de Fortaleza. Fortaleza. /Relatório técnico COGERH-SRH-CE/.
- YEVJEVICH, V (1972). *Stochastic Processes in Hydrology*. Fort Collins – Colorado: Water Resources Publications.
- VIEIRA, A. M., PEREIRA, B. B., SALES, P. R. H. (1998). Estimação conjunta dos parâmetros de um modelo estocástico multivariado contemporâneo periódico auto-regressivo -PAR(P). *Revista Brasileira de Recursos Hídricos*. Vol. 3, no 4, pág. 5-17, Out./Dez.
- WASSERMAN, P. D. (1989) *Neural Computing: theory and practice*, Van Nostrand Reinhold, New York.
- WEIGEND, A. S., RUMELHART, D. E., HUBERMAN, B. A. (1990), Predicting the Future: a Connectionist Approach, in *International Journal of Neural Systems*, vol.1, no 3, pp193-209, World Scientific Publishing Company

- WEIGEND, A. S., RUMELHART, D. E., HUBERMAN, B. A. (1991), Back-propagation, Weight- Elimination and Tiem Series Prediction, in Connectionist Models - Proceedings of the 1990 Summer School, Edited by D. S. Touretzky, J. L. Elman, T. J. Sejnowsky, G. E. Hinton, Morgan Kaufmann Publishers, Inc.
 - ZANDONADE, E. & SOUZA, R.,C., (1993) Forecasting Via Neural Networks: A Comparative Study, Pesquisa Operacional - SOBRAPO, vol. 14, no. 2, pp. 15-27.
- ZEALAND, C., M., BURN, D., H. & SIMONOVIC, S., P. (1999) Short term streamflow forecasting using artificial neural networks, Journal of Hydrology, vol. 214, p.32-48.
- ZELL, A. (1995) SNNS: User Manual. University of Stuttgart, Stuttgart (disponível para *download*, juntamente com o pacote computacional, no endereço eletrônico <ftp.informatik.uni-stuttgart.de>)

ANEXO A - Série de afluições ao açude Acarape do Meio

Ano	Deflúvios (m³/s)												Média Anual
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	
1912	0,002	6,174	8,550	16,940	13,459	2,682	0,703	0,687	0,626	0,482	0,304	0,201	4,234
1913	0,138	4,281	13,760	14,442	7,197	6,061	0,712	0,702	0,667	0,671	0,620	0,556	4,151
1914	0,543	2,618	11,357	16,016	11,241	11,816	1,201	1,511	0,683	0,659	0,461	0,319	4,869
1915	0,224	0,178	0,191	0,175	0,182	0,179	0,186	0,174	0,118	0,081	0,044	0,025	0,146
1916	0,016	0,016	12,412	7,567	8,736	9,663	0,710	0,695	0,575	0,396	0,270	0,224	3,440
1917	3,819	11,763	26,247	16,968	30,434	5,112	0,707	0,692	0,624	0,483	0,319	0,271	8,120
1918	0,245	0,515	8,315	8,942	13,818	6,079	0,708	0,696	0,660	0,616	0,409	0,286	3,441
1919	0,232	0,200	0,212	0,187	0,185	0,174	0,150	0,121	0,090	0,060	0,033	0,017	0,138
1920	0,007	0,001	7,529	6,849	4,869	8,062	2,108	0,710	0,673	0,622	0,446	0,366	2,687
1921	0,350	7,310	29,462	21,002	25,354	2,317	8,310	0,708	0,668	0,617	0,445	0,384	8,077
1922	0,307	0,263	1,220	10,305	18,842	5,499	5,001	0,711	0,675	0,632	0,423	0,322	3,683
1923	0,262	0,231	5,777	9,583	5,836	5,478	2,737	0,704	0,655	0,527	0,344	0,248	2,698
1924	0,167	3,312	21,410	33,823	26,185	12,199	1,304	0,701	0,657	0,540	0,433	0,326	8,421
1925	0,287	2,358	8,719	13,505	3,812	0,685	0,696	0,677	0,552	0,483	0,327	0,243	2,695
1926	0,189	1,912	17,715	14,854	6,564	0,691	0,705	0,689	0,566	0,400	0,252	0,176	3,726
1927	0,116	0,093	1,501	13,034	9,684	3,877	0,707	0,700	0,660	0,531	0,354	0,250	2,626
1928	0,182	0,145	0,135	7,177	3,991	0,513	0,524	0,513	0,417	0,310	0,215	0,148	1,189
1929	0,105	2,502	15,778	16,088	9,018	0,990	1,527	0,702	0,662	0,572	0,403	0,322	4,056
1930	0,240	0,196	0,215	3,274	1,279	4,031	0,519	0,513	0,470	0,374	0,258	0,188	0,963
1931	0,162	1,908	5,710	5,185	0,963	0,662	0,676	0,662	0,576	0,405	0,256	0,172	1,445
1932	0,122	0,109	2,899	0,240	0,244	0,240	0,251	0,250	0,202	0,153	0,091	0,055	0,405
1933	0,034	0,031	0,676	14,175	1,001	0,581	0,593	0,580	0,471	0,331	0,208	0,140	1,568
1934	0,118	3,015	19,840	14,288	17,223	3,572	0,706	0,686	0,543	0,370	0,250	0,201	5,068
1935	0,195	7,080	9,505	26,523	16,007	4,955	1,021	0,700	0,643	0,501	0,329	0,222	5,640
1936	0,154	0,122	0,453	0,156	4,657	2,041	0,437	0,434	0,402	0,300	0,190	0,126	0,789
1937	0,079	0,051	1,062	9,740	7,632	8,674	1,064	0,705	0,666	0,647	0,451	0,338	2,592
1938	0,259	0,227	7,111	17,644	9,759	5,607	0,705	0,690	0,637	0,494	0,325	0,243	3,642
1939	0,206	8,175	16,458	7,256	5,582	3,634	0,705	0,691	0,654	0,657	0,614	0,507	3,762
1940	0,401	0,368	6,526	24,019	16,735	9,416	2,889	0,702	0,664	0,638	0,428	0,302	5,258
1941	0,206	0,138	0,151	7,499	2,261	0,518	0,529	0,518	0,424	0,301	0,211	0,166	1,077

1942	0,128	0,096	1,957	4,021	1,574	1,158	0,480	0,472	0,392	0,275	0,183	0,128	0,905
1943	0,089	0,072	0,081	6,886	2,741	0,441	0,453	0,448	0,395	0,278	0,179	0,127	1,016
1944	0,113	0,104	0,110	7,228	9,691	1,443	0,706	0,694	0,640	0,489	0,339	0,239	1,816
1945	0,214	9,873	12,269	21,350	17,716	14,945	3,321	0,698	0,649	0,564	0,402	0,352	6,863
1946	5,451	5,917	17,662	14,224	4,181	3,092	0,707	0,692	0,597	0,420	0,261	0,178	4,449
1947	0,150	0,106	0,112	0,500	2,605	0,240	0,252	0,249	0,184	0,118	0,070	0,061	0,387
1948	0,042	0,029	0,027	0,036	1,463	1,138	0,190	0,191	0,143	0,090	0,049	0,026	0,285
1949	0,010	0,003	12,192	18,737	35,170	7,752	0,710	0,695	0,571	0,388	0,239	0,157	6,385
1950	0,097	0,070	8,104	9,327	12,098	0,686	0,695	0,668	0,482	0,324	0,200	0,140	2,741
1951	0,090	0,053	0,043	0,041	0,056	0,724	0,102	0,107	0,083	0,049	0,028	0,013	0,116
1952	0,011	0,011	11,045	14,988	3,509	0,453	0,459	0,384	0,247	0,161	0,095	0,057	2,618
1953	0,033	0,019	0,859	5,798	3,204	0,408	0,420	0,414	0,345	0,238	0,146	0,095	0,998
1954	0,061	0,039	4,323	3,298	6,471	0,648	0,480	0,473	0,409	0,279	0,172	0,119	1,398
1955	0,079	0,067	0,080	7,698	4,774	0,520	0,532	0,521	0,408	0,295	0,201	0,155	1,277
1956	0,145	0,117	1,310	6,630	0,838	0,422	0,434	0,426	0,363	0,253	0,157	0,103	0,933
1957	0,072	0,064	5,224	13,802	5,994	0,689	0,700	0,682	0,525	0,367	0,232	0,159	2,376
1958	0,122	0,080	0,066	0,057	0,062	0,064	0,069	0,059	0,033	0,015	0,002	0,000	0,052
1959	0,000	3,447	12,961	5,785	12,904	1,275	0,705	0,689	0,585	0,399	0,248	0,169	3,264
1960	0,111	0,070	10,000	7,051	0,822	0,462	0,475	0,467	0,395	0,272	0,169	0,109	1,700
1961	0,083	8,963	8,471	19,830	9,126	0,688	0,702	0,689	0,627	0,459	0,310	0,242	4,183
1962	0,191	0,153	11,088	12,168	5,986	0,829	0,706	0,691	0,626	0,464	0,314	0,273	2,791
1963	0,230	1,352	12,684	9,503	5,456	0,682	0,693	0,668	0,483	0,324	0,205	0,186	2,705
1964	3,368	11,778	20,065	31,703	21,734	2,568	2,478	0,706	0,671	0,674	0,499	0,342	8,049
1965	0,250	0,190	0,187	12,992	11,346	13,416	3,182	0,702	0,637	0,483	0,311	0,213	3,659
1966	0,149	0,103	0,116	2,956	2,973	2,767	0,480	0,477	0,452	0,376	0,244	0,173	0,939
1967	0,124	2,055	9,255	12,975	17,020	4,191	0,740	0,702	0,661	0,524	0,328	0,220	4,066
1968	0,171	0,143	2,659	6,542	10,128	2,082	0,705	0,697	0,648	0,490	0,325	0,232	2,069
1969	0,187	0,151	5,304	13,126	10,425	8,085	10,522	0,709	0,672	0,596	0,396	0,284	4,205
1970	0,221	0,189	3,359	9,145	3,473	1,173	0,712	0,699	0,658	0,519	0,353	0,270	1,731
1971	0,210	0,176	5,999	6,161	13,312	7,976	6,296	1,253	0,676	0,656	0,497	0,382	3,633
1972	0,298	0,251	0,262	1,181	5,439	2,275	3,152	0,705	0,669	0,626	0,455	0,328	1,303
1973	0,298	4,064	6,939	18,073	13,035	11,708	3,410	0,707	0,670	0,667	0,508	0,388	5,039
1974	5,701	7,423	24,316	42,010	25,490	8,980	0,758	0,702	0,663	0,622	0,420	0,314	9,783
1975	0,291	0,259	9,811	7,800	13,572	7,707	2,152	0,708	0,673	0,670	0,494	0,421	3,713
1976	0,412	0,378	9,666	17,442	0,711	0,680	0,693	0,677	0,607	0,459	0,335	0,261	2,693
1977	0,193	2,686	9,618	15,348	13,890	13,208	8,921	0,710	0,674	0,615	0,413	0,298	5,548

1978	0,220	0,156	2,921	6,337	11,654	1,981	2,481	0,711	0,675	0,663	0,517	0,401	2,393
1979	0,295	0,247	2,711	3,852	7,057	3,351	0,705	0,689	0,649	0,534	0,346	0,239	1,723
1980	0,169	7,352	7,850	1,619	0,702	1,640	0,706	0,691	0,613	0,464	0,328	0,232	1,864
1981	0,185	0,151	4,023	3,262	3,487	0,759	0,542	0,530	0,404	0,270	0,169	0,115	1,158
1982	0,099	0,085	3,628	3,907	4,171	1,511	0,655	0,645	0,607	0,486	0,327	0,233	1,363
1983	0,160	0,118	0,576	3,320	1,059	0,332	0,345	0,340	0,265	0,183	0,114	0,073	0,574
1984	0,051	0,039	3,209	6,564	15,499	9,578	3,672	0,708	0,672	0,674	0,536	0,404	3,467
1985	0,321	5,831	24,061	22,181	18,902	12,135	9,765	0,709	0,674	0,655	0,469	0,343	8,004
1986	0,318	2,710	11,980	27,179	16,150	11,360	2,823	0,707	0,672	0,668	0,530	0,457	6,296
1987	0,370	0,294	4,679	5,814	2,154	14,641	0,869	0,700	0,653	0,517	0,340	0,243	2,606
1988	0,181	0,167	1,548	17,144	15,751	5,164	3,427	0,707	0,670	0,634	0,481	0,407	3,857
1989	0,384	0,338	0,365	11,146	17,257	13,892	13,682	0,710	0,674	0,632	0,449	0,354	4,990
1990	0,330	0,280	0,284	0,272	2,217	0,955	0,409	0,408	0,388	0,350	0,234	0,159	0,524
1991	0,123	0,108	6,452	4,707	9,589	4,518	0,705	0,690	0,609	0,443	0,307	0,207	2,372
1992	0,134	5,112	2,897	7,214	1,264	1,804	0,710	0,695	0,584	0,403	0,278	0,191	1,774
1993	0,129	0,086	0,088	0,088	0,098	0,101	0,110	0,115	0,103	0,069	0,041	0,023	0,088
1994	0,015	0,016	8,747	11,888	21,488	16,841	4,582	0,707	0,668	0,548	0,345	0,240	5,507
1995	0,208	0,897	3,373	18,471	18,783	6,025	2,732	0,707	0,666	0,525	0,350	0,244	4,415
1996	0,183	0,657	13,222	22,826	6,478	1,634	0,702	0,688	0,622	0,482	0,347	0,262	4,009
Média	0,384	1,770	7,079	10,843	9,006	4,233	1,725	0,615	0,537	0,442	0,306	0,228	3,097
D.P.	0,970	2,923	7,019	8,384	7,770	4,444	2,497	0,211	0,174	0,178	0,141	0,117	2,225
C.V.	2,527	1,651	0,991	0,773	0,863	1,050	1,448	0,343	0,324	0,403	0,462	0,515	0,718
Mínimo	0,000	0,001	0,027	0,036	0,056	0,064	0,069	0,059	0,033	0,015	0,002	0,000	0,052
Máximo	5,701	11,778	29,462	42,010	35,170	16,841	13,682	1,511	0,683	0,674	0,620	0,556	9,783
Quantis (90)	0,362	6,718	17,180	21,211	18,818	11,772	3,574	0,709	0,673	0,657	0,489	0,383	6,034
Quantis (75)	0,250	2,502	11,045	15,348	13,572	6,079	2,108	0,702	0,664	0,615	0,413	0,314	4,183
Quantis (50)	0,181	0,196	5,710	9,145	6,564	2,275	0,706	0,691	0,624	0,482	0,325	0,232	2,695
Quantis (25)	0,111	0,096	0,859	5,185	2,741	0,686	0,529	0,518	0,424	0,324	0,208	0,155	1,303
Quantis (10)	0,037	0,039	0,124	0,363	0,828	0,430	0,370	0,357	0,254	0,170	0,102	0,066	0,544

ANEXO A - Série de afluições ao açude Gavião

Ano	Deflúvios (m³/s)												Média Anual
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	
1912	0,000	5,477	17,444	1,331	7,980	2,326	0,339	0,320	0,285	0,202	0,113	0,070	2,990
1913	0,043	2,836	8,004	6,939	4,121	1,269	0,326	0,320	0,281	0,212	0,135	0,092	2,048
1914	0,063	1,738	2,694	5,590	4,590	3,503	0,326	0,321	0,303	0,232	0,135	0,084	1,632
1915	0,048	0,033	0,033	0,026	0,027	0,023	0,014	0,005	0,000	0,000	0,000	0,000	0,017
1916	0,000	0,002	1,492	3,886	3,001	0,357	0,297	0,280	0,181	0,111	0,064	0,045	0,810
1917	4,276	11,222	14,693	10,151	10,958	1,074	0,324	0,304	0,201	0,124	0,070	0,049	4,454
1918	0,037	0,973	1,947	3,227	6,522	0,996	0,322	0,314	0,259	0,164	0,092	0,054	1,242
1919	0,040	0,027	0,023	0,020	0,017	0,010	0,006	0,001	0,000	0,000	0,000	0,000	0,012
1920	0,000	0,000	3,498	5,180	3,214	2,159	0,324	0,317	0,264	0,176	0,105	0,073	1,276
1921	0,071	1,565	7,693	9,330	9,919	2,540	0,322	0,316	0,262	0,218	0,146	0,144	2,711
1922	0,112	0,081	0,078	3,746	5,952	3,330	1,485	0,326	0,306	0,222	0,125	0,089	1,321
1923	0,062	0,048	2,164	2,136	1,191	0,240	0,246	0,236	0,158	0,099	0,053	0,030	0,555
1924	0,015	2,246	7,598	8,483	13,394	3,220	0,325	0,312	0,210	0,134	0,096	0,062	3,008
1925	0,050	0,045	0,883	6,486	5,043	0,314	0,318	0,282	0,186	0,150	0,093	0,060	1,159
1926	0,037	0,028	2,499	6,771	3,056	0,314	0,317	0,247	0,145	0,087	0,048	0,027	1,131
1927	0,014	0,008	0,446	7,233	3,585	0,313	0,319	0,311	0,223	0,135	0,076	0,051	1,059
1928	0,038	0,028	0,028	3,680	1,602	0,197	0,201	0,177	0,108	0,069	0,037	0,020	0,515
1929	0,009	1,426	4,562	7,172	0,634	0,316	0,320	0,291	0,183	0,116	0,063	0,038	1,261
1930	0,021	0,016	0,014	1,602	0,074	0,075	0,079	0,072	0,041	0,022	0,009	0,002	0,169
1931	0,001	0,996	2,504	1,504	0,260	0,198	0,201	0,154	0,094	0,056	0,028	0,014	0,501
1932	0,006	0,003	1,066	0,049	0,054	0,054	0,057	0,046	0,027	0,014	0,004	0,000	0,115
1933	0,000	0,002	0,005	8,226	0,857	0,289	0,291	0,216	0,128	0,076	0,040	0,021	0,846
1934	0,017	0,324	6,705	4,789	7,506	0,605	0,323	0,293	0,183	0,110	0,064	0,042	1,747
1935	0,034	0,253	2,149	5,598	6,172	1,984	0,326	0,318	0,231	0,144	0,080	0,048	1,445
1936	0,028	0,016	0,018	0,020	0,022	0,025	0,029	0,023	0,010	0,002	0,000	0,000	0,016
1937	0,000	0,000	0,730	5,112	3,595	3,076	0,324	0,316	0,237	0,158	0,089	0,056	1,141
1938	0,037	0,032	5,537	10,042	1,191	1,605	0,323	0,296	0,188	0,116	0,069	0,043	1,623
1939	0,026	5,117	2,697	4,662	3,903	0,479	0,323	0,311	0,235	0,165	0,119	0,076	1,509
1940	0,049	0,038	0,352	5,486	3,263	1,645	0,323	0,312	0,222	0,142	0,078	0,048	0,997
1941	0,029	0,016	0,019	0,459	0,147	0,058	0,059	0,038	0,021	0,009	0,002	0,000	0,071

1942	0,000	0,000	0,091	1,739	0,144	0,084	0,088	0,073	0,041	0,023	0,010	0,004	0,191
1943	0,000	0,001	0,001	3,085	0,125	0,110	0,114	0,100	0,061	0,035	0,017	0,008	0,305
1944	0,004	0,002	0,001	2,112	1,498	0,290	0,155	0,139	0,083	0,049	0,025	0,012	0,364
1945	0,008	4,477	1,980	8,778	6,539	0,373	1,123	0,321	0,251	0,160	0,094	0,064	2,014
1946	0,049	0,276	2,621	4,105	0,430	0,447	0,300	0,265	0,162	0,098	0,053	0,030	0,736
1947	0,020	0,012	2,637	2,538	3,073	0,304	0,310	0,302	0,214	0,134	0,074	0,056	0,806
1948	0,043	0,032	0,031	0,436	1,533	0,644	0,142	0,141	0,107	0,065	0,034	0,017	0,269
1949	0,007	0,003	3,711	5,085	10,416	0,854	0,326	4,264	0,314	0,280	0,170	0,116	2,129
1950	0,071	0,049	2,710	7,659	6,106	0,315	0,318	0,264	0,156	0,093	0,051	0,031	1,485
1951	0,017	0,008	0,004	0,176	0,020	0,025	0,031	0,032	0,018	0,007	0,001	0,000	0,028
1952	0,000	0,001	0,561	5,733	1,373	0,267	0,271	0,227	0,136	0,081	0,043	0,023	0,726
1953	0,011	0,004	0,200	1,384	0,615	0,259	0,115	0,105	0,063	0,036	0,016	0,006	0,235
1954	0,000	0,000	0,311	0,674	0,724	0,089	0,093	0,078	0,044	0,023	0,009	7,668	0,810
1955	0,097	0,089	0,516	2,825	1,947	0,284	0,287	0,231	0,136	0,081	0,044	0,028	0,547
1956	0,021	0,015	0,017	3,025	0,130	0,127	0,129	0,093	0,054	0,031	0,014	0,004	0,305
1957	0,000	0,000	3,092	5,321	0,702	0,296	0,299	0,231	0,136	0,081	0,043	0,023	0,852
1958	0,012	0,004	0,002	0,001	0,001	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,002
1959	0,000	0,002	2,676	1,531	2,229	0,232	0,236	0,196	0,117	0,069	0,036	0,019	0,612
1960	0,007	0,001	2,621	1,823	0,168	0,162	0,164	0,122	0,070	0,039	0,019	0,008	0,434
1961	0,002	2,832	3,253	8,327	2,560	0,315	0,319	0,280	0,170	0,104	0,056	0,035	1,521
1962	0,023	0,019	5,817	5,713	2,200	1,179	0,323	0,310	0,214	0,132	0,076	0,053	1,338
1963	0,163	2,907	13,496	9,255	5,891	0,315	0,320	0,305	0,203	0,125	0,070	0,061	2,759
1964	2,979	4,105	11,132	15,365	7,563	1,241	0,990	0,322	0,292	0,220	0,128	0,079	3,701
1965	0,052	0,039	0,036	5,939	2,494	7,276	0,469	0,322	0,257	0,170	0,096	0,057	1,434
1966	0,032	0,019	0,016	0,015	0,240	1,705	0,094	0,095	0,070	0,044	0,022	0,011	0,197
1967	0,003	1,940	8,202	6,553	6,439	2,160	0,325	0,318	0,242	0,157	0,087	0,051	2,206
1968	0,034	0,028	0,141	2,789	4,601	0,289	0,294	0,274	0,174	0,106	0,058	0,034	0,735
1969	0,028	0,016	0,016	4,383	2,315	0,389	1,333	0,298	0,271	0,191	0,111	0,067	0,785
1970	0,040	0,033	0,378	3,436	0,189	0,178	0,181	0,150	0,094	0,055	0,031	0,018	0,398
1971	0,010	0,010	3,478	2,684	6,761	5,849	4,206	0,325	0,302	0,233	0,152	0,101	2,009
1972	0,064	0,043	0,045	0,955	2,816	1,097	0,211	0,209	0,193	0,131	0,073	0,043	0,490
1973	0,033	1,777	8,850	11,794	10,434	5,006	3,909	0,326	0,309	0,243	0,143	0,088	3,576
1974	3,356	2,770	11,866	24,463	13,827	5,431	0,325	0,318	0,256	0,185	0,110	0,082	5,249
1975	0,075	1,332	5,731	8,096	4,449	3,785	3,759	0,323	0,292	0,197	0,110	0,083	2,353
1976	0,065	1,935	3,488	7,050	0,325	0,310	0,312	0,244	0,146	0,099	0,074	0,045	1,174
1977	0,028	1,256	3,322	4,776	6,632	6,609	5,358	0,325	0,291	0,207	0,122	0,072	2,417

1978	0,044	0,028	0,034	1,932	1,805	0,171	0,177	0,178	0,163	0,108	0,065	0,038	0,395
1979	0,020	0,014	0,591	0,042	3,137	0,150	0,155	0,138	0,105	0,073	0,041	0,023	0,374
1980	0,013	1,439	2,119	0,112	0,116	0,111	0,112	0,077	0,045	0,025	0,011	0,003	0,348
1981	0,001	0,004	4,351	0,902	0,177	0,170	0,160	0,106	0,063	0,035	0,016	0,006	0,499
1982	0,005	0,004	1,152	1,590	1,094	0,164	0,168	0,139	0,081	0,048	0,026	0,012	0,374
1983	0,003	0,001	0,843	0,041	0,047	0,048	0,044	0,026	0,011	0,003	0,000	0,000	0,089
1984	0,000	0,001	0,002	2,752	4,028	2,964	0,325	0,319	0,294	0,222	0,128	0,083	0,926
1985	0,061	5,174	7,342	13,158	8,093	1,498	3,738	0,324	0,290	0,190	0,105	0,067	3,337
1986	0,065	2,238	6,903	10,488	1,964	4,190	0,677	0,320	0,237	0,145	0,081	0,060	2,281
1987	0,054	0,034	6,265	0,886	0,237	1,655	0,276	0,270	0,203	0,127	0,073	0,043	0,844
1988	0,023	0,020	3,545	6,171	4,814	0,313	0,319	0,307	0,218	0,137	0,077	0,046	1,332
1989	0,040	0,036	0,133	5,605	1,931	4,526	2,207	0,323	0,305	0,246	0,146	0,098	1,300
1990	0,086	0,054	0,052	0,050	0,792	0,083	0,088	0,089	0,068	0,041	0,021	0,011	0,119
1991	0,004	0,003	4,576	2,311	2,184	0,300	0,304	0,274	0,175	0,110	0,066	0,036	0,862
1992	0,018	0,074	2,511	1,785	0,166	0,235	0,171	0,158	0,102	0,069	0,038	0,020	0,445
1993	0,008	0,002	0,002	0,071	0,087	0,030	0,033	0,032	0,019	0,008	0,001	0,000	0,024
1994	0,000	0,000	2,443	6,607	6,769	10,522	0,561	0,321	0,275	0,184	0,105	0,061	2,321
1995	0,049	0,050	1,704	11,179	8,694	3,330	0,404	0,322	0,279	0,181	0,103	0,059	2,196
1996	0,037	1,433	5,442	8,300	5,369	0,565	0,320	0,304	0,207	0,130	0,074	0,045	1,852
Média	0,154	0,838	2,949	4,618	3,304	1,317	0,544	0,271	0,168	0,112	0,065	0,131	1,206
D.P.	0,660	1,746	3,667	4,139	3,361	1,937	0,984	0,451	0,095	0,072	0,044	0,828	1,071
C.V.	4,297	2,084	1,243	0,896	1,017	1,471	1,808	1,665	0,566	0,641	0,685	6,314	0,888
Mínimo	0,000	0,000	0,001	0,001	0,001	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,002
Máximo	4,276	11,222	17,444	24,463	13,827	10,522	5,358	4,264	0,314	0,280	0,170	7,668	5,249
Quantis (90)	0,071	2,807	7,655	9,300	7,813	3,672	1,070	0,322	0,291	0,215	0,127	0,084	2,593
Quantis (75)	0,049	1,256	3,711	6,771	5,369	1,655	0,325	0,317	0,251	0,164	0,096	0,061	1,632
Quantis (50)	0,026	0,032	2,119	3,886	2,229	0,315	0,312	0,274	0,181	0,110	0,065	0,043	0,862
Quantis (25)	0,006	0,004	0,078	1,531	0,325	0,178	0,160	0,139	0,083	0,049	0,026	0,014	0,395
Quantis (10)	0,000	0,001	0,016	0,058	0,098	0,065	0,067	0,056	0,033	0,018	0,006	0,001	0,117

ANEXO A - Série de afluições ao açude Sítios Novos

Ano	Deflúvios (m³/s)												Média Anual
	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	
1912	0,000	0,587	16,435	9,913	19,700	8,212	2,986	2,663	1,905	0,433	0,012	0,007	5,238
1913	0,005	4,557	25,189	25,178	8,522	3,676	3,123	2,801	2,265	1,013	0,042	0,013	6,365
1914	0,009	0,211	5,829	12,788	15,054	7,134	3,206	2,883	2,476	1,140	0,023	0,009	4,230
1915	0,005	0,009	0,004	0,021	0,050	0,044	0,001	0,001	0,000	0,000	0,000	0,000	0,011
1916	0,001	0,014	4,179	7,408	7,044	2,460	2,301	2,008	0,625	0,012	0,008	0,005	2,172
1917	8,852	13,012	30,899	18,565	43,822	5,247	3,063	2,704	1,349	0,127	0,007	0,006	10,638
1918	0,005	0,113	6,465	14,185	16,071	6,495	2,991	2,656	1,409	0,101	0,010	0,006	4,209
1919	0,010	0,003	0,003	0,002	0,002	0,001	0,001	0,000	0,000	0,000	0,000	0,000	0,002
1920	0,000	0,000	6,543	8,438	8,588	4,450	3,033	2,706	1,596	0,174	0,009	0,007	2,962
1921	0,015	0,119	26,187	30,252	35,695	4,688	2,935	2,639	2,072	0,946	0,019	0,016	8,799
1922	0,015	0,016	0,052	30,936	19,125	2,030	0,231	0,163	0,068	0,024	0,004	0,007	4,389
1923	0,011	0,805	5,131	6,937	2,965	0,158	0,103	0,049	0,019	0,003	0,000	0,000	1,348
1924	1,549	17,261	27,968	37,077	32,307	8,693	0,163	0,076	0,027	0,006	0,001	0,008	10,428
1925	0,042	0,111	3,399	23,833	10,739	0,196	0,125	0,057	0,021	0,003	0,000	0,000	3,210
1926	0,003	0,047	7,868	20,195	3,839	0,187	0,107	0,049	0,015	0,001	0,000	0,000	2,693
1927	0,007	0,069	0,210	30,175	5,617	1,552	0,214	0,117	0,049	0,016	0,001	0,017	3,170
1928	0,015	0,030	0,124	6,621	2,398	0,142	0,093	0,040	0,012	0,001	0,000	0,001	0,790
1929	0,002	0,061	20,694	19,605	3,820	0,222	0,154	0,073	0,027	0,005	0,000	0,000	3,722
1930	0,001	0,000	0,002	0,028	0,033	0,026	0,011	0,001	0,000	0,000	0,000	0,000	0,009
1931	0,001	0,081	10,023	3,973	0,660	0,156	0,109	0,051	0,020	0,003	0,000	0,000	1,256
1932	0,002	0,010	0,093	0,114	0,087	0,062	0,060	0,026	0,007	0,000	0,000	0,001	0,039
1933	0,029	0,151	4,477	38,733	2,759	0,179	0,113	0,052	0,017	0,002	0,000	0,001	3,876
1934	0,083	10,666	54,930	25,123	9,669	1,700	0,141	0,064	0,024	0,004	0,000	0,002	8,534
1935	0,001	0,045	9,420	25,985	14,557	5,954	0,736	0,116	0,048	0,015	0,001	0,000	4,740
1936	0,015	0,016	0,089	0,064	0,158	0,325	0,162	0,079	0,029	0,006	0,000	0,000	0,079
1937	0,000	0,034	2,118	17,614	15,193	2,099	0,200	0,112	0,046	0,015	0,001	0,004	3,120
1938	0,026	0,053	16,763	24,670	7,339	0,359	0,157	0,078	0,028	0,005	0,000	0,000	4,123
1939	0,012	16,335	27,392	18,853	4,199	0,285	0,147	0,098	0,041	0,012	0,001	0,000	5,615
1940	0,001	0,072	10,880	33,641	5,601	0,207	0,117	0,052	0,017	0,001	0,000	0,000	4,216
1941	0,000	0,000	0,101	0,556	3,555	0,131	0,070	0,029	0,006	0,000	0,000	0,000	0,371

1942	0,000	0,052	0,793	5,807	0,902	0,179	0,099	0,044	0,013	0,001	0,000	0,000	0,657
1943	0,001	0,016	0,952	16,662	0,224	0,148	0,093	0,040	0,011	0,000	0,000	0,009	1,513
1944	0,035	0,034	0,046	1,699	10,770	0,774	0,144	0,065	0,022	0,003	0,000	0,005	1,133
1945	0,018	7,379	14,757	28,293	19,288	3,041	1,394	0,104	0,040	0,010	0,000	0,027	6,196
1946	0,105	0,112	18,143	22,897	4,820	3,153	0,151	0,069	0,024	0,004	0,000	0,000	4,123
1947	0,008	0,099	12,927	11,251	4,434	0,204	0,139	0,064	0,022	0,003	0,003	0,007	2,430
1948	0,000	0,006	2,375	3,551	5,676	1,168	0,154	0,073	0,026	0,004	0,000	0,004	1,086
1949	0,000	0,019	9,735	19,400	43,740	1,883	0,169	0,078	0,029	0,006	0,000	0,000	6,255
1950	0,000	0,039	7,800	13,419	3,122	0,158	0,085	0,037	0,010	0,000	0,000	0,000	2,056
1951	0,000	0,000	0,000	0,005	0,004	0,003	0,000	0,000	0,000	0,000	0,000	0,004	0,001
1952	0,021	0,016	0,048	9,776	0,236	0,143	0,075	0,031	0,007	0,000	0,000	0,000	0,863
1953	0,004	0,014	0,175	1,397	0,960	0,155	0,087	0,038	0,011	0,000	0,000	0,000	0,237
1954	0,003	0,040	3,312	0,260	1,715	0,185	0,134	0,062	0,023	0,003	0,000	0,013	0,479
1955	0,029	0,166	0,154	4,564	2,896	0,205	0,135	0,065	0,024	0,006	0,000	0,000	0,687
1956	0,000	0,080	9,776	11,358	2,627	0,182	0,115	0,056	0,021	0,003	0,000	0,000	2,018
1957	0,023	0,041	10,197	32,206	10,281	0,212	0,144	0,074	0,029	0,007	0,000	0,001	4,435
1958	0,001	0,000	0,005	0,060	0,090	0,069	0,047	0,018	0,002	0,000	0,000	0,000	0,024
1959	0,008	0,115	10,914	5,726	3,914	2,189	0,171	0,095	0,040	0,011	0,000	0,000	1,932
1960	0,000	0,000	0,075	2,675	0,200	0,126	0,086	0,044	0,014	0,001	0,000	0,002	0,269
1961	0,028	14,929	13,959	4,980	0,466	0,186	0,113	0,058	0,022	0,003	0,000	0,000	2,895
1962	0,011	2,955	7,179	2,995	0,252	0,207	0,141	0,068	0,026	0,005	0,000	0,000	1,153
1963	0,033	0,110	18,780	7,134	0,225	0,149	0,090	0,039	0,010	0,000	0,000	0,001	2,214
1964	0,037	0,142	8,040	37,206	7,753	0,221	0,178	0,097	0,039	0,011	0,000	0,000	4,477
1965	0,015	0,016	0,039	7,294	1,977	0,218	0,203	0,100	0,038	0,010	0,000	0,000	0,826
1966	0,000	0,005	0,031	0,088	0,154	0,167	0,122	0,062	0,021	0,003	0,000	0,000	0,054
1967	0,001	5,355	7,337	13,337	11,995	0,235	0,135	0,066	0,023	0,003	0,000	0,000	3,207
1968	0,003	0,018	0,786	4,405	7,779	0,208	0,125	0,057	0,019	0,002	0,000	0,002	1,117
1969	0,004	0,006	0,090	19,453	3,164	0,183	0,183	0,130	0,056	0,018	0,001	0,000	1,941
1970	0,031	0,098	0,165	9,150	1,588	0,162	0,091	0,040	0,011	0,000	0,001	0,000	0,945
1971	0,009	0,043	2,344	10,445	7,245	2,759	0,196	0,106	0,041	0,011	0,000	0,000	1,933
1972	0,003	0,004	0,022	0,046	0,157	0,149	0,125	0,073	0,029	0,006	0,000	0,004	0,052
1973	0,015	0,039	11,231	24,225	10,390	3,500	0,446	0,150	0,064	0,023	0,003	0,000	4,174
1974	0,056	4,490	20,882	27,221	17,966	0,489	0,163	0,078	0,029	0,007	0,000	0,030	5,951
1975	0,056	0,059	1,143	5,770	4,075	0,229	0,213	0,131	0,057	0,019	0,002	0,040	0,983
1976	0,081	0,128	7,310	8,291	0,210	0,134	0,073	0,031	0,007	0,000	0,000	0,000	1,355
1977	0,024	0,135	4,532	9,977	4,728	3,655	3,363	0,124	0,049	0,015	0,001	0,000	2,217

1978	0,000	0,072	0,800	6,971	6,066	0,183	0,145	0,100	0,040	0,011	0,000	0,000	1,199
1979	0,007	0,010	0,090	0,094	0,173	0,165	0,095	0,042	0,014	0,001	0,000	0,000	0,058
1980	0,030	0,074	6,265	0,166	0,116	0,096	0,052	0,019	0,002	0,000	0,000	0,000	0,568
1981	0,000	0,006	0,043	2,794	0,183	0,109	0,056	0,021	0,003	0,000	0,000	0,010	0,269
1982	0,025	0,038	0,153	1,097	2,509	0,191	0,121	0,059	0,020	0,002	0,000	0,000	0,351
1983	0,000	0,032	0,093	0,110	0,079	0,044	0,020	0,004	0,000	0,000	0,000	0,000	0,032
1984	0,014	0,030	0,059	10,203	10,093	1,280	0,142	0,070	0,033	0,008	0,000	0,000	1,827
1985	0,024	4,553	13,641	21,163	6,552	1,357	0,227	0,124	0,050	0,015	0,001	0,003	3,976
1986	0,034	2,707	25,080	15,640	2,300	2,221	0,841	0,108	0,045	0,014	0,001	0,000	4,083
1987	0,000	0,014	1,680	1,520	0,207	0,155	0,163	0,077	0,028	0,005	0,000	0,000	0,321
1988	0,004	0,027	0,131	14,570	7,947	0,204	0,175	0,121	0,048	0,015	0,001	0,001	1,937
1989	0,004	0,007	0,040	7,217	6,877	1,675	0,212	0,146	0,062	0,021	0,002	0,007	1,356
1990	0,023	0,011	0,112	0,116	0,545	0,171	0,119	0,059	0,020	0,003	0,000	0,000	0,098
1991	0,002	0,021	0,108	7,058	2,886	0,197	0,116	0,052	0,017	0,001	0,000	0,000	0,871
1992	0,001	0,050	0,169	5,015	0,210	0,147	0,086	0,037	0,010	0,000	0,000	0,000	0,477
1993	0,000	0,002	0,032	0,113	0,123	0,072	0,059	0,034	0,008	0,000	0,000	0,000	0,037
1994	0,023	0,060	3,623	18,314	11,071	8,166	0,846	0,114	0,046	0,013	0,000	0,001	3,523
1995	0,017	0,043	0,136	27,071	9,637	0,698	0,189	0,095	0,036	0,009	0,000	0,000	3,161
1996	0,020	0,053	5,691	14,248	2,384	0,202	0,115	0,057	0,019	0,002	0,000	0,000	1,899
Média	0,137	1,283	6,911	12,094	6,649	1,311	0,471	0,309	0,184	0,052	0,002	0,003	2,450
D.P.	0,971	3,607	9,626	10,867	8,951	2,102	0,901	0,758	0,525	0,197	0,006	0,007	2,396
C.V.	7,110	2,811	1,393	0,899	1,346	1,604	1,915	2,455	2,854	3,806	3,204	2,074	0,978
Mínimo	0,000	0,000	0,000	0,002	0,002	0,001	0,000	0,000	0,000	0,000	0,000	0,000	0,001
Máximo	8,852	17,261	54,930	38,733	43,822	8,693	3,363	2,883	2,476	1,140	0,042	0,040	10,638
Quantis (90)	0,037	4,528	19,928	27,864	15,720	4,141	1,938	0,158	0,067	0,022	0,004	0,009	5,464
Quantis (75)	0,023	0,115	10,023	19,453	8,588	1,700	0,196	0,106	0,041	0,012	0,001	0,004	3,976
Quantis (50)	0,008	0,045	3,312	9,150	3,820	0,205	0,141	0,066	0,024	0,004	0,000	0,000	1,932
Quantis (25)	0,001	0,016	0,101	2,794	0,252	0,156	0,095	0,044	0,014	0,001	0,000	0,000	0,568
Quantis (10)	0,000	0,004	0,039	0,101	0,136	0,101	0,059	0,027	0,007	0,000	0,000	0,000	0,053

ANEXO A - Série de afluências ao açude Choró-Limão

	Deflúvios (m³/s)												
Ano	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	Média Anual
1912	0,005	11,761	18,219	19,681	13,812	7,165	2,077	0,000	0,000	0,000	0,000	0,000	6,060
1913	0,017	0,017	1,984	33,554	13,556	5,743	5,413	0,940	0,000	0,000	0,000	0,003	5,102
1914	0,031	0,194	0,392	2,700	33,076	4,853	4,539	0,102	0,000	0,000	0,000	0,000	3,824
1915	0,000	0,000	0,000	0,010	0,001	0,001	0,000	0,000	0,000	0,000	0,000	0,006	0,002
1916	0,021	0,038	0,131	1,645	32,715	3,220	0,871	0,000	0,000	0,000	0,000	0,000	3,220
1917	0,239	29,275	110,672	10,229	70,356	14,889	12,250	2,037	0,000	0,000	0,000	0,001	20,829
1918	0,001	0,024	0,020	0,457	0,356	0,008	0,000	0,008	0,000	0,000	0,000	0,000	0,073
1919	0,150	0,003	0,000	0,000	0,005	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,013
1920	0,000	0,000	22,566	7,424	3,799	3,686	0,334	0,000	0,000	0,000	0,000	0,003	3,151
1921	0,006	0,160	95,233	53,763	114,222	18,000	15,226	8,495	0,192	0,000	0,000	0,000	25,441
1922	0,000	0,000	0,059	61,702	48,019	9,538	8,786	1,667	0,000	0,000	0,000	0,004	10,814
1923	0,004	18,537	2,437	11,958	4,089	1,106	0,000	0,000	0,000	0,000	0,001	0,000	3,178
1924	14,298	13,061	110,696	203,270	34,881	18,620	16,913	5,963	0,000	0,000	0,000	0,000	34,809
1925	0,002	0,001	83,222	80,481	12,851	8,929	1,153	0,000	0,000	0,000	0,000	0,000	15,553
1926	0,000	0,014	62,762	40,130	34,474	9,226	1,955	0,000	0,000	0,000	0,000	0,000	12,380
1927	0,000	0,005	0,155	0,165	0,833	0,603	0,000	0,000	0,000	0,000	0,000	0,000	0,147
1928	0,000	0,000	0,018	0,047	18,179	0,089	0,015	0,000	0,000	0,000	0,000	0,000	1,529
1929	0,002	0,070	0,521	18,717	3,102	0,400	0,035	0,000	0,000	0,000	0,000	0,000	1,904
1930	0,011	0,006	0,002	0,128	0,000	0,014	0,000	0,000	0,000	0,000	0,000	0,000	0,013
1931	0,008	0,015	0,300	0,083	0,000	0,016	0,000	0,000	0,000	0,000	0,000	0,000	0,035
1932	0,002	0,001	0,049	0,003	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,005
1933	0,001	0,008	0,062	53,552	5,272	1,340	0,000	0,000	0,000	0,000	0,000	0,000	5,020
1934	0,000	0,013	35,721	18,896	37,801	9,714	4,555	0,000	0,000	0,000	0,000	0,006	8,892
1935	0,000	0,024	0,314	18,231	11,478	4,801	4,718	0,248	0,000	0,000	0,000	0,000	3,318
1936	0,000	0,023	0,301	0,025	0,134	0,540	0,456	0,000	0,000	0,000	0,000	0,000	0,123
1937	0,000	0,052	0,329	16,685	23,916	10,230	4,138	0,000	0,000	0,000	0,000	0,000	4,613
1938	0,009	0,000	18,967	43,427	6,794	6,316	0,758	0,000	0,000	0,000	0,000	0,000	6,356
1939	0,001	21,912	47,593	5,717	6,075	1,952	0,000	0,000	0,000	0,001	0,000	0,000	6,938
1940	0,006	0,016	0,099	74,002	61,689	15,330	12,443	6,270	0,004	0,000	0,000	0,000	14,155
1941	0,000	0,014	4,012	1,358	1,905	0,069	0,000	0,000	0,000	0,000	0,000	0,000	0,613

1942	0,000	0,051	0,027	0,030	0,004	0,000	0,000	0,000	0,000	0,000	0,001	0,000	0,009
1943	0,002	0,045	0,025	12,563	2,050	0,064	0,006	0,000	0,000	0,000	0,000	0,019	1,231
1944	0,023	0,012	0,112	16,592	17,623	5,047	1,350	0,000	0,000	0,000	0,000	0,008	3,397
1945	0,007	5,597	2,053	27,737	36,421	7,844	8,142	2,000	0,000	0,000	0,000	0,000	7,483
1946	0,004	0,118	0,593	3,865	2,248	0,140	0,000	0,000	0,000	0,000	0,000	0,000	0,581
1947	0,002	0,027	31,618	48,286	50,430	10,287	4,819	0,000	0,000	0,000	0,006	0,127	12,134
1948	0,002	0,000	1,083	1,209	2,068	2,532	0,855	0,000	0,000	0,000	0,000	0,000	0,646
1949	0,000	0,010	19,842	33,854	23,233	7,800	3,461	0,000	0,000	0,000	0,000	0,000	7,350
1950	0,000	0,007	26,800	155,793	40,992	15,792	7,450	0,178	0,000	0,000	0,000	0,000	20,584
1951	0,004	0,000	0,001	2,078	1,151	22,374	2,853	0,000	0,000	0,000	0,000	0,002	2,372
1952	0,002	0,003	0,051	0,453	1,419	0,992	0,000	0,000	0,000	0,000	0,000	0,003	0,244
1953	0,000	0,000	0,015	0,072	12,557	2,239	0,224	0,000	0,000	0,000	0,000	0,000	1,259
1954	0,004	0,031	0,043	0,019	0,132	0,293	0,000	0,000	0,000	0,000	0,000	0,000	0,044
1955	0,003	0,026	0,231	32,209	35,829	6,416	1,094	0,000	0,000	0,000	0,000	0,001	6,317
1956	0,000	0,155	8,554	59,290	5,310	0,447	0,000	0,000	0,000	0,000	0,000	0,000	6,146
1957	0,002	0,001	20,218	49,680	8,041	4,967	0,089	0,000	0,000	0,000	0,000	0,000	6,917
1958	0,000	0,000	0,001	0,007	0,188	0,311	0,001	0,000	0,000	0,000	0,000	0,000	0,042
1959	0,010	0,213	13,696	24,399	5,297	4,761	0,530	0,000	0,000	0,000	0,000	0,000	4,076
1960	0,000	0,000	92,649	38,611	10,894	8,762	1,380	0,001	0,000	0,000	0,000	0,000	12,691
1961	0,018	26,663	61,247	75,133	13,434	12,169	5,325	0,035	0,000	0,000	0,000	0,000	16,169
1962	0,001	0,006	23,398	42,409	6,570	4,540	0,099	0,000	0,000	0,000	0,000	0,000	6,419
1963	0,067	0,498	94,070	33,279	14,709	9,230	1,622	0,000	0,000	0,000	0,000	0,003	12,790
1964	9,588	18,708	59,850	123,508	77,675	18,615	18,621	15,901	4,391	0,000	0,000	0,000	28,905
1965	0,003	0,005	0,023	80,093	14,796	46,075	11,098	2,463	0,000	0,000	0,000	0,000	12,880
1966	0,000	0,001	0,023	0,049	0,113	0,410	0,281	0,000	0,000	0,000	0,000	0,000	0,073
1967	0,000	0,023	9,328	52,552	35,992	8,840	5,573	0,363	0,000	0,000	0,000	0,000	9,389
1968	0,006	0,006	8,234	2,034	39,483	5,740	1,653	0,000	0,000	0,000	0,000	0,000	4,763
1969	0,002	0,002	0,080	44,308	4,609	4,746	16,672	5,062	0,030	0,000	0,000	0,000	6,293
1970	0,012	0,025	0,072	0,147	0,177	0,002	0,000	0,000	0,000	0,000	0,000	0,000	0,036
1971	0,010	0,011	0,066	10,020	12,660	17,164	5,217	1,352	0,000	0,000	0,000	0,000	3,875
1972	0,002	0,015	0,002	0,004	0,265	0,034	0,000	0,000	0,000	0,000	0,000	0,018	0,028
1973	0,019	0,015	13,986	92,460	39,653	21,282	13,276	7,857	0,122	0,000	0,000	0,000	15,723
1974	52,770	29,243	111,206	167,749	194,491	67,859	18,082	8,692	0,228	0,000	0,000	0,001	54,193
1975	0,003	0,003	14,999	2,297	12,461	4,916	5,065	2,228	0,000	0,000	0,000	0,001	3,498
1976	0,000	0,039	0,405	0,972	0,781	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,183
1977	0,003	0,125	0,521	10,195	96,211	13,781	10,204	5,526	0,000	0,000	0,000	0,000	11,380

1978	0,000	0,092	0,523	0,354	0,685	1,030	0,097	0,000	0,000	0,000	0,000	0,004	0,232
1979	0,000	0,001	0,014	0,010	0,245	0,565	0,000	0,000	0,000	0,000	0,000	0,000	0,070
1980	0,001	36,607	36,736	5,758	1,851	0,002	0,000	0,000	0,000	0,000	0,000	0,000	6,746
1981	0,000	0,000	71,688	12,124	4,885	0,205	0,000	0,000	0,000	0,000	0,000	0,008	7,409
1982	0,003	0,024	0,240	0,666	0,890	0,348	0,000	0,000	0,000	0,000	0,000	0,000	0,181
1983	0,000	0,090	0,162	0,015	0,002	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,022
1984	0,001	0,018	0,038	33,553	79,670	20,199	9,591	1,820	0,001	0,000	0,000	0,000	12,074
1985	0,018	5,262	108,140	68,613	55,888	25,191	18,254	13,293	1,881	0,000	0,000	0,005	24,712
1986	0,006	0,241	48,835	102,935	46,922	15,808	14,531	4,904	0,000	0,000	0,000	0,000	19,515
1987	0,000	0,008	0,110	7,071	2,011	0,040	0,097	0,000	0,000	0,000	0,000	0,000	0,778
1988	0,000	0,001	0,028	64,963	68,443	10,327	7,701	0,455	0,000	0,000	0,000	0,004	12,660
1989	0,005	0,005	0,030	31,514	30,130	7,645	30,065	4,453	0,000	0,000	0,000	0,015	8,655
1990	0,009	0,002	0,094	0,006	0,444	0,389	0,000	0,000	0,000	0,000	0,000	0,000	0,079
1991	0,000	0,004	0,083	0,637	20,113	1,720	0,000	0,000	0,000	0,000	0,000	0,000	1,880
1992	0,001	3,914	1,269	1,922	1,154	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,688
1993	0,000	0,001	0,011	0,003	0,001	0,001	0,002	0,000	0,000	0,000	0,000	0,000	0,002
1994	0,001	0,052	3,894	29,333	26,502	52,654	20,131	4,039	0,000	0,000	0,000	0,001	11,384
1995	0,008	0,015	0,028	23,705	17,281	15,951	5,080	0,679	0,000	0,000	0,000	0,000	5,229
1996	0,059	0,104	0,215	42,876	16,578	4,922	0,154	0,001	0,000	0,000	0,000	0,000	5,409
Média	0,912	2,628	17,695	28,801	21,024	7,646	4,087	1,259	0,081	0,000	0,000	0,003	7,011
D.P.	5,987	7,507	31,664	39,951	30,838	11,409	6,245	2,936	0,516	0,000	0,001	0,014	8,993
C.V.	6,566	2,857	1,789	1,387	1,467	1,492	1,528	2,332	6,405	9,220	7,075	4,893	1,283
Mínimo	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,002
Máximo	52,770	36,607	111,206	203,270	194,491	67,859	30,065	15,901	4,391	0,001	0,006	0,127	54,193
Quantis (90)	0,023	9,296	68,118	74,681	53,705	18,369	14,029	4,999	0,000	0,000	0,000	0,005	15,990
Quantis (75)	0,008	0,092	19,842	42,876	33,076	9,714	5,325	0,455	0,000	0,000	0,000	0,001	10,814
Quantis (50)	0,002	0,015	0,392	12,124	10,894	4,761	0,758	0,000	0,000	0,000	0,000	0,000	4,613
Quantis (25)	0,000	0,003	0,051	0,457	1,151	0,311	0,000	0,000	0,000	0,000	0,000	0,000	0,244
Quantis (10)	0,000	0,000	0,016	0,017	0,120	0,002	0,000	0,000	0,000	0,000	0,000	0,000	0,036

ANEXO A - Correlações

LAG	CORREL
0	1,000
1	0,660
2	0,296
3	-0,019
4	-0,167
5	-0,216
6	-0,225
7	-0,219
8	-0,186
9	-0,074
10	0,125
11	0,363
12	0,464
13	0,357
14	0,134
15	-0,084
16	-0,186
17	-0,225
18	-0,231
19	-0,228
20	-0,200
21	-0,109
22	0,069
23	0,273
24	0,334
25	0,236

LAG	CORREL
0	0,863
1	0,585
2	0,240
3	-0,024
4	-0,149
5	-0,187
6	-0,201
7	-0,191
8	-0,158
9	-0,048
10	0,131
11	0,360
12	0,436
13	0,301
14	0,094
15	-0,084
16	-0,186
17	-0,199
18	-0,206
19	-0,203
20	-0,160
21	-0,078
22	0,091
23	0,253
24	0,304
25	0,183

LAG	CORREL
0	0,814
1	0,470
2	0,139
3	-0,073
4	-0,150
5	-0,169
6	-0,173
7	-0,169
8	-0,143
9	-0,051
10	0,116
11	0,337
12	0,368
13	0,230
14	0,009
15	-0,129
16	-0,167
17	-0,177
18	-0,177
19	-0,172
20	-0,148
21	-0,070
22	0,075
23	0,221
24	0,259
25	0,110

LAG	CORREL
0	0,750
1	0,514
2	0,240
3	0,019
4	-0,092
5	-0,143
6	-0,157
7	-0,152
8	-0,127
9	-0,037
10	0,095
11	0,301
12	0,358
13	0,267
14	0,089
15	-0,061
16	-0,128
17	-0,159
18	-0,164
19	-0,159
20	-0,138
21	-0,073
22	0,046
23	0,184
24	0,194
25	0,128

ANEXO A - Correlações

LAG	CORREL
0	1,000
1	0,613
2	0,287
3	0,029
4	-0,113
5	-0,160
6	-0,175
7	-0,169
8	-0,137
9	-0,049
10	0,119
11	0,372
12	0,497
13	0,359
14	0,147
15	-0,038
16	-0,132
17	-0,170
18	-0,180
19	-0,177
20	-0,141
21	-0,072
22	0,073
23	0,245
24	0,295
25	0,208

LAG	CORREL
0	0,773
1	0,442
2	0,148
3	-0,034
4	-0,116
5	-0,146
6	-0,152
7	-0,148
8	-0,126
9	-0,081
10	0,078
11	0,323
12	0,385
13	0,252
14	0,038
15	-0,092
16	-0,131
17	-0,149
18	-0,153
19	-0,150
20	-0,131
21	-0,079
22	0,038
23	0,185
24	0,240
25	0,122

LAG	CORREL
0	0,732
1	0,549
2	0,259
3	0,049
4	-0,058
5	-0,116
6	-0,135
7	-0,130
8	-0,096
9	-0,047
10	0,082
11	0,284
12	0,359
13	0,303
14	0,132
15	-0,024
16	-0,095
17	-0,134
18	-0,145
19	-0,142
20	-0,125
21	-0,083
22	0,033
23	0,125
24	0,165
25	0,140

ANEXO A - Correlações

LAG	CORREL
0	1,000
1	0,530
2	0,159
3	-0,039
4	-0,101
5	-0,127
6	-0,133
7	-0,130
8	-0,120
9	-0,084
10	0,048
11	0,314
12	0,436
13	0,294
14	0,060
15	-0,076
16	-0,117
17	-0,132
18	-0,137
19	-0,137
20	-0,129
21	-0,094
22	0,014
23	0,193
24	0,294
25	0,174

LAG	CORREL
0	0,645
1	0,468
2	0,219
3	0,015
4	-0,068
5	-0,114
6	-0,128
7	-0,124
8	-0,114
9	-0,080
10	0,015
11	0,215
12	0,318
13	0,262
14	0,102
15	-0,042
16	-0,098
17	-0,123
18	-0,131
19	-0,130
20	-0,123
21	-0,096
22	-0,026
23	0,097
24	0,180
25	0,134

LAG	CORREL
0	1,000
1	0,538
2	0,256
3	0,068
4	-0,032
5	-0,091
6	-0,112
7	-0,107
8	-0,083
9	-0,028
10	0,054
11	0,232
12	0,336
13	0,252
14	0,095
15	-0,034
16	-0,085
17	-0,107
18	-0,117
19	-0,116
20	-0,101
21	-0,065
22	-0,002
23	0,117
24	0,162
25	0,096

ANEXO B – Rotinas do MATLAB**MODELO DA ROTINA UTILIZADA PARA TREINAMENTO E SIMULAÇÃO DE RNAs
COM 1 CAMADA INTERMEDIÁRIA**

```
clear, whitebg, clc, clf, close all
```

```
% Inicializando
```

```
dcentc;  
dcsaic;
```

```
nni = 9;  
F1 = 'logsig';  
F2 = 'logsig';
```

```
[w1,b1] = rands(nni,8);  
[w2,b2] = rands(4,nni);
```

```
% Parâmetros de treinamento ...:
```

```
err_goal = 0.003;  
max_epoca = 1000;  
lr = 0.1;
```

```
tp = [100 max_epoca err_goal lr];
```

```
% Treinamento da rede ...:
```

```
[w1, b1, w2, b2, ep, tr] = trainbpx (w1, b1, F1, w2, b2, F2, P, T, tp);
```

```
F=logsig(w1*P,b1);  
FIM=logsig(w2*F,b2);
```

```
% Salvando os pesos e os bias
```

```
save pesos01 w1 b1 w2 b2
```

```
% Simulação
```

```
a=simuff(P,w1,b1,'logsig',w2,b2,'logsig');
```

ANEXO B – Rotinas do MATLAB**MODELO DA ROTINA UTILIZADA PARA TREINAMENTO E SIMULAÇÃO DE RNAs
COM 2 CAMADAS INTERMEDIÁRIAS**

```
clear, whitebg, clc, clf, close all
```

```
%Inicializando
```

```
dcentc;  
dcsaic;
```

```
nni = 3;  
F1 = 'logsig';  
F2 = 'logsig';  
F3 = 'logsig';
```

```
[w1,b1] = rands(nni,8);  
[w2,b2] = rands(nni,nni);  
[w3,b3] = rands(4,nni);
```

```
% Parâmetros de treinamento ....:
```

```
err_goal = 0.003;  
max_epoca = 1000;  
lr = 0.1;
```

```
tp = [100 max_epoca err_goal lr];
```

```
% Treinamento da rede ....:
```

```
[w1, b1, w2, b2, w3, b3, ep, tr] = trainbpx (w1, b1, F1, w2, b2, F2, w3, b3, F3, P, T,  
tp);
```

```
F=logsig(w1*P,b1);  
FIM=logsig(w2*F,b2);  
F3=logsig(w3*FIM,b3);
```

```
%Salvando os pesos e os bias
```

```
save pesos01 w1 b1 w2 b2 w3 b3
```

```
%Simulação
```

```
a=simuff(P,w1,b1,'logsig',w2,b2,'logsig', w3, b3, 'logsig');
```

ANEXO C – Correlações – Modelagem Multivariada

ACARAPE - AUTOCORRELAÇÃO		
LAG	Histórica	Modelada
0	1,000	1,000
1	0,660	0,533
2	0,296	0,209
3	-0,019	-0,121
4	-0,167	-0,281
5	-0,216	-0,344
6	-0,225	-0,357
7	-0,219	-0,345
8	-0,186	-0,286
9	-0,074	-0,123
10	0,125	0,210
11	0,363	0,503
12	0,464	0,804
13	0,357	0,518
14	0,134	0,189
15	-0,084	-0,126
16	-0,186	-0,288
17	-0,225	-0,347
18	-0,231	-0,359
19	-0,228	-0,347
20	-0,200	-0,294
21	-0,109	-0,144
22	0,069	0,160
23	0,273	0,493
24	0,334	0,685
25	0,236	0,494

ACARAPE x GAVIÃO		
LAG	Histórica	Modelada
0	0,863	0,967
1	0,585	0,434
2	0,240	0,132
3	-0,024	-0,150
4	-0,149	-0,269
5	-0,187	-0,318
6	-0,201	-0,330
7	-0,191	-0,310
8	-0,158	-0,237
9	-0,048	-0,067
10	0,131	0,231
11	0,360	0,492
12	0,436	0,759
13	0,301	0,416
14	0,094	0,112
15	-0,084	-0,153
16	-0,166	-0,280
17	-0,199	-0,320
18	-0,206	-0,333
19	-0,203	-0,309
20	-0,160	-0,247
21	-0,078	-0,089
22	0,091	0,179
23	0,253	0,477
24	0,304	0,641
25	0,183	0,398

ACARAPE x S. NOVOS		
LAG	Histórica	Modelada
0	0,814	0,911
1	0,470	0,357
2	0,139	0,043
3	-0,073	-0,199
4	-0,150	-0,272
5	-0,169	-0,287
6	-0,173	-0,288
7	-0,169	-0,277
8	-0,143	-0,222
9	-0,051	-0,072
10	0,116	0,221
11	0,337	0,480
12	0,368	0,739
13	0,230	0,345
14	0,009	0,027
15	-0,129	-0,203
16	-0,167	-0,277
17	-0,177	-0,288
18	-0,177	-0,289
19	-0,172	-0,276
20	-0,148	-0,226
21	-0,070	-0,086
22	0,075	0,178
23	0,221	0,475
24	0,259	0,628
25	0,110	0,333

ACARAPE x CHORÓ		
LAG	Histórica	Modelada
0	0,750	0,935
1	0,514	0,431
2	0,240	0,152
3	0,019	-0,120
4	-0,092	-0,245
5	-0,143	-0,299
6	-0,157	-0,311
7	-0,152	-0,296
8	-0,127	-0,237
9	-0,037	-0,096
10	0,095	0,189
11	0,301	0,451
12	0,358	0,728
13	0,267	0,410
14	0,089	0,134
15	-0,061	-0,121
16	-0,128	-0,253
17	-0,159	-0,303
18	-0,164	-0,314
19	-0,159	-0,296
20	-0,138	-0,242
21	-0,073	-0,112
22	0,046	0,137
23	0,184	0,430
24	0,194	0,614
25	0,128	0,389

GAVIÃO - AUTOCORRELAÇÃO		
LAG	Histórica	Modelada
0	1,000	1,000
1	0,613	0,435
2	0,287	0,156
3	0,029	-0,104
4	-0,113	-0,228
5	-0,160	-0,288
6	-0,175	-0,305
7	-0,169	-0,289
8	-0,137	-0,228
9	-0,049	-0,098
10	0,119	0,152
11	0,372	0,409
12	0,497	0,681
13	0,359	0,411
14	0,147	0,142
15	-0,038	-0,105
16	-0,132	-0,237
17	-0,170	-0,288
18	-0,180	-0,307
19	-0,177	-0,288
20	-0,141	-0,234
21	-0,072	-0,122
22	0,073	0,103
23	0,245	0,402
24	0,295	0,584
25	0,208	0,390

GAVIÃO x S. NOVOS		
LAG	Histórica	Modelada
0	0,773	0,952
1	0,442	0,369
2	0,148	0,075
3	-0,034	-0,155
4	-0,116	-0,235
5	-0,146	-0,262
6	-0,152	-0,268
7	-0,148	-0,257
8	-0,126	-0,211
9	-0,081	-0,100
10	0,078	0,144
11	0,323	0,400
12	0,385	0,671
13	0,252	0,351
14	0,038	0,064
15	-0,092	-0,157
16	-0,131	-0,238
17	-0,149	-0,261
18	-0,153	-0,267
19	-0,150	-0,255
20	-0,131	-0,211
21	-0,079	-0,115
22	0,038	0,101
23	0,185	0,406
24	0,240	0,582
25	0,122	0,338

ANEXO C – Correlações – Modelagem Multivariada

GAVIÃO x CHORÓ		
LAG	Histórica	Modelada
0	0,732	0,976
1	0,549	0,433
2	0,259	0,172
3	0,049	-0,074
4	-0,058	-0,204
5	-0,116	-0,269
6	-0,135	-0,288
7	-0,130	-0,275
8	-0,096	-0,227
9	-0,047	-0,121
10	0,082	0,115
11	0,284	0,368
12	0,359	0,644
13	0,303	0,403
14	0,132	0,160
15	-0,024	-0,073
16	-0,095	-0,212
17	-0,134	-0,270
18	-0,145	-0,290
19	-0,142	-0,276
20	-0,125	-0,226
21	-0,083	-0,137
22	0,033	0,066
23	0,125	0,359
24	0,165	0,556
25	0,140	0,376

S. NOVOS - AUTOCORRELAÇÃO		
LAG	Histórica	Modelada
0	1,000	1,000
1	0,530	0,391
2	0,159	0,068
3	-0,039	-0,152
4	-0,101	-0,213
5	-0,127	-0,230
6	-0,133	-0,232
7	-0,130	-0,228
8	-0,120	-0,211
9	-0,084	-0,142
10	0,048	0,065
11	0,314	0,379
12	0,436	0,699
13	0,294	0,377
14	0,060	0,055
15	-0,076	-0,153
16	-0,117	-0,216
17	-0,132	-0,229
18	-0,137	-0,232
19	-0,137	-0,226
20	-0,129	-0,207
21	-0,094	-0,147
22	0,014	0,044
23	0,193	0,401
24	0,294	0,621
25	0,174	0,378

S. NOVOS x CHORÓ		
LAG	Histórica	Modelada
0	0,645	0,943
1	0,468	0,406
2	0,219	0,146
3	0,015	-0,082
4	-0,068	-0,188
5	-0,114	-0,241
6	-0,128	-0,253
7	-0,124	-0,246
8	-0,114	-0,224
9	-0,080	-0,158
10	0,015	0,024
11	0,215	0,311
12	0,318	0,611
13	0,262	0,390
14	0,102	0,136
15	-0,042	-0,079
16	-0,098	-0,194
17	-0,123	-0,241
18	-0,131	-0,254
19	-0,130	-0,245
20	-0,123	-0,217
21	-0,096	-0,161
22	-0,026	0,004
23	0,097	0,330
24	0,180	0,546
25	0,134	0,385

CHORÓ - AUTOCORRELAÇÃO		
LAG	Histórica	Modelada
0	1,000	1,000
1	0,538	0,396
2	0,256	0,130
3	0,068	-0,094
4	-0,032	-0,200
5	-0,091	-0,256
6	-0,112	-0,272
7	-0,107	-0,259
8	-0,083	-0,205
9	-0,028	-0,096
10	0,054	0,120
11	0,232	0,358
12	0,336	0,608
13	0,252	0,359
14	0,095	0,120
15	-0,034	-0,095
16	-0,085	-0,204
17	-0,107	-0,256
18	-0,117	-0,273
19	-0,116	-0,258
20	-0,101	-0,202
21	-0,065	-0,109
22	-0,002	0,080
23	0,117	0,363
24	0,162	0,525
25	0,096	0,329

APÊNDICES

**APÊNDICE I – Localização das Bacias Metropolitanas de Fortaleza dentro
do estado do Ceará**

APÊNDICE II – Localização dos Açudes estudados dentro das Bacias Metropolitanas de Fortaleza