

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE**

**CENTRO DE CIÊNCIAS E TECNOLOGIA**

**CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL**

**PREVISÃO REGIONALIZADA DE VAZÃO SAZONAL UTILIZANDO**

**REDES NEURAIS ARTIFICIAIS**

**JOSÉ ROSENILTON DE ARAÚJO MARACAJÁ**

**CAMPINA GRANDE – PB**

**MAIO – 2005**

**JOSÉ ROSENILTON DE ARAÚJO MARACAJÁ**

**PREVISÃO REGIONALIZADA DE VAZÃO SAZONAL UTILIZANDO**

**REDES NEURAIAS ARTIFICIAIS**

Dissertação apresentada ao Curso de Pós-Graduação em Engenharia Civil, na área de Engenharia de Recursos Hídricos, em cumprimento às exigências para obtenção do Grau de Mestre.

**ÁREA DE CONCENTRAÇÃO: RECURSOS HÍDRICOS**

**ORIENTADORES: VAJAPYAM SRIRANGACHAR SRINIVASAN**

**CARLOS DE OLIVEIRA GALVÃO**

**CAMPINA GRANDE – PB**

**MAIO – 2005**



M298p

Maracaja, Jose Rosenilton de Araujo

Previsao regionalizada de vazao sazonal utilizando redes neurais artificiais / Jose Rosenilton de Araujo Maracaja. - Campina Grande, 2005.

122 f.

Dissertacao (Mestrado em Engenharia Civil) - Universidade Federal da Paraiba, Centro de Ciencias e Tecnologia.

1. Previsao Hidrologica - 2. Redes Neurais Artificiais  
3. Previsao Sazonal da Vazao 4. Dissertacao I. Srinivasan, Vajapeyam Srirangachar, Dr. II. Galvao, Carlos de Oliveira, Dr. III. Universidade Federal da Paraiba - Campina Grande (PB) IV. Titulo

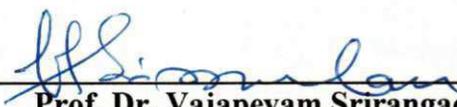
CDU 556.06(043)

**JOSÉ ROSENILTON DE ARAÚJO MARACAJÁ**

**PREVISÃO REGIONALIZADA DE VAZÃO SAZONAL UTILIZANDO  
REDES NEURAS ARTIFICIAIS**

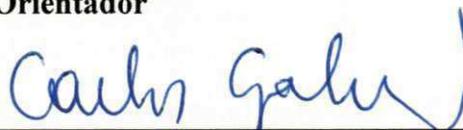
**APROVADA EM 31 DE MAIO DE 2005**

**COMISSÃO EXAMINADORA:**



---

**Prof. Dr. Vajapeyam Srirangachar Srinivasan**  
**Orientador**



---

**Prof. Dr. Carlos de Oliveira Galvão**  
**Orientador**



---

**Prof. Dr. Celso Augusto Guimarães Santos**  
**Examinador**



---

**Prof. Dr. Eduardo Eneas de Figueiredo**  
**Examinador**

**CAMPINA GRANDE - PB**

**MAIO – 2005**

Aos meus pais, Rui e Zefinha, a quem devo tudo. Para Marize e Norton Lincoln, incentivadores desse ideal.

## AGRADECIMENTOS

Agradeço primeiramente a Deus, pela sua presença constante em minha vida, sem a qual, reconheço, não transpassaria jamais as barreiras que se opuseram contra esse ideal.

A Rui, meu pai, a minha mãe Zefinha, a minha irmã Maria Augusta, aos meus tios Toinho e Ezequiel, a minha esposa Marize, pelo amor e constante incentivo durante a minha vida escolar, oferecendo o melhor de si para que eu me realizasse profissionalmente.

Ao professor orientador Dr. Vajapeyam S. Srinivasan pelo compartilhamento de sua expressiva sabedoria na arte de ensinar, essencial para a minha formação.

Ao professor orientador Dr. Carlos de Oliveira Galvão, que tem o dom de orientar, preparando-nos não apenas profissionalmente, mas também como pessoa.

As minhas colegas Isabelli Yrusca e Klécia Forte pela colaboração e ajuda no trato com o modelo de previsão da precipitação RSM.

A Roberta Melo, que sempre mostrou-se prestativa na dissolução de minhas dúvidas.

A todos os funcionários, professores e alunos da área de Recursos Hídricos da UFCG em Campina Grande, os quais guardo comigo com grande carinho.

Ao programa CAPES que financiou esse trabalho e colabora constantemente no desenvolvimento técnico científico do nosso país.

## RESUMO

Muitas bacias hidrográficas têm séries hidrológicas pequenas e/ou descontínuas, potencializando uma demanda por dados hidrométricos nestas bacias. Nas regiões pertencentes ao semi-árido existem carências de informações relativas às previsões de vazão ou volume escoado sazonalmente, principalmente a reservatórios. Este trabalho contempla as bacias hidrográficas dos rios Piranhas-Açu e Apodi, localizadas no nordeste brasileiro e de grande importância para a região, em que se realizaram estas previsões, com análise das incertezas, utilizando-se a previsão de precipitação sazonal. Para isso, fez-se uso das bacias com dados hidrométricos no estabelecimento de um modelo de regionalização para a estimativa da vazão média diária sazonal nas bacias sem dados hidrométricos, usando informações da previsão da precipitação e das características fisiográficas das bacias, como: área de drenagem, comprimento do rio principal, declividade média do rio, densidade de drenagem. Usou-se a técnica de Redes Neurais Artificiais (RNAs) e comparou-se seus resultados com um modelo de Regressão Múltipla desenvolvido em trabalhos anteriores. De forma geral, a RNA mostrou um bom desempenho, semelhante ao do estatístico clássico de Regressão Múltipla. A qualidade do ajuste do modelo relaciona-se com a conformidade das grandezas físicas das sub-bacias, ou seja, este resultado mostra a necessidade de uma pré-avaliação dos dados, com o uso de amostras representativas do conjunto de bacias para a calibração da Rede Neural. Na previsão da vazão sazonal, apesar da previsão da precipitação ainda conter um elevado nível de incerteza, ambos os modelos hidrológicos obtiveram, em geral, um bom desempenho, pois, foi constatado que as incertezas acumuladas, propagadas para a etapa da previsão da vazão, foram atenuadas no processo da transformação chuva em vazão, através das bacias hidrográficas.

Palavras-chaves: regionalização, redes neurais artificiais, previsão da vazão sazonal.

## ABSTRACT

Many river basins have discontinuous and/or small hydrological series, raising the hydrometric data demand in these basins. There are lacks of information in the semiarid reservoirs related to seasonal forecasts of outflow or drained volume. This dissertation contemplates Piranhas-Açu and Apodi river basins, located in the northeastern Brazil with great importance for the region, with the use of the seasonal precipitation forecast. The basins with hydrometric data were used in the establishment of a regional model to estimate the seasonal daily average outflow in the basins without hydrometric data. The precipitation forecast and the physiographic characteristics of the basins (draining area, length of the main river, mean slope of the river, density of draining) were used in this process. The Artificial Neural Nets (ANNs) technique was used and its results were compared to a Multiple Regression Model developed in previous researches. The ANN showed a good performance when compared to Multiple Regression Model. Relations between the model adjustment quality and the physical characteristics of the sub-basins were noticed. This result shows the need of a data evaluation study with the use of representative samples of the set of basins for the Neural Net calibration. Both hydrological models showed good performances in the seasonal outflow forecast, despite the fact that the precipitation forecasts still contain high level of uncertainty. It was evidenced that the accumulated uncertainties, propagated to the outflow forecasting stage, had been attenuated in the transformation process of rainfall in outflow through the hydrological basins.

Keywords: region models, artificial neural nets, outflow forecast.

## SUMÁRIO

<b>DEDICATÓRIA.....</b>	<b>i</b>
<b>AGRADECIMENTOS.....</b>	<b>ii</b>
<b>RESUMO.....</b>	<b>iii</b>
<b>ABSTRACT.....</b>	<b>iv</b>
<b>SUMÁRIO.....</b>	<b>v</b>
<b>LISTA DE TABELAS.....</b>	<b>viii</b>
<b>LISTA DE FIGURAS.....</b>	<b>ix</b>
<b>LISTA DE SÍMBOLOS.....</b>	<b>xii</b>
<b>1. INTRODUÇÃO.....</b>	<b>01</b>
<b>2. REVISÃO DE LITERATURA.....</b>	<b>04</b>
2.1. REGIONALIZAÇÃO HIDROLÓGICA.....	04
2.2. APLICAÇÕES DE RNAs EM RECURSOS HÍDRICOS.....	08
2.3. VANTAGENS E DESVANTAGENS DAS RNAs.....	15
<b>3. REDES NEURAS ARTIFICIAIS.....</b>	<b>17</b>
3.1. DEFINIÇÕES DE REDES NEURAS.....	18
3.2. BREVE HISTÓRICO.....	19
3.3. O NEURÔNIO BIOLÓGICO.....	21
3.4. O NEURÔNIO ARTIFICIAL.....	23
3.5. FUNÇÃO DE ATIVAÇÃO.....	26
3.6. ARQUITETURA DA REDE NEURAL.....	28
3.7. APRENDIZADO POR CORREÇÃO DE ERRO E ALGORITMO DE RETRO-PROPAGAÇÃO.....	34
3.8. ALGORITMO DE TREINAMENTO DE LEVENBERG-MARQUARDT.....	37

<b>4. A REGIÃO DE ESTUDO E ANÁLISE DOS DADOS.....</b>	<b>39</b>
4.1. SELEÇÃO, COLETA E TRATAMENTO DOS DADOS.....	39
4.2. DADOS DESCRITIVOS DA REGIÃO.....	40
4.3. DADOS HIDROLÓGICOS.....	44
4.4. CARACTERÍSTICAS FÍSICAS.....	50
<b>5. METODOLOGIA.....</b>	<b>52</b>
5.1. DESCRIÇÃO GERAL DA METODOLOGIA.....	52
5.2. ETAPAS DA CONSTRUÇÃO DO MODELO DE RNA.....	56
5.3. VALIDAÇÃO DO MODELO.....	57
5.3.1. Calibração e validação cruzada.....	57
5.3.2. Calibração e validação mista.....	59
5.3.3. Calibração e validação clássica.....	61
5.4. PREVISÃO DA PRECIPITAÇÃO E DA VAZÃO.....	62
5.4.1. Extração da previsão de precipitação.....	62
5.4.2. Previsão da vazão.....	64
5.5. ÍNDICES DE DESEMPENHO.....	64
<b>6. RESULTADOS E DISCUSSÃO.....</b>	<b>66</b>
6.1. CONSTRUÇÃO DO MODELO DE RNA.....	66
6.2. ANÁLISE DO AJUSTE E VALIDAÇÕES DO MODELO.....	73
6.2.1. Análise dos resultados na validação cruzada.....	75
6.2.2. Análise dos resultados na validação mista.....	87
6.2.2.1. <i>Validação mista com os dados tratados de Serra Negra</i> .....	87
6.2.2.2. <i>Validação mista sem os dados de Serra Negra</i> .....	93
6.2.3. Análise dos resultados na validação clássica.....	95
6.3. RESULTADOS DA PREVISÃO DE VAZÃO.....	101
6.3.1. Previsão da precipitação sazonal.....	102

6.3.2. Previsão da vazão média diária sazonal e análise das incertezas.....	104
6.4. AVALIAÇÃO E COMPARAÇÃO FINAL ENTRE RNA E REGRESSÃO MÚLTIPLA.....	109
<b>7. CONCLUSÕES E RECOMENDAÇÕES.....</b>	<b>111</b>
7.1. CONCLUSÕES.....	111
7.2. RECOMENDAÇÕES.....	112
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>113</b>
<b>ANEXO.....</b>	<b>120</b>
ANEXO A: PARÂMETROS DO MODELO DE RNA DE MÚLTIPLAS CAMADAS (3-2-1).....	121

## LISTA DE TABELAS

Tabela 3.1 -	Tipos de funções de ativação mais empregadas em RNA.....	27
Tabela 4.1 -	Descrição das bacias dos postos fluviométricos (Melo, 2003).....	47
Tabela 4.2 -	Séries sazonais de vazão (m <sup>3</sup> /s) e precipitação (mm) utilizadas (Melo, 2003).....	48
Tabela 4.3 -	Características físicas das sub-bacias estudadas (Melo, 2003).....	50
Tabela 5.1 -	Conformação dos conjuntos de dados para a calibração e validação por divisão com base nas sub-bacias.....	59
Tabela 5.2 -	Sub-bacias atendidas pelo modelo de previsão de precipitação.....	64
Tabela 6.1 -	Coefficientes de determinação obtidos na investigação da estrutura da RNA com uma camada escondida.....	67
Tabela 6.2 -	Coefficientes de determinação obtidos no ajuste para a calibração e validação para estruturas de RNA com duas camadas escondidas.....	69
Tabela 6.3 -	Coefficientes de determinação obtidos no ajuste para a calibração e validação para estruturas de RNA com três camadas escondidas.....	69
Tabela 6.4 -	Comparação entre os índices de desempenho dos modelos de RNA e Regressão Múltipla de Melo na fase de calibração.....	76
Tabela 6.5 -	Comparação entre os índices de desempenho dos modelos de RNA e Regressão Múltipla de Melo na fase de validação.....	77
Tabela 6.6 -	Resultados da validação para o posto de Serra Negra com tratamento dos dados.....	86
Tabela 6.7 -	Resultados do modelo de RNA para a validação mista com os dados tratados de Serra Negra.....	87
Tabela 6.8 -	Resultados do modelo de RNA para a validação mista sem os dados de Serra Negra.....	94
Tabela 6.9 -	Índices de desempenho obtido pelo modelo de RNA para as três combinações da validação clássica.....	101
Tabela 6.10	Índices de desempenho do modelo RSM na previsão da precipitação sazonal.....	102
Tabela 6.11	Séries sazonais de precipitação observada (Pobs) e prevista (Pprev) em mm.....	104
Tabela 6.12 -	Comparação entre RNA e Regressão Múltipla (Melo, 2003) na simulação da vazão média diária sazonal a partir de dados de chuva sazonal observados.....	105
Tabela 6.13 -	Comparação entre RNA e Regressão Múltipla (Melo, 2003) na previsão da vazão média diária sazonal a partir de dados de chuva sazonal previstos.....	105
Tabela 6.14 -	Variação relativa do coeficiente de determinação entre os níveis de simulação da vazão sazonal e o da previsão.....	106

## LISTA DE FIGURAS

Figura 3.1 -	Componentes do neurônio (Osório e Vieira, 1999).....	22
Figura 3.2 -	Analogia entre os neurônios naturais e artificiais (Tafner et al., 1995).....	23
Figura 3.3 -	Neurônio de McCulloch-Pitts (Adaptado de Haykin, 2001).....	25
Figura 3.4 -	Neurônio de MCP modificado (Adaptado de Haykin, 2001).....	26
Figura 3.5 -	Fluxograma das etapas a serem definidas na elaboração de um projeto de RNA.....	28
Figura 3.6 -	Rede de múltiplas camadas conectadas unidirecionalmente (Haykin, 2001).....	31
Figura 3.7 -	Rede com conexões recorrentes e com camada intermediária (Haykin, 2001).....	32
Figura 3.8 -	Ilustração da aprendizagem por correção de erro.....	35
Figura 4.1 -	Localização geográfica e bacias dos postos fluviométricos da bacia Piranhas-Açu-Apodi (Fonte: UFPB/ANEEL, 2001).....	41
Figura 4.2 -	Distribuição espacial dos postos pluviométricos e fluviométricos selecionados (Fonte: UFPB/ANEEL, 2001).....	45
Figura 5.1 -	Esquema da metodologia geral adotada.....	55
Figura 5.2 -	Fluxograma do processo de treinamento e validação de uma RNA com aprendizado supervisionado (Hines, 1997).....	57
Figura 5.3 -	Representação da distribuição e organização dos conjuntos criados na calibração e validação mista.....	61
Figura 6.1 -	Variação do coeficiente de determinação médio com o número de neurônios para uma camada escondida.....	68
Figura 6.2 -	Variação do coeficiente de determinação médio para estruturas de redes com mais de uma camada escondida.....	70
Figura 6.3 -	Arquitetura da rede neural.....	71
Figura 6.4 -	Comportamento do ajuste obtido com os modelos de regressão múltipla de Melo (2003) e RNA para todos os dados de todas as sub-bacias juntas.....	74
Figura 6.5 -	Correlação entre as vazões observadas e as calculadas pelos modelos de regressão múltipla de Melo (2003) e RNA na simulação de todos os dados disponíveis.....	75
Figura 6.6 -	Resultados da validação cruzada, aplicado aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro; (b) Aparecida; (c) Augusto Severo; (d) Emas; (e) Fazenda Angicos; (f) Mossoró; (g) Pau dos Ferros; (h) Pedra de Abelhas; (i) Piancó; (j) São Fernando; (k) Sítio Volta; (l) Upanema e (m) Serra Negra.....	78

Figura 6.7 -	Resultado da validação cruzada no ajuste com RNA e Regressão de Melo (2003) aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro, (b) Aparecida, (c) Augusto Severo, (d) Emas, (e) Fazenda Angicos, (f) Mossoró, (g) Pau dos Ferros, (h) Pedra de Abelhas, (i) Piancó, (j) São Fernando, (k) Sítio Volta, (l) Upanema e (m) Serra Negra.....	81
Figura 6.8 -	Correlação da validação para Serra Negra entre os resultados obtidos com o modelo de RNA e o de Melo extraídos os cinco primeiros anos de sua série de dados.....	86
Figura 6.9 -	Variação espacial das variáveis: (a) área de drenagem e (b) comprimento do rio principal.....	88
Figura 6.10 -	(a) Caso 1 – Ajuste na fase de validação, (b) Caso 1 - Correlação na fase de validação, (c) Caso 4 – ajuste na fase teste de parada e (d) Caso 4 – Correlação na fase teste de parada.....	89
Figura 6.11 -	(a) Caso 11 – Ajuste na fase teste de parada, (b) Caso 11 - Correlação na fase teste de parada, (c) Caso 11 – Ajuste na fase de validação e (d) Caso 11 - Correlação na fase de validação.....	90
Figura 6.12 -	(a) Variação da magnitude das áreas no caso 11 e (b) Variação da magnitude do comprimento dos rios no caso 11.....	91
Figura 6.13 -	(a) Caso 6 – Ajuste na fase teste de parada, (b) Caso 6 - Correlação na fase teste de parada, (c) Caso 6 – Ajuste na fase de validação e (d) Caso 6 - Correlação na fase de validação.....	92
Figura 6.14 -	(a) Variação da magnitude das áreas no caso 6 e (b) Variação da magnitude do comprimento dos rios no caso 6.....	93
Figura 6.15 -	(a) Variação da área para a combinação 1 da validação clássica e (b) variação do comprimento do rio para a combinação 1 da validação clássica.....	96
Figura 6.16 -	(a) Comportamento do modelo na calibração da combinação 1 para validação clássica (b) Correlação na calibração da combinação 1 da validação clássica (c) Comportamento do modelo na validação da combinação 1 para validação clássica e (d) Correlação na validação da combinação 1 da validação clássica.....	97
Figura 6.17 -	(a) Variação da área para a combinação 2 da validação clássica e (b) Variação do comprimento do rio para a combinação 2 da validação clássica.....	98

Figura 6.18 - (a) Comportamento do modelo na calibração da combinação 2 para validação clássica (b) Correlação na calibração da combinação 2 da validação clássica (c) Comportamento do modelo na validação da combinação 2 para validação clássica e (d) Correlação na validação da combinação 2 da validação clássica.....	98
Figura 6.19 - (a) Variação da área para a combinação 3 da validação clássica e (b) variação do comprimento do rio para a combinação 3 da validação clássica.....	100
Figura 6.20 - (a) Comportamento do modelo na calibração da combinação 3 para validação clássica, (b) Correlação na calibração da combinação 3 da validação clássica, (c) Comportamento do modelo na validação da combinação 3 para validação clássica e (d) Correlação na validação da combinação 3 da validação clássica.....	100
Figura 6.21 - Correlação entre a precipitação prevista pelo modelo RSM e a observada para os dados de todas sub-bacias juntas.....	103
Figura 6.22 - Comportamento do modelo RSM na previsão da precipitação sazonal para os dados de todas as sub-bacias juntas.....	103
Figura 6.23 - Resultado da previsão da vazão média diária sazonal com os modelos de RNA e Regressão Múltipla de Melo para as sub-bacias de: (a) Antenor Navarro, (b) Aparecida, (c) Pau dos Ferros, (d) Piancó, (e) São Fernando e (f) Sítio Volta.....	107
Figura 6.24 - Correlação existente no ajuste das vazões observadas às calculadas pelo modelo de RNA a ser regionalizado (todas as sub-bacias).....	110

## LISTA DE SÍMBOLOS

$\phi$	Conjunto de treinamento da rede neural
$P_{pc}$	Precipitação diária prevista corrigida
$\overline{P_o}$	Precipitação média diária observada (média móvel de 15 dias antes do evento atual e 15 dias depois entre todos os anos da série)
$\sigma_o$	Desvio padrão móvel de 30 dias da precipitação diária observada (15 dias antes do evento atual e 15 dias depois entre todos os anos da série)
$\sigma_s$	Desvio padrão móvel de 30 dias da precipitação simulada (15 dias antes do evento atual e 15 dias depois)
$P_s$	Precipitação simulada a ser corrigida (evento atual)
$\overline{P_s}$	Precipitação média móvel diária simulada (15 dias antes do evento atual e 15 dias depois)
$\overline{Q_{obs}}$	Vazão média diária sazonal observada para toda a série de dados do posto fluviométrico
$\overline{Q_{calc}}$	Vazão média diária sazonal calculada para toda a série de dados do posto fluviométrico
$Q_{calc}$	Vazão média diária sazonal calculada para um dado ano da série de dados
$\eta$	Taxa de aprendizado
$\mu$	Parâmetro introduzido para agilizar o processo da convergência
$\theta_j$	Limiar do neurônio j
$\delta_j$	Gradiente local no neurônio j
$\Delta w_{ij}$	Correção dos pesos entre os neurônios i e j
$A$	Área de drenagem da bacia hidrográfica
$Dd$	Densidade de drenagem
$S$	Declividade média do rio principal
$D_n$	Conjunto dos $p$ exemplos de saídas desejáveis apresentados à RNA

$e_i$	Erro chegado até o neurônio $i$
$E_k$	Erro total cometido pela rede na saída dos neurônios da última camada $k$
$F(.)$	Função de ativação do neurônio
$I$	Matriz identidade
$J$	Número de neurônios na camada de saída
$J(.)$	Matriz jacobiana da derivada parcial do erro cometido em relação aos pesos
$K$	Número de camadas da rede neural
$L$	Comprimento do rio principal da bacia hidrográfica
$n_j$	Integração das informações ponderadas pelos pesos advindas do neurônio $i$ para o $j$
$p$	Número de pares de padrões para o treinamento
$P$	Precipitação média sazonal
$Q$	Vazão média diária sazonal
$Q_{obs}$	Vazão média diária sazonal observada para um dado ano da série de dados
$R^2$	Coefficiente de determinação
$U(.)$	Função geral custo (erro quadrático) do algoritmo LM para os neurônios da camada de saída.
$u_j$	Resíduo (erro) chegado até o neurônio $j$
$W$	Vetor de pesos de uma rede neural artificial
$w_{ij}$	Peso (parâmetro) entre o neurônio $i$ e o neurônio $j$
$x_i (i=1,2,3,\dots,p)$	Representam as $p$ entradas do sistema
$X_n$	Conjunto das $p$ entradas (dados) apto a treinarem a rede neural
$y_i$	Saída (resposta) do neurônio $i$
$\beta$	Fator de treinamento

## 1. INTRODUÇÃO

Há tempos o homem busca o adequado conhecimento dos processos hidrológicos para retirar deles o melhor aproveitamento. Estes, por sua vez, se apresentam na natureza de forma complexa, dificultando a sua quantificação e, mais ainda, a sua previsão. No entanto, ultimamente, consideráveis avanços têm-se observado nos esforços dirigidos ao entendimento das variáveis condicionantes da precipitação, principal variável climatológica explicativa da vazão. Os Modelos de Circulação Global aparecem hoje como a principal ferramenta na busca da simulação deste processo na natureza.

Segundo Galvão *et al.* (2003), nas regiões tropicais, os mecanismos oceânicos e atmosféricos que determinam a maior parte da variabilidade climática interanual já estão razoavelmente caracterizados, dando origem a diversos métodos de previsão da precipitação sazonal. Porém, apesar de todo progresso, muito ainda precisa ser feito para se ter maior confiabilidade e segurança na tomada de decisão; pois, infelizmente, ainda tem-se um elevado grau de incerteza associada à previsibilidade, especialmente por haver diferenças na escala temporal e espacial entre os processos climatológicos sazonais e os hidrológicos.

A região nordeste do Brasil vem recebendo a contribuição de vários pesquisadores na linha da previsão meteorológica, estando estas informações disponíveis para o público. Um exemplo de tais resultados de modelagem climática regional pode ser encontrado no trabalho de Nobre *et al.* (2001) para a Região Nordeste do Brasil. A maioria dos métodos empregados produzem previsões de um a três meses antes da estação chuvosa e se referem a todo o período chuvoso (3 ou 4 meses) e a toda a região. A previsão é anunciada pela primeira vez em novembro ou dezembro para o período de fevereiro a maio, a partir da situação dos preditores naquele momento, e a seguir, atualizada mensalmente até o início de fevereiro.

A falta de dados hidrométricos, em quantidade e cobertura adequada, tanto na escala espacial quanto temporal, é uma realidade, traduzindo-se numa das principais dificuldades em

recursos hídricos, e isso nada mais é do que um reflexo da precária cobertura das redes de postos fluviométricos existentes no nosso país, tornando-se mais agravante quando ocorrem em bacias de açudes, que necessitam de um monitoramento contínuo, visto a sua importância, seja no abastecimento, geração de energia, etc. Para sanar tal problema, é usualmente indicada a regionalização hidrológica de variáveis, como a vazão, já que tal técnica explora, de forma espacial, as variáveis que interferem na determinação da vazão em diferentes locais de uma região hidrológicamente homogênea, permitindo, com isso, a extrapolação dessa informação para locais onde não se dispõe.

Com isso, pensou-se em viabilizar um método que consiga, com alguma antecedência, prever a vazão média diária sazonal (média das vazões diárias durante a estação chuvosa) em bacias hidrográficas, assim, uma vez determinado o modelo de regionalização formulado a partir das variáveis explicativas da vazão, como a precipitação e as características físicas das bacias, como área de drenagem, comprimento do rio principal, declividade média etc, este poderá ser utilizado para prever a vazão média diária sazonal em qualquer local inserido na região para o qual foi desenvolvido, possibilitando, com isso, a sua aplicabilidade em locais sem dados hidrométricos disponíveis e, contribuindo para uma maior integração regional entre as bacias. Assim, a partir das precipitações previstas pelos meteorologistas, pode-se, antecipadamente, prever a vazão nas bacias em questão e, com base nisso, ter subsídios para tomadas de decisões sobre medidas preventivas contra eventos extremos, como cheias e secas, minimizando os efeitos negativos destes.

Acreditando na evolução destas técnicas preventivas, este trabalho, entre outras coisas, busca contribuir para a previsão regional das vazões sazonais e, com isso, poder quantificar ou mesmo prever o volume escoado que poderá, efetivamente, ser disponibilizado à população após uma dada estação chuvosa, traduzindo-se numa informação importante para o gerenciamento dos recursos hídricos.

Muito se tem feito para o entendimento dos processos da transformação chuva-vazão na bacia hidrográfica, tendo em vista a importância dessa informação, seja para projetos de engenharia ou mesmo para o gerenciamento. Modelos analíticos têm sido desenvolvidos com o intuito de se estimar o escoamento superficial. Contudo, devido à complexidade desses processos hidrológicos, tais modelos deixam a desejar, pois são fundamentados em simplificações.

O uso de redes neurais para a previsão de dados hidrológicos, vazão e precipitação, nos seus mais diferentes usos, é hoje uma área bastante promissora (Galvão e Trigo, 1999). Assim, tendo em

vista os recentes êxitos nas aplicações desta técnica empírica na modelagem de sistemas que envolvam entradas e saídas de variáveis temporais complexas, espera-se uma boa adequação desta na simulação dos processos hidrológicos na bacia. Por outro lado, como Redes Neurais Artificiais (RNAs) permitem, na sua calibração, a absorção de aspectos variados de uma mesma zona hidrológica, como as características físicas das sub-bacias ou mesmo da distribuição espacial da precipitação, faz-se viável a implementação da regionalização da vazão a esta técnica.

Assim, o objetivo deste estudo é, fazendo uso das técnicas de regionalização, buscar um modelo baseado nas técnicas de Redes Neurais Artificiais que sirva para simular e prever as vazões médias diárias sazonais a partir de dados previstos para a precipitação sazonal e das características físicas da bacia, servindo para aplicação em locais, na bacia, com pouco ou nenhum dado hidrométrico disponível.

Este trabalho busca obter avanços com relação ao trabalho de Melo (2003), que usou, com o mesmo fim, a técnica de regressão múltipla e demonstrou, no seu trabalho, ser esta uma metodologia bastante promissora. As bacias dos rios Piranhas-Açu e Apodi são usadas como caso de estudo neste trabalho, assim como foram para o trabalho de Melo (2003).

Assim sendo, os objetivos específicos deste trabalho são:

- i- Desenvolver um modelo de previsão da vazão sazonal que relacione esta variável hidrológica à variável causadora, precipitação prevista, bem como, às características físicas da bacia que melhor expliquem a vazão;
- ii- Calibrar e validar o modelo, avaliando-se o seu desempenho na simulação da transformação chuva-vazão;
- iii- Comparar os resultados obtidos com o modelo em questão com os de outro modelo já desenvolvido para a região em estudo anterior por Melo (2003);
- iv- Avaliar as incertezas implícitas ao modelo na geração de previsões de vazões médias diárias sazonais.

## 2. REVISÃO DE LITERATURA

### 2.1. REGIONALIZAÇÃO HIDROLÓGICA

Segundo Tucci (2002), o termo regionalização tem sido utilizado em hidrologia para determinar a transferência de informações de um local para outro dentro de uma área com comportamento hidrológico semelhante. Para isso, faz-se uso de um conjunto de ferramentas capaz de extrair, ao máximo, as informações necessárias de uma região, com homogeneidade hidrológica, para preenchimento das lacunas ou suprimento de dados em determinados locais da bacia, porventura deficitários, estimando as variáveis hidrológicas desejáveis para toda a região hidrologicamente similar à estudada.

As principais variáveis hidrológicas no manejo dos recursos hídricos são: a precipitação e a vazão. A primeira é medida através de pluviômetros, que registram a entrada pontual num processo espacial da bacia hidrográfica, enquanto que a vazão é quantificada através de postos fluviométricos localizados em seções do rio, e representa a integração espacial da saída do sistema, como escoamento na bacia hidrográfica. A densidade de uma rede hidrométrica, na realidade, devido às dimensões espaciais das bacias hidrográficas e até mesmo ao comportamento estocástico das variáveis hidrológicas, dificilmente atenderá a toda região hidrográfica. Sendo assim, invariavelmente, existirão áreas desprovidas de dados e/ou séries temporalmente descontínuas, que poderão ser supridas pelas técnicas desenvolvidas para a regionalização.

As características físicas e climáticas das bacias, que melhor se relacionem no processo da transformação da chuva em vazão, devem ser consideradas num estudo de regionalização, porém, para que seja viável, estas devem ser de fácil obtenção.

As metodologias aplicadas à regionalização são variadas, podendo seguir vários métodos que a possibilitem. Segundo Tucci (1993), existem três classes de métodos utilizados na regionalização, são eles:

- (i) **Métodos que regionalizam os parâmetros da distribuição de probabilidades:** Neste caso, é ajustada uma distribuição estatística às frequências dos dados das diferentes bacias pertencentes à região estudada;
- (ii) **Métodos que regionalizam o evento com um determinado risco:** Neste caso, são ajustadas distribuições às vazões de diferentes postos. Assim, a vazão de interesse, associada a um determinado tempo de retorno, poderá ser obtida a partir das distribuições ajustadas a cada posto.
- (iii) **Métodos que regionalizam uma curva adimensional de probabilidades, denominado de método da cheia-índice ou index-flood:** Neste caso, adimensionaliza-se as curvas individuais de probabilidade com base no seu valor médio, estabelecendo uma curva adimensional regional média dos postos com a mesma tendência.

Em qualquer dos métodos de regionalização é necessária à delimitação de regiões hidrológica e estatisticamente homogêneas, cujas estações tenham séries oriundas de populações regidas pela mesma distribuição de probabilidades e apenas seus parâmetros variando entre as estações (Silva e Araújo, 2002).

Comumente, os estudos de regionalização são direcionados para vazões máximas, mínimas e médias de longo período, onde o estabelecimento da vazão média de longo período reflete uma estimativa da potencialidade hídrica da bacia hidrográfica. O interesse das vazões máximas de longo período se faz no dimensionamento de obras hidráulicas. No caso das vazões mínimas, seu estabelecimento é importante para a estimativa da disponibilidade natural dos rios nos períodos críticos, estação seca, permitindo o estabelecimento da regularização artificial dos cursos d'água, visando, inclusive, a manutenção da vida aquática.

Moreira *et al.* (2002) promoveram um estudo de regionalização na sub-bacia 39 pertencente ao nordeste brasileiro. Neste estudo, foi proposta a regionalização da distribuição estatística de probabilidades das vazões máximas, mínimas e médias de longo período. Através desse estudo, os autores puderam identificar regiões de comportamento hidrológico homogêneo e definiram equações que permitem uma avaliação do regime hidrológico, sua potencialidade hídrica e seus limites de variação, também possibilitam estimar a probabilidade de ocorrência de eventos críticos em cada uma das regiões estudadas.

Medeiros *et al.* (2002) realizaram uma pesquisa, tendo como caso de estudo a bacia do rio Apodi, no Rio Grande do Norte, com o objetivo de introduzir o conceito de diferentes garantias

associadas ao atendimento da demanda na regionalização da curva de regularização e buscaram avaliar a metodologia simplificada apresentada por Tucci (1993) para considerar a evaporação na extrapolação da mesma. De acordo com a metodologia simplificada, a evaporação pode ser considerada como uma demanda adicional do reservatório e pode ser estimada considerando-se uma área correspondente a  $2/3$  da área máxima do espelho d'água do reservatório e a evaporação média anual da região, assim, pode-se regionalizar, através de análise de regressão, a evaporação em função da área máxima do espelho d'água no reservatório. No entanto, segundo os autores, a metodologia simplificada tende a superestimar as perdas por evaporação. Porém, esta metodologia carece de uma maior investigação, pois foi aplicada a um número reduzido de reservatórios,

Tavares *et al.* (2002) propuseram um estudo nas bacias dos rios Jucuruçu, Mucuri e São Mateus, pertencentes aos estados da Bahia, Espírito Santos e Minas, visando a otimização da rede fluviométrica, com base nos estudos de regionalização de vazões médias anuais, máximas anuais e mínimas anuais de diversas durações. A metodologia utilizada foi a que regionaliza as curvas adimensionais de probabilidade e o fator de adimensionalidade. Os autores afirmam que, através da análise dos limites das diversas regiões homogêneas e dos desvios calculados entre os valores observados e calculados pela equação de regressão, foi possível indicar as áreas nas quais necessitam da instalação de novas estações.

Freitas *et al.* (2002) realizaram a regionalização das vazões mínimas, máximas e médias de longo período, bem como análise da curva de permanência das vazões no tempo nas bacias 46, 47, 48 e 49 da Bacia do Rio São Francisco. Na elaboração das equações usadas para a regionalização, levou-se em conta aspectos fisiográficos e climáticos. Da mesma forma, Elesbon *et al.* (2002) também realizaram a regionalização das vazões mínimas, máximas e médias de longo período no Estado do Espírito Santo, porém, neste trabalho buscou-se a integração da regionalização em Sistemas de Informação Geográficas (SIGs) no processo de automatização dessas informações.

Lanna, *et al.* (1983), realizaram uma análise estatística regional de vazões mínimas com 1 a 7 dias de duração através de curvas adimensionais de frequência para três regiões da bacia do rio Jacuí. Segundo os autores, os resultados se mostraram consistentes na estimativa de vazões mínimas até a ordem de 15 dias de duração e tempo de retorno até cerca de 50 anos.

Góes e Campana (2001) desenvolveram um modelo que incorpora as variáveis que retratam a dinâmica das modificações no uso do solo para a regionalização de vazões, utilizando-se técnicas

de geoprocessamento, com vista à determinação de vazões mínimas, máximas e médias para bacia hidrográfica.

Cirilo *et al.* (1992) realizaram a regionalização de parâmetros de modelos hidrológicos, aplicados em bacias hidrográficas do estado de Pernambuco, visando à aplicação desses modelos em bacias sem dados fluviométricos.

Diniz e Clarke (2001) afirmam que, após a calibração de um modelo de geração de vazão, a principal decisão a ser tomada será a escolha de outra região onde se possa aplicar o conjunto de parâmetros deste modelo. O procedimento bastante utilizado atualmente, nesse sentido, segundo os autores, é o da similaridade hidrológica entre bacias hidrográficas. Contudo, ainda segundo os autores, a extrapolação do modelo para outras regiões ainda é feita sob severas limitações.

A regionalização é estabelecida com o objetivo de se obter a informação hidrológica em locais sem dados ou com poucos dados. O princípio de regionalização se baseia na similaridade espacial de algumas funções, variáveis e parâmetros que permitem essa transferência (Tucci, 2002). Como consequência da implementação dos sistemas estaduais e federal de gerenciamento de recursos hídricos e da escassez de dados obtidos através de medições em campo, cresce no Brasil a necessidade de se desenvolver métodos eficientes de regionalização hidrológica. Até alguns anos atrás os projetos de novas obras hidráulicas se constituíam a principal motivação para a regionalização hidrológica, mas, com os enfoques mais recentes de valorização do gerenciamento da água, o próprio gerenciamento assumiu relevante importância no cenário da hidrologia no Brasil (Diniz e Clarke, 2001).

Nesse sentido, RNA surge como uma metodologia útil na regionalização da vazão, uma vez que, considera aspectos diversos das sub-bacias contidas numa região de interesse, como: área de drenagem; comprimento do rio principal; declividade média do rio, pluviometria, etc. Por outro lado, também, levando-se em conta a não linearidade do processo de transformação da chuva em vazão, as redes neurais, composta por funções não lineares, revelam-se numa alternativa eficaz, sendo altamente recomendadas em estudos que envolvam relações complexas de entrada e saída, tendo, por isso, alcançado bons resultados na modelagem dos processos hidrológicos.

A principal vantagem do uso da técnica de RNA é o fato dela não requerer conhecimentos explícitos da bacia, dispensando-se uma análise teórica dos processos implícitos do ciclo hidrológico. No entanto, deve-se ressaltar que tal vantagem pode, eventualmente, se reverter numa

desvantagem, uma vez que, trata-se de um modelo do tipo caixa-preta, ou seja, não se pode conhecer os motivos pelos quais levaram tal modelo a um certo resultado, podendo-se chegar a resultados inconsistentes. Apenas o bom senso do hidrólogo poderá reparar as falhas de um modelo como o de RNA.

## 2.2. APLICAÇÕES DE RNA EM RECURSOS HÍDRICOS

Ultimamente a aplicação do método empírico de Redes Neurais Artificiais tem obtido resultados animadores em diversos campos do conhecimento, inclusive como método eficaz no tratamento de variáveis temporais complexas, como no caso das variáveis hidrológicas chuva e vazão. Porém, seu emprego ainda é escasso, pois se trata de uma ferramenta relativamente recente, e vem ganhando credibilidade a ponto de concorrer ou ser compatível com métodos mais tradicionais, como no caso da regressão múltipla, que segundo Gardner e Dorling (1998), as RNAs têm uma grande vantagem sobre as demais técnicas estatística pelo fato de não precisar de suposições iniciais sobre a distribuição estatística dos dados. Suas recentes aplicações na hidrologia têm-se mostrado particularmente efetiva na transformação chuva-vazão e, conforme Favoreto *et al.* (2001), uma das áreas promissoras para grande aplicabilidade das RNAs é na previsão de dados hidrológicos, vazão e precipitação, nos seus mais diferentes usos. Baseado nisso, julgou-se o método de redes neurais artificiais como apropriado para o desenvolvimento desta dissertação.

Neste tópico, são apresentadas algumas aplicações de RNAs, em recursos hídricos, a temas gerais, na previsão de séries temporais e, finalmente, na regionalização hidrológica.

As RNAs têm sido utilizadas com sucesso para modelar relações envolvendo séries temporais complexas de entrada e saída em várias áreas (Vemuri, 1994).

Muller e Fill (2003) verificaram o comportamento de um modelo de RNA na propagação de vazões em rios. O caso de estudo foi o rio Iguaçu, entre Fluiópolis e União da Vitória. Neste estudo, foi criada uma rede *perceptron* multicamadas do tipo 2-8-8-8-1, onde, na primeira camada tinham-se dois neurônios, um responsável pela informação da vazão em Fluiópolis e o outro pelo incremento de vazão; depois, mais três camadas escondidas, cada uma com oito neurônios com funções de ativação do tipo sigmóide logística e, finalmente, na última camada, o neurônio de saída, responsável pela resposta da propagação da vazão para União da Vitória. Os autores concluíram que o método era promissor, pois, apesar do mesmo tratar-se de uma técnica puramente matemática,

onde não se levava em conta a teoria intrínseca do problema, tal método obteve resultados animadores.

Nayak *et al.* (2003) realizaram um estudo intitulado “*A neuro-fuzzy computing technique for hydrological time series*”, trabalho este que objetivou a integração das técnicas de RNAs às de lógica difusa para a modelagem do escoamento no rio Baitarani no Estado de Orissa na Índia. A pesquisa obteve bons resultados; segundo os autores, já que a vazão simulada com o modelo desenvolvido acompanhara o comportamento histórico da série e suas características estatísticas. Eles ressaltaram também o aumento da facilidade no processo de modelar e concluíram afirmando haver viabilidade de tal técnica na modelagem de vazões em rios.

Ramos e Galvão (2001) aplicaram as técnicas de redes neurais a um problema de modelagem hidrometeorológica de desagregação espacial da chuva, com o objetivo de avaliar a estabilidade oferecida pelo método. Os autores concluíram que o modelo apesar de poder fornecer bons resultados na fase de calibração, oferecendo altos coeficientes de correlação, o mesmo bom desempenho pode não acontecer na fase de validação. Os autores aconselharam, no uso dessa técnica, certos cuidados, como por exemplo, o de evitar ao máximo o excesso de parâmetros numa rede, motivo pelo qual ocorre o superajustamento. Indicaram a importância de se realizar um pré-processamento dos dados de entrada da rede neural antes de utilizá-los na calibração, bem como, a necessidade de se atribuir critérios de estabilidade para a escolha da melhor rede.

Rohn e Mine (2003) aplicaram as técnicas de redes neurais na previsão de precipitações de curtíssimo prazo. As autoras propuseram um modelo de RNA que possuía seis neurônios na camada de entrada, referente às seis estações pluviométricas adjacentes à de interesse. As informações provenientes das estações adjacentes alimentavam a rede; estas informações de precipitações tinham uma defasagem no tempo de 15 min., relativo ao tempo de previsão do modelo, ou seja, a rede era informada sobre as condições presentes de chuva existente nas seis estações adjacentes para, então, ter condições de prever a precipitação depois de 15 min. na estação de interesse, que era representada pelo neurônio de saída. A conclusão deste trabalho foi que, o modelo não obteve resultados satisfatórios e observaram que as previsões giraram em torno de um valor médio sendo incapaz de simular os picos dos eventos. As autoras justificaram a deficiência do modelo e atribuíram à variabilidade das precipitações, que impediu que a rede reconhecesse as características relevantes nos eventos observados e afirmaram que os dados não possuíam um padrão bem identificado para que a rede neural retirasse relações e aprendesse adequadamente. Finalmente, as

autoras afirmaram que redes neurais não são técnicas milagrosas e que não podem oferecer bons resultados se os dados de entrada não propiciam um aprendizado adequado.

“As pesquisas com redes neurais artificiais tentam simular o cérebro humano, principalmente a sua capacidade de aprender e se adaptar a eventuais mudanças por meio de exemplos. Assim, as RNAs podem executar tarefas que os programas convencionais não conseguem realizar, pois não têm essa característica de aprendizagem e adaptabilidade. Os dados de níveis de um rio são registrados num linígrafo. Analisar e prever eventos futuros, fundamentados nesses registros é uma tarefa difícil, porque, várias variáveis como chuva, infiltração e características do solo influenciam na altura do rio de uma maneira não linear.” (Santos, 2001).

Olívio *et al.* (2002) aplicaram as técnicas de redes neurais artificiais ao problema de previsão de cheias fluviais, o tipo de rede neural escolhido foi a *perceptron* de múltiplas camadas e o algoritmo de treinamento usado no estudo foi o da retropropagação do erro. Foi apresentado à rede, como padrão de entrada, o nível do rio a montante de uma seção de interesse e esperou-se uma resposta adequada, da rede neural, com relação ao nível do rio nessa mesma seção de interesse. Este estudo faz parte de uma seqüência de outros estudos com o mesmo propósito, onde se pretende chegar ao melhor tipo e arquitetura da rede e aos melhores padrões de entrada, para um melhor reconhecimento do problema. O interesse inicial, desse estudo, foi a previsão de níveis fluvimétricos para 4, 6, 8 e 10 horas de antecedências, contudo, apenas a previsão para 4 horas de antecedência obteve resultados satisfatórios. Os autores concluíram que, redes neurais se prestam para a previsão de cheias e que os resultados poderiam melhorar caso fossem utilizados dados de entrada mais apropriados.

O setor elétrico é o maior responsável pelo gerenciamento dos grandes reservatórios brasileiros; pois, a energia elétrica em nosso país é oriunda, em sua grande parte, do potencial hidroelétrico destes. Portanto, faz-se imprescindível a boa previsão de vazão para garantir a devida operacionalidade destes reservatórios, com vista à diminuição de prejuízos sociais, políticos e econômicos. Até recentemente, para a previsão de vazões, o Setor Elétrico Brasileiro fazia uso dos modelos estocásticos para análise de séries temporais, com ênfase na metodologia de Box e Jenkins (1976).

Ballini *et al.* (1997) trabalharam com o modelo de RNA com o objetivo de prever vazão média mensal e compararam os resultados com os do modelo de Box & Jenkins. As séries históricas temporais foram retiradas das usinas de Furnas, Itumbiara e Sobradinho. A rede neural usada foi do

tipo múltiplas camadas e o algoritmo de treinamento adotado foi o da retropropagação do erro. Eles formularam a pesquisa em duas abordagens, na primeira, a série temporal original foi convertida em uma série padronizada, removendo-se a média e o desvio-padrão sazonal. Com isso, foi possível explorar a estrutura das funções de autocorrelação e autocorrelação parcial da série padronizada para determinação das entradas da rede. Na segunda, exploraram a estrutura das funções de autocorrelação e autocorrelação parcial da série original para posterior definição das entradas. Assim, segundo os autores, pode-se treinar a rede para que essa também aprendesse a sazonalidade supostamente estocástica. Os autores fizeram uma observação, advinda da pesquisa, destacando a importância da padronização da série e mostraram as vantagens ao se utilizar redes neurais quando essa padronização não é realizada. Com tudo, a ressalva que se faz é que o desempenho das redes neurais é sempre afetado por fatores como: topologia das redes; parâmetros de treinamento e natureza das séries temporais.

Muitos pesquisadores vêm tentando aperfeiçoar modelos e técnicas na tentativa de se antecipar aos eventos naturais. As previsões quantitativas de chuvas podem se tornar numa informação indispensável aos gerenciadores de bacias hidrográficas e, em particular, de combate a enchentes, se idealizam sistemas de alertas que possam orientar a defesa civil quanto à antecipação de eventos que potencializem enchentes ou devastações. Contudo, as dificuldades são extremas, devido à alta variabilidade das escalas temporal e espacial e a não-linearidades das variáveis que descrevem o processo natural da precipitação.

Almeida e Barbosa (2004) associaram um modelo de previsão baseado nas técnicas de redes neurais à teoria dos *Runs*, com o objetivo de conhecer a previsão da vazão para um horizonte de cinco dias. A rede neural possuía na camada de entrada onze neurônios, que representavam as condições antecedentes da bacia hidrográfica dos últimos cinco dias referentes à vazão e à precipitação e mais uma variável de entrada referente ao total previsto de precipitação para os próximos cinco dias. Na camada de saída, estava o neurônio responsável pela correspondente previsão da vazão média para os próximos cinco dias. O algoritmo de treinamento, usado pelos autores, nesse trabalho, foi o do gradiente conjugado escalonado que utilizam as informações de segunda ordem (matriz Hessiana). Os autores concluíram o trabalho afirmando que os resultados foram satisfatórios na previsão de vazão média diária para um horizonte de cinco dias ( $Q_5$  dias) e que tal técnica auxilia na identificação de um possível início de evento de seca hidrológica e de que, com um acompanhamento diário é possível se detectar a evolução dos déficits e a indicação do possível término do evento dentro de intervalos de tempo de cinco dias de duração.

Santos (2001) utilizou o conceito de redes neurais na modelagem hidrológica de bacias urbanas com dados de telemetria na previsão de vazão. Seus resultados se mostraram satisfatórios na previsão com RNAs, através dos dados de radar, com até 90 min. de antecedência. Ela comenta, em seu trabalho de dissertação, que os modelos envolvendo RNAs oferecem a vantagem de não requererem um conhecimento explícito da bacia estudada e têm apresentado bons resultados na modelagem de processos hidrológicos de transformação de chuva em vazão, e que devido a isso, essa técnica deva ser utilizada nesse contexto, especialmente nos casos onde os conhecimentos dos processos hidrológicos sejam muito limitados.

Sarmiento (1996) realizou uma análise relacionando a arquitetura da rede neural em função do problema a ser tratado. O objetivo é mostrar a possibilidade do uso das técnicas de RNA na modelagem de variáveis hidrológicas. Para isso, foram mostrados dois exemplos: (a) simulação da relação chuva-vazão mensal em uma bacia da região semi-árida do Nordeste e (b) na previsão de vazões médias diárias com intervalos de 1 e 2 dias do rio Leine, localizado na região central da Alemanha. Sarmiento termina concluindo que o uso das RNAs deve ser indicado nas modelagens dos fenômenos naturais em casos que não se tenha uma formulação matemática explícita que traduza as relações entre as diversas variáveis envolvidas. Finalmente, uma outra observação feita foi quanto à extensão da série histórica requerida para o treinamento da RNA na transformação chuva-vazão em regiões semi-áridas, que devem ser bastante superiores àquelas advindas de bacias de rios perenes.

Barp e Barbosa (1999) compararam o modelo hidrológico conceitual chuva-vazão SMAP, em sua versão mensal, com modelos desenvolvidos através das técnicas de redes neurais artificiais. Foram trabalhados três casos diferentes. No primeiro caso, investigou-se o potencial individual de cada modelo na geração da vazão, com o SMAP sendo calibrado de forma manual e automática, através de um método de otimização de primeira ordem; e o modelo de RNA, do tipo *perceptron* de múltiplas camadas, com um algoritmo de treinamento de segunda ordem utilizado por Von Zuben (1996) e desenvolvido por Moller (1993) e denominado de *método do gradiente conjugado escalonado*. Segundo os autores, este método mostrou-se superior ao método de retropropagação do erro, que possui um algoritmo de otimização de primeira ordem. Foram escolhidas duas estruturas de rede neural, uma com um neurônio na camada de entrada, onde se apresentava a variável precipitação como dado de entrada, sete neurônios na camada escondida e um neurônio na camada de saída, responsável pela resposta do modelo para definição da vazão mensal, sendo portando, uma rede do tipo 1-7-1; a segunda estrutura de rede possuía dez neurônios na camada escondida, tendo a

estrutura 1-10-1. No segundo e terceiro caso, trabalhou-se com o modelo de redes neurais acoplado ao modelo SMAP para a geração da vazão, com o objetivo de substituição dos parâmetros do modelo conceitual através da implementação de RNAs. Assim, tinham-se, para uma segunda situação, as vazões superficiais e a de base, obtidos pelo modelo SMAP, como padrões de entrada da rede, tendo, portanto, a estrutura do tipo 2-7-1 e 2-10-1. Na terceira versão, a rede neural recebia, como padrão de entrada, os volumes armazenados nos reservatórios solo e subterrâneos, também obtidos através do modelo conceitual SMAP. Os autores fizeram uso de métodos estatísticos dos resíduos para comparação entre os três casos citados, como o erro padrão de estimativa, erro percentual de volume, erro percentual de vazão máxima e correlação. Segundo os autores, o modelo de redes neurais que tem como entrada a precipitação e saída a vazão mensal (caso 1), apresentou desempenho próximo ao do SMAP calibrado manualmente. Porém, quando as entradas do modelo de redes neurais foram as variáveis que já incorporavam processos hidrológicos, advindas do modelo conceitual SMAP (casos 2 e 3), observou-se consideráveis melhorias nos resultados, mostrando-se sempre superior ao modelo conceitual quando esse trabalha de forma isolada. Os autores concluíram, afirmando, que a técnica de redes neurais artificiais é um campo promissor para a modelagem da transformação chuva-vazão em bacias hidrográficas.

Valença (1997) realizou um estudo avaliando a aplicação de redes neurais perceptron multicamadas em recursos hídricos, com ênfase ao processo de transformação chuva em vazão, comparando os resultados, neste caso, com os dos modelos conceituais MOHTSA e SMAP e na previsão de vazão média mensal com os dos modelos de regressão e Box-Jenkins. Segundo o autor, a comparação dos resultados obtidos entre os modelos tradicionais e os da rede neural para a modelagem chuva-vazão foram de ótima qualidade, destacando a grande vantagem da versatilidade desse último método, devido à sua não-linearidade e de permitir, no processo chuva versus vazão, incorporar a representatividade de cada posto pluviométrico, ao invés de se trabalhar apenas com a chuva média. O autor destaca, também, a vantagem do uso de RNA em permitir a regionalização quando se levam em consideração aspectos diversos das bacias, como: área de drenagem, declividade, pluviometria média, coeficientes de forma da bacia, tipo de solo, etc. No que diz respeito à previsão de vazão média mensal, a técnica de redes neurais obteve, mais uma vez, excelentes resultados e o autor, ainda, completa afirmando que, já era de se esperar pelo fato de redes neurais terem em sua essência potentes modelos não lineares que incorporam os de regressão e Box-Jenkins.

Cannon e Whitfield (2002) utilizaram uma rede neural do tipo *Perceptron Multi Layer* na modelagem da vazão diária numa bacia canadense. Para isso, eles relacionaram as vazões de 21 estações fluviométricas com os dados de temperatura e precipitação correspondente ao período estudado.

Khalil *et al.* (2001) desenvolveram um modelo baseado nas técnicas de redes neurais capaz de preencher as lacunas de dados hidrológicos existentes nas séries históricas, para isso, foram usadas duas abordagens distintas: (a) o preenchimento das falhas foi obtido a partir da própria série estudada, e nesse caso a vazão atual era função da vazão anterior; ou (b) preenchimento das falhas baseado nas séries dos postos vizinhos, ou seja, os neurônios eram compostos pelas séries dos postos vizinhos. Em ambos os casos a função de ativação utilizada foi a sigmóide.

Diniz e Clarke (2001) apresentaram um estudo, para quatorze bacias da região do semi-árido nordestino, que objetivou a utilização das técnicas de redes neurais artificiais na regionalização dos parâmetros do modelo conceitual chuva-vazão SMAP mensal, com base nas características físicas e climáticas mais relevantes das bacias hidrográficas. Num primeiro momento, os autores obtiveram os parâmetros, calibrando o modelo SMAP para cada bacia. Posteriormente, foi realizada a regionalização desses parâmetros por meio da rede neural. A RNA foi do tipo multicamadas, sendo formada por quatro camadas, tendo uma camada de entrada, duas intermediárias e uma de saída. Na primeira camada, tinham-se seis neurônios, cada um responsável pela recepção de uma informação característica das bacias (área, altitude média, desnível específico, precipitação média anual, evaporação média anual e permeabilidade média do solo). Cada camada intermediária foi composta por doze neurônios com funções sigmóides. A camada de saída era composta por seis neurônios que representavam os parâmetros do modelo SMAP (capacidade de saturação, coeficiente de infiltração, coeficiente de descarga, constante de deplecionamento do reservatório subterrâneo e os parâmetros de escoamento). Foi adotada a validação cruzada na avaliação do desempenho da rede neural, onde se faziam uso de treze sub-bacias para o treinamento da rede e foi obtido o conjunto de parâmetros, o qual foi introduzido no modelo conceitual para simulação da vazão na bacia omitida durante a fase de treinamento, comparando-se o desempenho do modelo SMAP agindo individualmente na simulação da vazão e depois integrado ao modelo de RNA, este procedimento foi repetido quatorze vezes. Segundo os autores, esta técnica obteve resultados bons para algumas bacias; porém, ruim para outras, provavelmente devido às bacias não estarem dentro de uma mesma zona hidrologicamente homogênea.

No trabalho realizado por Freitas (2003), um dos objetivos de sua pesquisa foi o de analisar a aplicação de Redes Neurais Artificiais como uma ferramenta de regionalização e comparar esta com métodos estatísticos usuais. Foram estudadas as sub-bacias 46, 47,48 e 49 da Bacia Hidrográfica do São Francisco. Para isso, foram utilizados dois modelos de RNA para a regionalização da vazão média. No primeiro, os parâmetros utilizados foram a área e os percentuais de solos classificados quanto às características hidrológicas; no segundo, os padrões de entrada foram a área de drenagem, comprimento do rio principal, declividade do rio principal, densidade de drenagem, desnível específico, precipitação total anual e precipitação máxima diária. Em ambos os casos, a autora dividiu os dados em dois grupos, um de vazões de menores magnitudes e outro de vazões de grandes magnitudes. Os modelos eram calibrados através dos dados de dez estações fluviométricas, e validados, normalmente, em cinco estações para o grupo (I) e em quatro para o grupo (II) de cada caso. A arquitetura da rede variou de acordo com cada caso e grupo analisado, para o primeiro caso, as redes tiveram as arquiteturas 5-2-1 e 5-3-2-1 para os grupos (I) e (II), respectivamente, e, para o segundo caso, 7-2-1 e 7-3-1 também para os grupos (I) e (II), respectivamente. Para todas as estruturas foram empregadas funções de ativação gaussiana na camada intermediária e na camada de saída a sigmóide. Segundo a autora, de forma geral, na comparação entre as técnicas estatísticas tradicionais e a de RNA, esta última conduziu a melhorias dos índices estatísticos, resultando num maior grau de liberdade dos modelos, o que, os torna mais consistentes. A autora ainda conclui que, tais modelos apresentam bom potencial para a regionalização de vazões em áreas com escassez de dados.

### **2.3. VANTAGENS E DESVANTAGENS DAS RNAs**

Como para qualquer modelo matemático que busca a representação dos fenômenos naturais, as RNAs apresentam consigo uma série de vantagens e desvantagens na sua utilização. Abaixo se apresentam algumas destas vantagens e desvantagens compiladas e adaptadas de texto encontrado no site da internet: [www.univ.com.br/acnm/Redes/~RN-INDEX.htm](http://www.univ.com.br/acnm/Redes/~RN-INDEX.htm), em novembro de 2004.

As principais vantagens na aplicação de redes neurais são:

- a) Qualidade superior: as análises realizadas através das técnicas de redes neurais são superiores às conseguidas através de técnicas estatísticas;

- b) Auto-aprendizado: na tomada de decisão, as RNAs não necessitam de conhecimentos de especialistas, elas se baseiam apenas nos conhecimentos adquiridos através de exemplos históricos a ela apresentados;
- c) Implementação mais rápida: o tempo de implementação de uma rede neural, bem como seu custo, é menor do que o necessário para construção de um sistema especialista equivalente;
- d) Imunidade à falhas: devido ao fato das unidades de processamento das redes neurais operarem em paralelo, a destruição ou problema num dos seus neurônios não torna a rede inoperante, podendo até mesmo passar despercebido (como ocorre no cérebro humano);
- e) Capacidade de generalização: mesmo com dados incompletos ou imprecisos as redes podem preencher as lacunas sem sofrer degradação; é algo como a interpolação e extrapolação da estatística, porém operacionalmente muito diferente;
- f) Imunidade a ruídos (erros): as redes conseguem separar o ruído existente na informação relevante dos dados reais, podendo ser utilizadas até mesmo como filtros de dados;
- g) Adaptabilidade: uma vez construída uma rede eficiente em dada aplicação, ela pode ser utilizada em aplicações de tempo real, sem necessidade de ter sua arquitetura alterada a cada atualização; basta que seja re-treinada com base nos novos dados históricos que forem surgindo;

As principais desvantagens no uso das redes neurais artificiais são:

- a) Treinamento demorado: o treinamento de uma rede, dependendo da aplicação, pode demorar horas ou mesmo dias;
- b) Resultados desconcertantes: as redes podem chegar a conclusões que contrariam as regras e teorias estabelecidas, bem como, considerar dados irrelevantes como básicos; somente o bom senso do profissional experiente saberá tratar tais casos;
- c) Caixa-preta: não se pode conhecer o motivo pela qual levou a rede a uma determinada conclusão; seus critérios decisórios são encriptados, não sabendo quais valores são relevantes à tomada de uma decisão;
- d) Volume grande de dados: para uma rede aprender corretamente, necessita-se de um grande volume de dados históricos; a carência de dados relevantes em quantidade suficiente torna a rede inaplicável;
- e) Preparação dos dados: os dados de entrada necessitam de tratamento prévio; devem ser normalizados e cuidadosamente selecionados, para que a rede seja corretamente ensinada a agir. Dados de má qualidade produzem resultados falhos.

### 3. REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) foram idealizadas, na teoria, para simularem o comportamento funcional do cérebro humano, capaz de imitá-lo na prática de aprender, errar e realizar descobertas, ou seja, ser autônomo. O cérebro humano é um fascinante processador e armazenador de informações, apresenta-se com uma elevada complexidade, com seus neurônios, altamente conexionista, funcionando de forma não-linear e paralela, oferecendo-lhe uma performance apreciável no reconhecimento de padrões e soluções de problemas e, de longe, superior ao mais potente computador existente na atualidade. Apesar da velocidade de processamento do cérebro ser relativamente menor, sua condição conexionista compensa essa limitação, conferindo-lhe um excelente desempenho, constituído por aproximadamente 10 bilhões de neurônios, sendo estes interligados por meio de sinapses e juntos formam uma grande rede chamada Rede Neural Biológica (RNB). As sinapses são responsáveis pela transmissão de estímulos que podem ser estendidos por todo o corpo humano. Caso o cérebro entenda tal estímulo como sendo importante, este é ativado no processo racional, caso contrário, este é reprimido. Esta estrutura neural é responsável por uma extrema capacidade de processamento e armazenamento de informação, resultando na característica atribuída à inteligência.

Tenta-se, através da Inteligência Artificial (IA), realizar uma analogia ao comportamento do cérebro humano, buscando entendê-lo por meio de modelos matemáticos. A comunidade científica, ao longo da história, almeja desvendar os mistérios da inteligência biológica, e a partir disso, estabelecer, de forma científica, as relações entre inteligência e atividade nervosa. Questões como agilidade e eficiência na resolução de problemas, através do sistema neural, foram investigadas. Com o amadurecimento da IA, desenvolveram-se modelos computacionais capazes de simular a atividade neural do cérebro humano, respondendo e aprendendo como tal. Com isso, deu-se origem à RNA.

O uso de redes neurais para a previsão de dados hidrológicos, vazão e precipitação, nos seus mais diferentes usos é hoje uma área bastante promissora. (Galvão e Trigo, 1999).

De modo geral, as redes neurais têm permitido obter resultados satisfatórios e melhores que os modelos estatísticos tradicionais. Ainda assim, essa é uma técnica relativamente pouco empregada neste contexto. Pois, se observa que um caso difere de outro e não há uma referência segura. Nada garante que uma rede que funciona para um local será eficiente para outro com características semelhantes (Favoreto *et al.* 2001).

### 3.1. DEFINIÇÕES DE REDES NEURAIS

Haykin (2001) define redes neurais como sendo:

“Uma rede neural é um processador maciço paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos”:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.”

Segundo Braga *et al.* (2000), as Redes Neurais Artificiais são modelos matemáticos que se assemelham às estruturas neurais biológicas e que têm capacidade computacional adquirida por meio de aprendizado e generalização.

Galvão e Valença (1999) definem RNAs como sendo um sistema constituído por elementos de processamento interconectados, chamados de neurônios, os quais estão dispostos em camadas de entrada (uma camada de entrada, uma camada ou várias intermediárias e uma de saída) e são responsáveis pela não-linearidade da rede, por meio do processo interno de certas funções matemáticas.

Carvalho *et al.* (1998) definem RNAs como sendo um sistema paralelo distribuído composto por unidades de processamentos simples (EPs) que computam determinadas funções matemáticas (normalmente não-lineares).

Assim, as RNAs podem ser definidas como sendo técnicas computacionais que modelam e solucionam problemas, de forma simplificada, inspirados na estrutura neural dos seres humanos, através de uma série de experiências, tentativas e erros, coisa que os modelos tradicionais não o fazem, pois não possuem essa capacidade de aprendizagem.

### 3.2. BREVE HISTÓRICO

A neurociência tem progredido de forma animadora nas últimas décadas. Recentes avanços têm permitido um maior entendimento do funcionamento do cérebro humano, como, por exemplo, entender como se dar o fluxo de informações e seu processamento no interior deste, fazendo com que se torne próximo o sonho invejável de modelar matematicamente esse comportamento, em forma de algoritmo computacional, na tentativa de reproduzir, em máquinas, aquela que é, certamente, a maior virtude do ser humano, a inteligência, mesmo que isso ocorra, ainda, de forma simplista e primitiva.

Segundo Koivács (2002), o primeiro trabalho científico envolvendo a neuro computação ocorreu em 1943, no artigo intitulado: “*A Logical Calculus of the Ideas Immanent in Nervous Activity*” de Warren McCulloch e Walter Pitts, onde, talvez inspirados pelos avanços existentes na época, relacionando as propriedades eletrofisiológicas e a natureza booleana da inteligência, propuseram a construção de uma máquina baseada e inspirada no cérebro humano, sendo, portanto, a primeira referência em termos de RNAs.

A segunda grande contribuição para o desenvolvimento da disciplina de Redes Neurais se deu através do trabalho do psicólogo Donald Hebb em 1949, com a publicação do seu livro intitulado de “*The Organization of Behavior*” (A Organização do Comportamento). Neste trabalho, Hebb apresentou o famoso *postulado de aprendizagem*, sendo o primeiro a propor uma lei matemática de aprendizagem específica para as sinapses dos neurônios. “Hebb propôs que a conectividade do cérebro é continuamente modificada conforme o organismo vai aprendendo tarefas funcionais diferentes e que agrupamentos neurais são criados por tais modificações” (Haykin, 2001).

Baseados nos estudos de Hebb, muitos outros trabalhos foram desenvolvidos, como exemplo, o de Rochester *et al.* (1956), que é considerado a primeira experiência na simulação

computacional para verificação comportamental de uma rede neural artificial, composta por centenas de neurônios altamente conectados e estimulada por agentes externos.

Minsky (1951) desenvolveu o primeiro neuro computador, conhecido por Snark, capaz de simular o aprendizado, ajustando automaticamente os pesos entre as sinapses, operando com sucesso, porém, não chegou a realizar nenhuma função útil.

Rosenblat (1958) criou a *Rede Perceptron*, que era uma rede de duas camadas usada com sucesso no reconhecimento de caracteres, avançando de forma extraordinária os estudos até então desenvolvidos, com sua maneira moderna de lidar o assunto, para os padrões da época, é considerado hoje como o fundador da neuro computação. Em 1962, foi publicado o seu livro “Principles of Neurodynamics” (Rosenblat, 1962), no qual o autor trata de seu trabalho sobre o *perceptron* como uma adaptação do modelo de McCulloch e Pitts no reconhecimento de padrões através de um método inovador de aprendizado supervisionado. Ele também demonstrou o teorema da convergência do *perceptron*.

A rede *Adaline* (*adaptive linear element*, elemento linear adaptativo) foi introduzida por Widrow e Hoff (1960), suprimindo uma simplificação imposta aos modelos artificiais até então existentes, com relação ao sistema neural biológico. Nesta nova abordagem, foi criada uma rede que emulava o cérebro humano no que diz respeito ao seu funcionamento paralelo, com a implementação de múltiplos processadores trabalhando de forma paralela, e não apenas um isoladamente. Widrow (1962) introduziu a estrutura *Madaline* (*multiple-adaline*), que foi a primeira rede com múltiplos elementos adaptativos de camadas treináveis.

Toda essa euforia, pela qual passava as pesquisas direcionadas a neuro computação, em que parecia que tudo era possível e que num breve espaço de tempo tudo poderia ser resolvido através de sistemas inteligentes, não durou muito. Minsky e Papert (1969) lançaram o livro “Perceptron”, onde, nesta publicação, os autores teceram severas críticas ao modelo *Perceptron*, apontando de forma condizente, através de formulações matemáticas, suas limitações e as estendiam para os modelos de múltiplas camadas, “argumentando que os *Perceptrons* apresentavam limitações em suas aplicações, não possuíam capacidade de aprendizado para resolver problemas simples e nem uma adequada sustentação matemática. Além disso, provaram formalmente que uma rede formada de uma única camada de neurônios, independente do algoritmo de aprendizagem, é capaz apenas de resolver problema de associação de padrões, quando os conjuntos de pares são linearmente separáveis” (Santos, 2001).

A década de 70 foi notavelmente afetada pelos comentários de Minsky e Papert (1969), apesar de alguns poucos trabalhos na área de redes neurais, a comunidade científica dessa época não se sentia motivada a dar continuidade às pesquisas e, assim, o tema não mais repercutia, caindo em descrédito.

Os trabalhos envolvendo a neuro computação retomaram novo ânimo com os trabalhos publicados pelo biólogo e físico de reputação mundial Hopfield (1982), repercutindo, positivamente, de forma mundial e novamente incentivando a comunidade científica a dar continuidade a essa área emergente do conhecimento.

Finalmente, Rumelhart *et al.* (1986) sanaram a deficiência fundamental existente no treinamento da rede neural artificial apontada por Minsky e Papert, com a implementação do “Backpropagation Error Correction Algorithm” ou algoritmo de retropropagação do erro, adaptado para redes de neurônios *Perceptron* de multicamadas, onde as funções de ativação das unidades de processamento (neurônios) foram substituídas por funções sigmóides contínuas, não-lineares e diferenciáveis.

A utilização de RNA vem se constituindo, nas últimas décadas, numa tendência no meio científico, com modelos matemáticos aplicáveis nas mais variadas áreas do conhecimento e, em especial, na compreensão dos fenômenos hidrológicos. Essa linha de pesquisa vem evoluindo e se consolidando numa ferramenta útil para a solução de problemas complexos e não-lineares que envolvam padrões de entrada e saída, como o da transformação chuva em vazão.

### 3.3. O NEURÔNIO BIOLÓGICO

São os neurônios biológicos as principais células constituintes do cérebro humano; estima-se que este é formado por aproximadamente 10 bilhões de neurônios altamente interligados, com cerca de 60 trilhões de ligações sinápticas, unidos de forma paralela no processamento conjunto de milhões de informações. O neurônio é composto por três partes distintas: o *corpo celular*, também conhecido por *soma*, onde se realizam todos os processamentos das informações; os *dendritos*, que são ramificações que se assemelham aos galhos de árvores e que são responsáveis pelo recebimento dos milhões de bits de informações advindas de outros neurônios e dos mais diversos campos sensoriais do corpo humano, e as conduzem até o núcleo do corpo celular, onde são armazenadas e

processadas, resultando numa resposta em forma de pulsos elétricos, conhecidos como impulsos nervosos, que são propagados para a extremidade do *axônio*, onde são transmitidas por meio de sinapses para os neurônios adjacentes a este, caso contrário, ocorre a inibição do sinal. Estes componentes são representados na Figura 3.1.

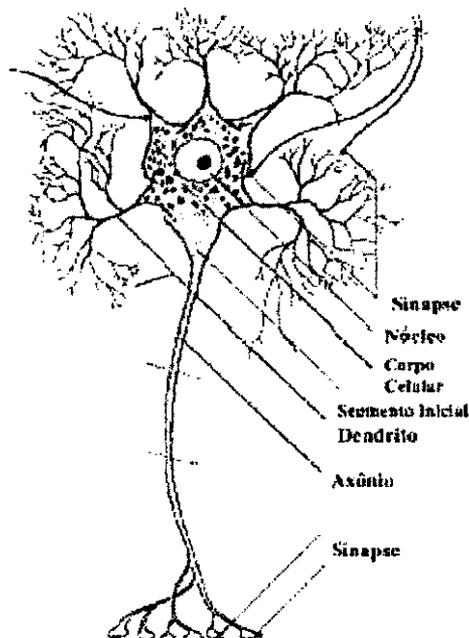


Figura 3.1 - Componentes do neurônio (Osório e Vieira, 1999).

Em suma, o modelo de funcionamento do neurônio é bastante simples, tendo-se basicamente três etapas a serem cumpridas: os estímulos advindos de outros neurônios, em forma de impulsos, são conduzidos através dos dendritos até o soma, onde são “somados” e, caso a soma resultante seja superior a um determinado limiar, o neurônio é ativado e estimulado a propagar o impulso para o axônio, responsável pela transmissão desta informação para as demais células nervosas através de processos sinápticos.

Uma característica fundamental da maioria das sinapses é a propagação do sinal numa única direção. Isto permite que, os sinais sejam conduzidos nas direções adequadas ao desempenho das funções nervosas necessárias. O conjunto entre os neurônios e as sinapses forma uma grande rede, denominada de *rede neural*. O neurônio pode controlar a frequência de pulsos, aumentando ou diminuindo a polaridade na membrana pós-sináptica, inibindo ou excitando a geração dos pulsos num outro neurônio. Esse controle determina o funcionamento, o comportamento e o raciocínio do ser humano (Santos, 2001).

O armazenamento de informação ou *memória* também está ligado à função das sinapses. Quando certos tipos de sinais sensoriais passam através de seqüências de sinapses, a transmissão fica mais evidente ou eficiente em pulsos subseqüentes. Esse processo é denominado de *facilitação*. Então, uma vez que, as lembranças tenham sido armazenadas no sistema nervoso, elas se tornam parte do mecanismo de processamento. Os processos de pensamento do cérebro comparam novas experiências sensoriais com as lembranças armazenadas, as lembranças ajudam a selecionar as novas informações sensoriais e a canalizá-las para dentro de áreas de armazenamento apropriadas para uso futuro ou para dentro de áreas motoras para causar respostas corporais imediatas (Guyton e Hall, 1997).

### 3.4. O NEURÔNIO ARTIFICIAL

A estrutura dos neurônios artificiais foi desenvolvida de forma, proposital, a imitar a dos neurônios biológicos, assim, seu funcionamento é bastante similar ao das células nervosas. O neurônio artificial também é conhecido na literatura por outras nomenclaturas, como: *Elementos de Processamentos (EPs)*, *Nó* e *Nodo*.

Os modelos de Redes Neurais Artificiais também são conhecidos na literatura como Modelos Conexionistas, compostos por várias unidades de processamentos (neurônios), trabalhando maciçamente em paralelo e de forma não linear, emulando as principais características do comportamento e da estrutura das Redes Neurais Biológicas (RNB), tidas como principais razões de seu excelente desempenho no reconhecimento de padrões e resolução de problemas. A Figura 3.2 ilustra as semelhanças existentes entre ambos os sistemas.

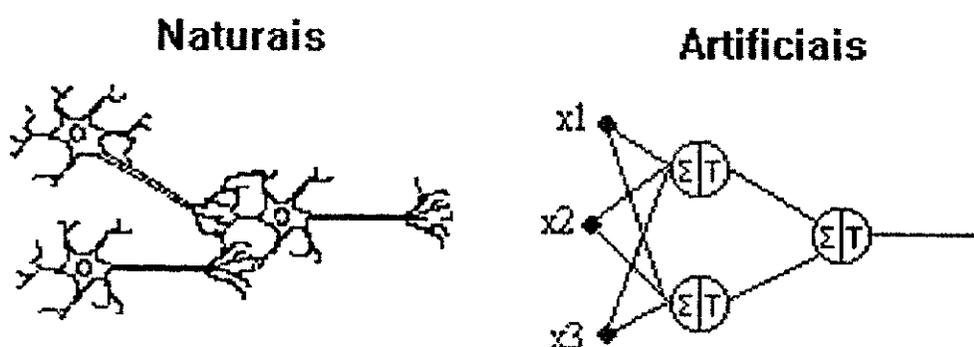


Figura 3.2 - Analogia entre os neurônios naturais e artificiais (Tafner *et al.*, 1995).

Os pesquisadores pioneiros na modelagem matemática do comportamento da Rede Neural Biológica foram McCulloch e Pitts em 1943. Seu neurônio era um dispositivo binário, com sua saída sendo restringida a pulso ou não-pulso, resultante de uma ponderação, através de pesos, das suas várias entradas no sistema. Nesse sentido, a analogia desenvolvida pelos pesquisadores foi a seguinte: as *sinapses* foram representadas por pesos  $w_{ij}$ , os quais são multiplicados pelas entradas  $x_i$ , que se assemelham aos *dendritos* dos neurônios naturais, estas entradas ponderadas pelos pesos são conduzidas até o elemento de processamento (neurônio), onde o núcleo da célula viva é representado por uma *função de ativação*, usada para comparar o resultado da soma das entradas ponderadas pelos pesos sinápticos com o limiar do núcleo  $\theta_j$ , restando o *axônio*, que foi representado pela saída do neurônio  $y_j$ . A função de ativação usada para representar o núcleo foi a degrau, ilustrada na Tabela 3.1, e o modelo representado na Figura 3.3 pode ser escrito matematicamente pelas Equações 3.1 e 3.2.

$$n_j = \sum_{i=1}^p w_{ij} x_i \quad (3.1)$$

$$y_j = F(n_j) = F\left(\sum_{i=1}^p w_{ij} x_i - \theta_j\right) \quad (3.2)$$

onde:

$F$  é a função de ativação do neurônio;

$w_{ij}$  são os pesos;

$x_i$  ( $i=1,2,3,\dots,p$ ) representam as  $p$  entradas do sistema;

$n_j$  saída da combinação linear;

$\theta_j$  é o limiar do neurônio;

$y_j$  representa a saída do neurônio.

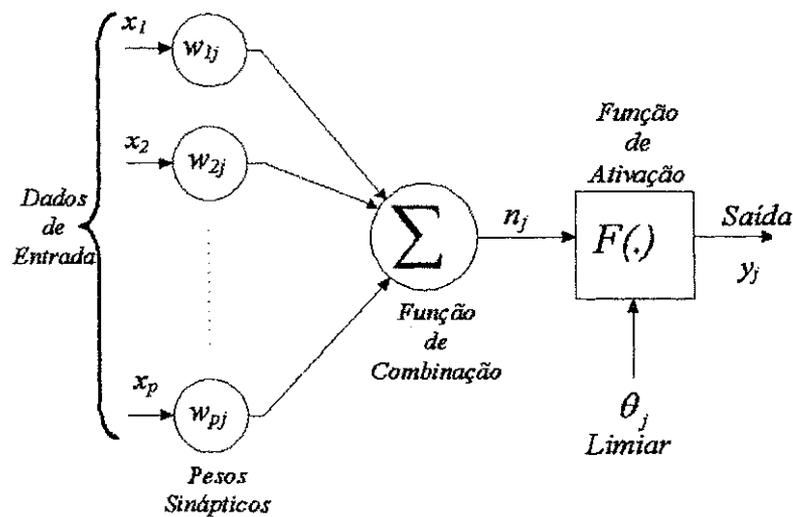


Figura 3.3 - Neurônio de McCulloch-Pitts (Adaptado de Haykin, 2001).

O modelo do neurônio artificial introduzido por McCulloch e Pitts (MCP) pode ser visto de uma nova maneira, tal qual mostrada na Figura 3.4, ou seja, supondo-se que, na estrutura apresentada na Figura 3.3 se possa inserir, através de um neurônio externo  $j$ , um novo parâmetro, que por simplificação seja considerado igual ao limiar  $\theta_j$ , assim tem-se  $w_{0j} = \theta_j$ , ainda, como exemplo, supõe-se uma entrada correspondente, de valor fixo, e igual a  $-1$ , ou seja,  $x_0 = -1$ . Com isso, a Equação 3.2 pode ser reescrita segundo a Equação 3.3.

$$y_j = F(n_j) = F\left(\sum_{i=0}^p w_{ij} x_i\right) \quad (3.3)$$

Assim, segundo o neurônio MCP a saída da rede neural será:

$$y_j = 0 \quad \text{se} \quad F\left(\sum_{i=1}^p w_{ij} x_i\right) < \theta_j \quad \text{ou} \quad (3.4)$$

$$y_j = 1 \quad \text{se} \quad F\left(\sum_{i=1}^p w_{ij} x_i\right) \geq \theta_j \quad (3.5)$$

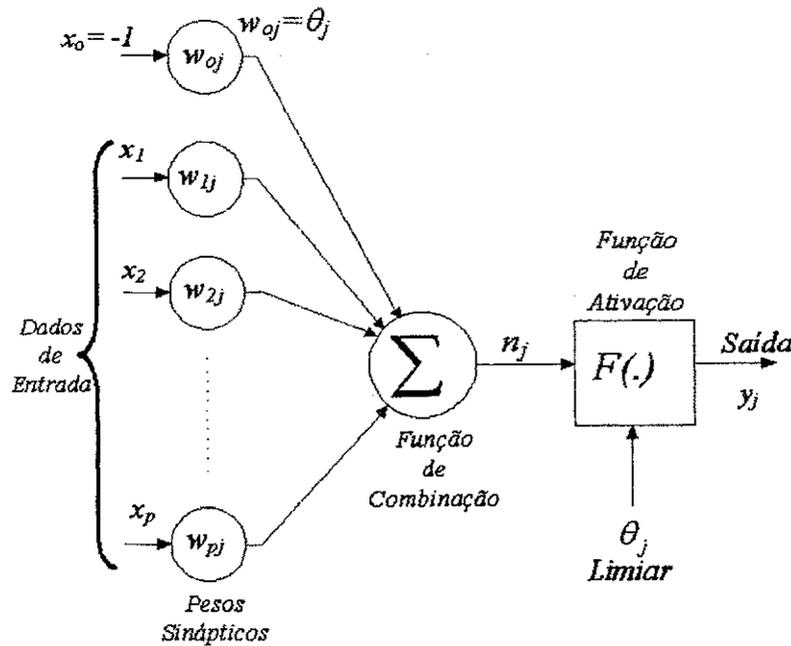


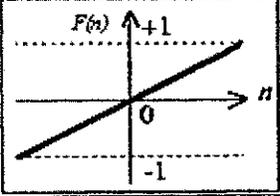
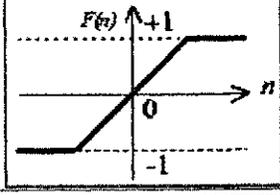
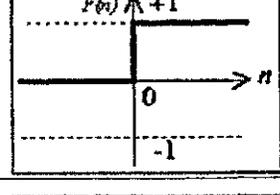
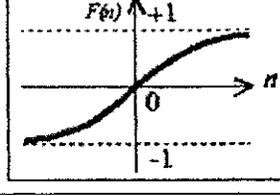
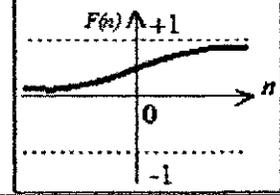
Figura 3.4 - Neurônio de MCP modificado (Adaptado de Haykin, 2001).

Esse trabalho deve ser reconhecido e é de grande valia para o desenvolvimento das técnicas de redes neurais existentes atualmente. Tal modelo é, certamente, o alicerce onde se apóia hoje toda a base teórica contextualizada da neurocomputação. Houve melhorias significativas dessa idéia inicial, sendo a principal, a troca da função de ativação degrau por outras, como, a mais usual, que é a sigmóide, por ser não-linear, contínua, diferenciável e monotônica, características importantes para o desenvolvimento de algoritmos de treinamentos justificáveis.

### 3.5. FUNÇÃO DE ATIVAÇÃO

A função de ativação  $F(.)$  possui a finalidade de processar e mapear toda somatória dos estímulos, ponderados pelos pesos, advindos dos neurônios que o alimenta com informações. O resultado deste processamento faz com que o neurônio alcance um novo estado de ativação que será propagado através de sua saída  $y_i$ , como um novo estímulo de chegada para os demais neurônios receptores deste. Segundo Haykin (2001), a função de ativação também é conhecida como função restritiva, já que restringe o intervalo permissível de amplitude do sinal de saída a um valor finito, onde, normalmente, este intervalo normalizado de um neurônio é escrito como o intervalo unitário fechado  $[0,1]$  ou alternativamente  $[-1,1]$ . As funções de ativação mais difundidas na literatura são expostas na Tabela 3.1.

Tabela 3.1 – Tipos de funções de ativação mais empregadas em RNA

Função	Equação	Representação Gráfica
Linear	$F(n) = n$	
Rampa	$F(n) = \begin{cases} 1 & \text{se } n \geq 1; \\ n & \text{se }  n  < 1; \\ -1 & \text{se } n \leq -1. \end{cases}$	
Degrau	$F(n) = \begin{cases} 1 & \text{se } n \geq 0; \\ 0 & \text{se } n < 0. \end{cases}$	
Tangente Hiperbólica (Logística)	$F(n) = \frac{2}{(1 + e^{-2n})} - 1$ *	
Sigmóide (Logística)	$F(n) = \frac{1}{1 + e^{-n}}$	

\* A função de ativação tangente hiperbólica sigmóide foi empregada nesse estudo e tal formulação foi adaptada pelo MATLAB 5.3<sup>®</sup>.

- Função Linear: Diferentemente da função degrau, esta não limita a saída e são usadas para armazenar entrada e saída de dados. Os neurônios que possuem esta função de propagação funcionam como aproximadores lineares.
- Função Rampa: Esta função pode ser vista como uma aproximação de um amplificador não-linear, ou seja, é uma função não-linear simplificada.
- Função Degrau: Normalmente é usada em neurônios que tomam decisões binárias, pois limitam a saída do neurônio a apenas dois valores (0 ou 1), como nos classificadores.
- Função Tangente Hiperbólica: Esta é um exemplo de função logística e está definida no intervalo de [-1, +1]. A função logística ou sigmóide é a função de ativação ou transferência mais utilizada em RNA (Kovács, 1996). São caracterizadas pelo seu formato em S alongado, são funções semi-lineares, contínuas, monotonicamente crescentes e limitadas por

assíntotas horizontais (Loesch e Sari, 1996). São deriváveis em toda sua extensão, são simétricas e possuem todas as derivadas contínuas, características importantes para demonstração de teoremas matemáticos (Santos, 2001).

- Função Sigmóide: Esta função permite a entrada de qualquer valor no intervalo  $[-\infty, +\infty]$  e as comprime para o intervalo  $[0, +1]$ . Possui todas as características descritas para a função tangente hiperbólica, por isso, é tida, juntamente com essa, como a mais utilizada em redes neurais.

### 3.6. ARQUITETURA DA REDE NEURAL

A arquitetura de uma RNA refere-se à forma como os seus neurônios estão organizados. Para cada problema existe uma estrutura adequada de rede neural, existindo várias estruturas que se diferem umas das outras em função do número de camadas e pela forma como seus neurônios interagem. Logo, para cada tipo de problema existirá uma topologia de rede mais apropriada para o caso. No fluxograma da Figura 3.5, têm-se as principais questões a serem definidas na construção de um projeto de RNA.

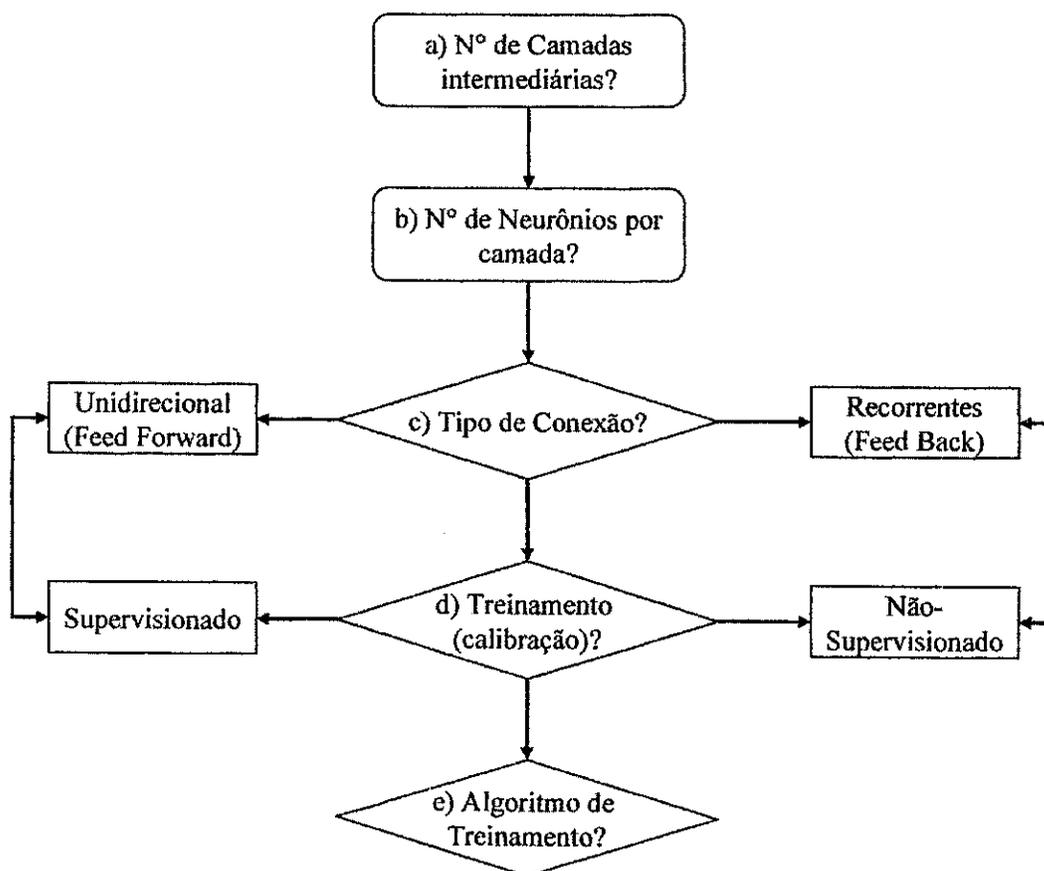


Figura 3.5 – Fluxograma das etapas a serem definidas na elaboração de um projeto de RNA.

### a. Número de camadas

Para definição do número de camadas intermediárias não existe uma regra bem definida a este respeito, pois isso depende do tipo do problema. O que existe na literatura especializada são sugestões advindas de experiências passadas. Sabe-se que, na grande maioria dos casos, apenas uma camada é suficiente para problemas menos complexos, no máximo duas camadas, em casos mais complexos, são aconselhadas. Isso porque, apenas o neurônio da última camada é quem tem realmente noção do erro cometido pela rede, os neurônios intermediários apenas têm estimativas do erro; por exemplo, se uma rede possui duas camadas escondidas, então, a primeira realiza uma estimativa do erro e passa para a segunda, então, a segunda fará, na realidade, uma estimativa da estimativa do erro e só a última camada é que tem total conhecimento do erro quando compara sua saída com a desejada.

De maneira geral, as RNAs possuem uma camada de entrada, zero ou mais camadas intermediárias ou escondidas e uma camada de saída. Pode-se citar como exemplos de RNAs sem camadas intermediárias as *Single Layered Perceptron* e o *ADaptive LINEar Elemente (ADALINE)* (Haykin, 2001). No entanto, as RNAs mais empregadas são aquelas com uma ou mais camadas intermediárias, conhecidas como *Redes de Múltiplas Camadas* ou *MLP (MultiLayered Perceptron)* e essas camadas têm as seguintes características:

- **Camada de Entrada:** Esta é responsável por captar estímulos externos e repassá-los para os neurônios da camada escondida ou intermediária;
- **Camada escondida ou intermediária:** É aquela onde estão os neurônios responsáveis pelo processamento interno das informações ponderadas advindas da camada de entrada, este processamento se dá através das funções de ativação. Assim, por meio de um algoritmo de treinamento adequado, é nesta camada onde se realiza a extração das características intrínsecas do problema tratado, ou seja, por meio de combinações de pesos ou parâmetros, a rede consegue codificar características próprias do problema identificado através dos padrões de entrada;
- **Camada de saída:** Esta última camada é a responsável pela organização e entrega da resposta da RNA produzida a partir dos estímulos propagados da camada intermediária.

### ***b. Número de neurônios por camada***

A quantidade de neurônios usada, em cada camada escondida, também não é preestabelecida; porém, deve-se ter bastante cuidado nessa etapa, pois, tem-se que encontrar o ponto ótimo, ou seja, a rede não pode ter neurônios de mais, pois corre o risco desta não ser capaz de generalizar o problema, ficando super-parametrizada, perdendo a sensibilidade aos padrões de entrada, oferecendo uma maior atenção aos parâmetros da rede, desprezando ou simplesmente memorizando os dados de entrada, causando o *superajustamento* no treino e pouca representatividade na validação. Por outro lado, se o número de neurônios for aquém do necessário, então, a rede passa a sentir deficiência na representação do problema, dificultando sua convergência, o fato é que, deve-se fazer uma investigação detalhada e avaliar as diversas possibilidades até se encontrar, através de um método empírico, a melhor estrutura.

No entanto, o que se tem são indicações de especialistas baseadas nas suas experiências próprias. Muitos sugerem projetar uma rede com um número de neurônios relativamente grande e posteriormente “*podar*”, retirando-os, até atingir um número de neurônios que ofereçam um ajuste satisfatório. Outros, no entanto, aconselham o contrário, iniciar o projeto da rede com um pequeno número de neurônios, aumentando esse número sucessivamente até atingir o ponto ótimo no ajuste. Essa última concepção é mais viável, pois o tempo de treinamento de uma rede neural aumenta bastante com o seu tamanho (Valença; Ludermir, 1999b). Existem, ainda, outras indicações que relacionam o número de neurônios da camada escondida com os da camada de entrada e de saída, por exemplo, ser igual à média aritmética entre o número de neurônios da camada de entrada e os da camada de saída. Com base em tudo isso, o projeto da rede neural, neste estudo, ocorreu de forma empírica, preferindo-se iniciar com um pequeno número de neurônios na camada escondida e aumentando esse número até que se obteve um bom ajuste na simulação da vazão sazonal, chegando-se, como ponto ótimo, à rede com dois neurônios na camada escondida, que nesse caso se confirmou ser igual à média aritmética entre o número de neurônios da camada de entrada (três) e o de saída (um). Porém, isso não é regra, cada problema é particular e necessita de uma estrutura própria.

### ***c. Tipos de conexão***

Existem diversas formas de interação entre os neurônios constituintes de uma rede neural, porém, duas delas são as mais comuns:

- Unidirecional (feedforward), onde os sinais se propagam apenas numa direção, ou seja, todos os neurônios da camada a montante se conectam a todos os neurônios da camada à jusante, não havendo realimentação de sinais propagados de uma camada a jusante para montante ou para neurônios adjacentes à sua própria camada. As redes feedforward são referenciadas como sistemas de mapeamento não-linear estático instantâneo (Loke, 1995). A Figura 3.6 ilustra esse tipo de rede.

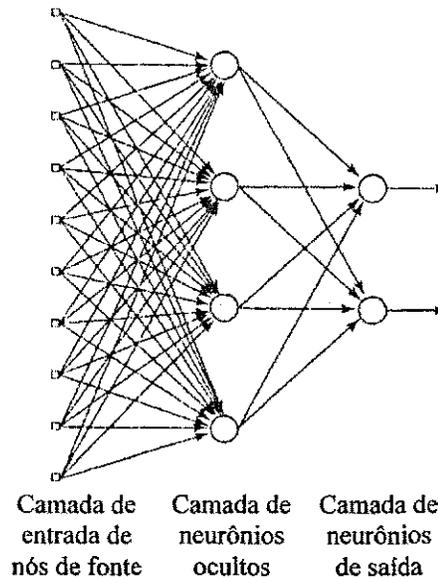


Figura 3.6 – Rede de múltiplas camadas conectadas unidirecionalmente (Haykin, 2001).

- Recorrentes (feedback), pode haver realimentação de sinais já propagados na rede. São mais empregados em sistemas dinâmicos. As redes feedback são referenciadas como sistemas não-lineares dinâmicos (Loke, 1995). A Figura 3.7 apresenta essa modalidade de rede neural.

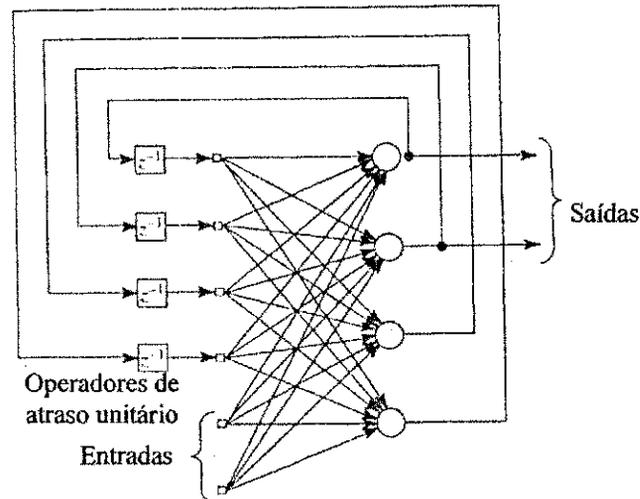


Figura 3.7 – Rede com conexões recorrentes e com camada intermediária (Haykin, 2001).

No presente estudo, será empregado o primeiro caso, por ser o mais adequado para o problema, uma vez que, como será visto, o tipo de aprendizagem empregado foi o supervisionado, que segundo relatos da literatura, oferece melhores resultados pelo fato dos sinais ocorrerem em apenas uma direção.

#### *d. Tipo de treinamento*

Como já mencionado anteriormente, os modelos conexionistas são sistemas que tentam emular o cérebro humano, tendo justamente como principal vantagem a capacidade de “*aprender*”, adaptando-se ao ambiente no qual esteja inserido e de melhorar seu próprio desempenho baseado nessa aprendizagem. A fase de aprendizado de uma RNA é essencial na resolução de problemas com essa técnica, pois, é através desta que a rede neural consegue captar informações importantes dos padrões de entrada por meio do *algoritmo de aprendizado ou de treinamento*, que é um processo iterativo de ajuste dos pesos e bias (parâmetros), por meio de regras bem definidas, visando a solução generalizada para o problema tratado, de tal forma que, as saídas calculadas pela rede sejam iguais ou próximas da saída desejada. Existe uma extensa variedade de algoritmos de aprendizagem que diferem entre si basicamente pela forma como realizam o ajuste dos pesos.

Haykin (2001) define o termo aprendizagem no contexto de redes neurais como:

“Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre”.

De acordo com o ambiente de funcionamento do treinamento, o aprendizado pode ser classificado em classes de paradigmas de aprendizado, os mais comuns são o *treinamento supervisionado* e o *não-supervisionado*, porém, também existe o *treinamento por reforço* e o *por competição*.

- **Treinamento supervisionado:**

Este é um caso em que há a existência de um agente externo, indicando à rede o resultado correto, ou seja, é entregue à rede o padrão de entrada e o de saída como exemplo da resposta, a qual a rede deverá chegar; este caso requer como tipo de conexão a unidirecional ou feedforward.

- **Treinamento não-supervisionado:**

Este caso se caracteriza por não necessitar de nenhum agente externo, ou seja, são apresentados à rede apenas os padrões de entrada, e esta, através de algoritmos apropriados, se auto-organizam e se adaptam ao problema interpretando os dados e classificando-os, por critérios de vizinhanças e semelhanças, em busca da resposta. As redes que possuem este tipo de treino são sistemas altamente dinâmicos e geralmente usam conexões do tipo recorrentes.

- **Treinamento por reforço:**

Esta modalidade é um caso particular do treinamento supervisionado, em que o treinamento ocorre por tentativas e erros, onde, a rede é recompensada em caso de sucesso e punida em caso contrário;

- **Treinamento por competição:**

Como o próprio nome sugere, nesse caso, ocorre uma competição entre os neurônios da saída da RNA, para saber qual destas será ativada, ou seja, ocorre uma competição entre as unidades de processamentos de saída para decidir qual terá seus pesos atualizados no processo de treinamento. Portanto, este é um caso particular do treinamento não-supervisionado.

e. *Algoritmo de treinamento*

Os algoritmos de treinamento dos modelos ditos conexionistas podem ser classificados em quatro classes segundo suas próprias regras, são elas:

- *Aprendizado por correção de erro*: é feito o ajuste dos pesos e bias (parâmetros da rede neural), de forma a obter o erro mínimo entre a resposta da RNA e a saída real;
- *Aprendizado Hebbiano*: o ajuste é realizado segundo a regra de Hebb (1949), em que diz que a união simultânea numa sinapse (conexão) entre dois neurônios, sincronamente ativos, ocasionaria uma força seletivamente mais intensa nessa conexão, assim, o ajuste do peso numa conexão entre dois neurônios ocorre apenas quando ambos os neurônios estejam simultaneamente ativos;
- *Aprendizado competitivo*: os neurônios competem entre si disputando a sua ativação;
- *Aprendizado Boltzman*: é um algoritmo de aprendizagem estocástica fundamentada em princípios da mecânica estatística.

### 3.7. APRENDIZADO POR CORREÇÃO DE ERRO E ALGORITMO DE RETRO-PROPAGAÇÃO

A regra de aprendizagem por correção de erro foi à empregada neste trabalho, e por esse motivo apenas esta será descrita em detalhes a seguir.

Na Figura 3.8 tem-se uma ilustração de como ocorre o aprendizado por algoritmos que fazem uso da correção de erros, como se pode ver, os algoritmos desse tipo, são baseados em processos iterativos de reajustes dos pesos das sinapses entre os neurônios, visando, com isso, a minimização do erro global, indicado pela diferença entre o resultado oferecido pela a rede e a resposta almejada. Os algoritmos clássicos de *retro-propagação do erro* são formulados com base no *gradiente descendente* da função objetivo erro, introduzido por Rumelhart (1986). A *regra delta*, como também é conhecida, busca a convergência desta função para o mínimo global, que é quando a rede, por ajustes sucessivos, encontra o conjunto de pesos ou parâmetros que conduz a um resultado ótimo, pois é quando, teoricamente, a rede neural proporcionaria o menor erro, ajustando sua resposta à desejada. Por tanto, na implementação dessa regra faz-se necessário informar a rede, através de uma fonte externa, os exemplos de respostas desejadas para cada padrão de entrada durante a fase do treinamento.

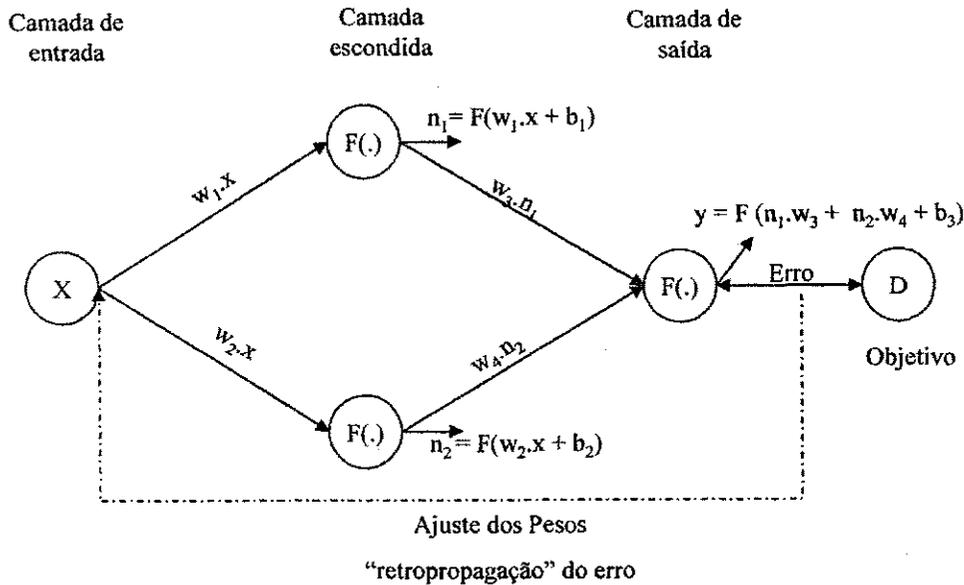


Figura 3.8 – Ilustração da aprendizagem por correção de erro.

Assim, para um dado conjunto de treinamento  $\phi = \{X_n, D_n\}_{n=1}^p$  onde se tenha  $p$  pares de treinamento e considerando-se uma rede neural formada por  $K$  camadas, então, o treinamento desta rede é realizado através do seguinte algoritmo:

- A. Define-se, inicialmente, um conjunto de pesos ou parâmetros  $W^{(0)}$ , bem como, uma taxa de aprendizado  $\eta$ ;
- B. Posteriormente, apresenta-se à camada de entrada da rede um par de treinamento  $(X_i, D_i)$  e então, calcula-se as saídas de todos os  $j$ -ésimos neurônios da camada subsequente da seguinte maneira:

$$u_j = w_j x_i - \theta_j \tag{3.6}$$

$$y_j = F(u_j) \tag{3.7}$$

onde  $F$  é a função de ativação.

- C. O procedimento da etapa B é repetido para todas as camadas seguintes, de forma que todos os neurônios, até a  $K$ -ésima camada, tenham calculado suas saídas;
- D. Obtido a resposta dos neurônios da camada de saída, esta pode ser comparada com o padrão de resposta desejada, de maneira a obter-se um resíduo ou erro e, com isso, pode-se determinar o gradiente local para todos os neurônios desta camada, dado pelas expressões:

$$e_i = d_j - y_j \quad (3.8)$$

$$\delta_j = e_j F'(u_j) \quad (3.9)$$

E. Agora, de forma retrograda, calcula-se o gradiente para todos os neurônios da camada anterior à última camada.

$$\delta_j = F'(u_j) \sum_{l=1}^J \delta_l w_{jl} \quad (3.10)$$

onde, nesse caso,  $J$  é o número de neurônios da camada de saída.

F. O passo E é repetido para todos os neurônios posteriores, exceto, para os da camada de entrada, tendo-se sempre  $J$  como o número de neurônios da camada posterior àquela onde atualmente se está calculando os gradientes locais  $\delta$ .

G. A atualização corretiva de cada peso  $w_{ij}$  entre o neurônio  $i$  da camada  $k$  e o neurônio  $j$  da camada  $k+1$  é dado por:

$$\Delta w_{ij} = \eta \delta_j y_j \quad (3.11)$$

$$w_{ij}^1 = w_{ij}^0 + \Delta w_{ij} \quad (3.12)$$

Lembrando-se que, o cálculo de  $\delta_j$  para a camada de saída é dado pela Equação 3.9, enquanto que para as demais camadas  $\delta_j$  é dado pela Equação 3.10.

H. Retorna-se ao passo B até que todos os padrões de entrada tenham sido apresentados;

I. Repetem-se os passos B a H até que algum critério de convergência tenha sido obtido.

O algoritmo de retro-propagação do erro ou *backpropagation*, em geral, possui uma deficiência por exigir muitas iterações para alcançar a convergência. Por isso, foram criadas várias modificações, fazendo com que surgissem muitos algoritmos de treinamento adaptados a partir desse. Porém, a maioria destes novos algoritmos deriva-se do algoritmo *backpropagation*, por isso sua incontestável importância.

### 3.8. ALGORITMO DE TREINAMENTO DE LEVENBERG-MARQUARDT

Um exemplo de algoritmo de retro-propagação que foi adaptado com base no de Rumelhart é o de Levenberg-Marquardt (LM), que segundo Hagan e Menhaj (1994), enquanto o *backpropagation* padrão utiliza a descida do gradiente como método de aproximação do mínimo da função erro, o algoritmo de Levenberg-Marquardt utiliza uma aproximação pelo método de Newton.

A descrição matemática desse algoritmo foi compilada e adaptada do trabalho de Campos e Báez (2002). Inicialmente, obtem-se a função objetivo a ser otimizada, sendo que, nesse caso, trata-se da diferença quadrática entre a saída desejada e a calculada pela rede. Assim, de forma geral, a função a ser minimizada pode ser escrita para os neurônios da camada de saída da seguinte maneira:

$$U(w_k) = \sum_{k=1}^n (w_k x_k - \theta_k)^2 \quad (3.13)$$

onde  $k$  está relacionado com cada saída (neurônio) da rede no processo iterativo, sendo:

$$E_k = (w_k x_k - \theta_k) \quad (3.14)$$

então,

$$E = [e_1 \ e_2 \ \dots \ e_n]^T \quad (3.15)$$

Assim, agrupando-se as Equações 3.13 e 3.14, tem-se:

$$U(w_k) = \sum_{k=1}^n (E^k)^2 \quad (3.16)$$

A correção dos pesos da rede ocorre de maneira análoga ao algoritmo de retro-propagação da seguinte forma:

$$W^{k+1} = W^k + \Delta W^k \quad (3.17)$$

onde  $\Delta W^k$  atualiza os parâmetros antigos  $W^k$  visando a minimização da função objetivo erro. Essa atualização dos pesos é promovida pela seguinte equação:

$$\Delta W^k = -[J(W^k)^T J(W^k) + \mu^k I]^{-1} J(W^k)^T E^k \quad (3.18)$$

em que  $I$  é a matriz identidade,  $\mu$  é o parâmetro introduzido para agilizar o processo da convergência, e  $J(W)$  é a matriz jacobiana da derivada parcial entre o erro cometido em relação aos pesos.

$$J(W^k) = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \dots & \frac{\partial e_1}{\partial w_n} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \dots & \frac{\partial e_2}{\partial w_n} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_n}{\partial w_1} & \frac{\partial e_n}{\partial w_2} & \dots & \frac{\partial e_n}{\partial w_n} \end{bmatrix}$$

O parâmetro  $\mu$  será multiplicado por um fator de treinamento  $\beta$  sempre que um passo do algoritmo representar um aumento da função objetivo erro, caso contrário, o parâmetro  $\mu$  será dividido por  $\beta$  quando houver uma diminuição desta função, agilizando o processo da convergência, portanto, o parâmetro  $\mu$ , variável no tempo, diminui após cada passo do algoritmo que reduza a função objetivo e sofre acréscimos quando o algoritmo se afasta do mínimo da função. Tendo-se, portanto, uma redução do erro a cada iteração realizada pelo algoritmo de treinamento. Assim, segundo Hagan e Menhaj (1994), existe uma oscilação entre o método clássico de retro-propagação e este, uma vez que, quando houver uma convergência para o mínimo da função objetivo, o parâmetro  $\mu$  é pequeno e o algoritmo se aproxima do método de Newton, caso contrário, se não houver convergência, o método se aproxima da descida do gradiente e isso faz com que quando comparado com outras técnicas, esse algoritmo proporcione um desempenho superior, por proporcionar uma maior velocidade na convergência associado a uma maior precisão no resultado.

O parâmetro  $\mu$  funciona como um fator de estabilização do treinamento, ajustando a aproximação de forma a utilizar a rápida convergência do método de Newton e evitando passos muito grandes que possam levar a um erro de convergência (Hagan e Menhaj, 1994). Num trabalho realizado por Demuth e Beale (1998), onde realizaram a comparação do desempenho entre vários algoritmos de treinamento na resolução de um determinado problema, os autores chegaram à conclusão de que o algoritmo de Levenberg-Marquardt foi amplamente superior aos demais, uma vez que atingiu a convergência num menor tempo, necessitando de um menor número de iterações e com um menor número de operações com pontos flutuantes.

Observa-se, no entanto, que a maior deficiência do algoritmo de LM refere-se à elevada capacidade computacional requerida por ele em relação às utilizadas pelos demais métodos. Contudo, visto que no presente trabalho não se faz necessário um alto nível computacional e que, diante do número entre os padrões de entrada e de saída, se previa que a rede neural seria pequenas, adotou-se o mesmo como algoritmo de treinamento responsável pelo ajuste entre a resposta desejada e a oferecida pela rede, tendo em vista sua eficiência já confirmada.

## 4. A REGIÃO DE ESTUDO E ANÁLISE DOS DADOS

### 4.1. SELEÇÃO, COLETA E TRATAMENTO DOS DADOS

A escolha das bacias hidrográficas dos rios Piranhas-Açu-Apodí para a aplicação da metodologia se deu principalmente pelos motivos de:

1. Ser uma região homogênea e típica do semi-árido do Nordeste;
2. Possuir algumas bacias hidrológicas de postos fluviométricos inseridas nesta, (Antenor Navarro (AN), Aparecida (AP), Augusto Severo (AS), Emas (EM), Fazenda Angicos (FA), Mossoró (MO), Pau dos Ferros (PF), Pedra de Abelhas (PA), Piancó (PI), São Fernando (SF), Sítio Volta (SV), Upanema (UP) e Serra Negra (SN), com dados observados e com problemas típicos de outras bacias do Nordeste;
3. Ser uma bacia já trabalhada com estudos de regionalização, permitindo uma comparação entre os resultados obtidos.

Nesta fase preliminar, os dados necessários para a elaboração do modelo de RNA já haviam sido levantados por Melo (2003) e estavam disponíveis em seu acervo. Assim, foram selecionadas aquelas características físicas das sub-bacias hidrográficas de maior facilidade de mensuração e obtenção, destacando-se: a área de drenagem ( $A$ ); o comprimento do rio principal ( $L$ ); a declividade média do rio principal ( $S$ ) e a densidade de drenagem da sub-bacia ( $D_d$ ). As séries de dados observadas de precipitação e vazão também foram retiradas do estudo de Melo (2003), já na escala sazonal de interesse. Com a série de vazões diárias de cada posto fluviométrico, foi feita a média desses valores diários durante a estação chuvosa (fevereiro-maio) de cada ano, resultando em vazões médias diárias sazonais. No caso da precipitação, também durante a estação chuvosa de cada ano, para cada posto pluviométrico, acumulou-se os valores diários de precipitação, para, posteriormente, retirar-se a média aritmética entre os postos inseridos em cada sub-bacia, resultando na precipitação total média sazonal.

Entretanto, deve-se lembrar que, as séries de dados de precipitação e vazão diária foram retiradas originalmente do banco de dados da Agência Nacional de Energia Elétrica e da Agência Nacional de Águas (ANEEL/ANA) e que as mesmas já tinham sido submetidas a testes não-paramétricos para a devida observância da estacionariedade das séries em estudos já promovidos anteriormente pela UFPB/ANEEL (2001).

Uma vez identificadas as variáveis a serem trabalhadas, os passos seguintes são:

- a) Avaliar a qualidade dos dados disponíveis;
- b) Dividir a amostra de dados de acordo com cada abordagem trabalhada nas validações cruzada, mista e clássica;
- c) Normalizar os dados para uma melhor assimilação e maior rapidez na aprendizagem da rede neural, evitando a saturação da mesma;
- d) Organizar o banco de dados para ser utilizado pelo modelo de redes neurais. As entradas de informações nos modelos de RNAs se dão através de vetores, onde cada padrão de informação é disposto numa linha da matriz.

Segundo Eklund (1994), a normalização dos dados de entrada da RNA é um procedimento onde se converte um conjunto de dados a um intervalo menor do que o original, tornando mais fácil o treinamento da rede neural e facilitando a sua convergência, melhorando o desempenho e até mesmo reduzindo o tamanho da rede quanto ao número de camadas intermediárias e de neurônios por camada. Ainda no início deste trabalho, foram feitas simulações com os dados no seu estado normal, ou seja, sem normalizá-los, porém, o comportamento do modelo de RNA frente a esses dados foi de completa instabilidade. Com isso e com base na literatura, todos os padrões de informações disponíveis foram normalizados, dividindo-se cada valor utilizado na série de dados pelo máximo valor correspondente desta série, resultando no uso de séries de dados contidas no intervalo entre 0 e +1, proporcionando redes mais estáveis e facilitando o aprendizado da mesma.

## **4.2. DADOS DESCRITIVOS DA REGIÃO**

Faz-se necessário uma análise das características físico-climáticas da área a ser estudada na obtenção de um modelo chuva-vazão, haja vista o alto nível de complexidade envolvido no processo espaço-temporal que o modelo deverá representar. Assim, informações espaciais e

temporais devem ser levantadas com o propósito de retirar conclusões acertadas e uma melhor compreensão no processo da modelagem hidrológica.

A bacia hidrográfica estudada, vista na Figura 4.1, é monitorada pela Agência Nacional de Águas e é denominada, segundo a mesma, de sub-bacia 37, onde parte é inserida no estado do Rio Grande do Norte e a outra parte no Estado da Paraíba, entre os meridianos  $36^{\circ} 14' 15''$  e  $38^{\circ} 46' 22''$  de longitude oeste e entre os paralelos  $4^{\circ} 48' 04''$  e  $6^{\circ} 14' 15''$  de latitude sul. Esta é formada pela união das bacias hidrográficas dos rios Apodi (rio estadual) e Piranhas-Açu (rio federal). O rio Apodi tem como principal afluente o rio do Carmo, enquanto que o rio Piranhas-Açu possui os rios Espinharas, do Peixe, Piancó e Seridó.

No Estado do Rio Grande do Norte, os principais municípios inseridos na área hidrológica estudada são Mossoró, Açu e Caicó; já no Estado da Paraíba se destacam Patos, Sousa e Cajazeiras.

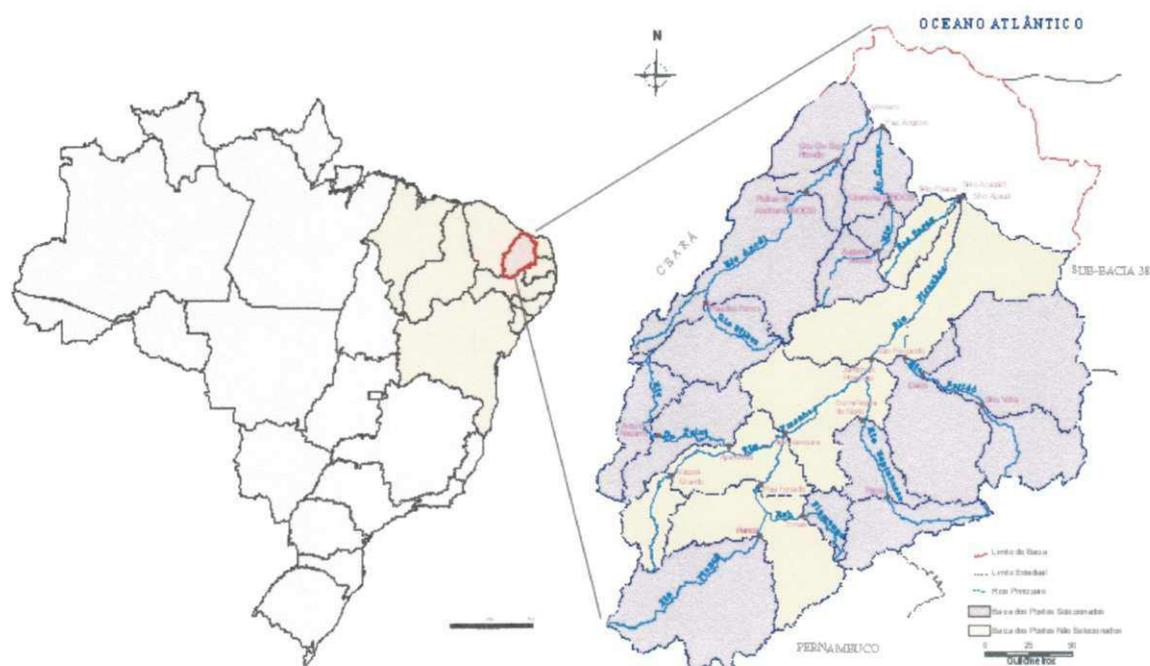


Figura 4.1 - Localização geográfica e bacias dos postos fluviométricos da bacia Piranhas-Açu-Apodi (Fonte: UFPB/ANEEL, 2001).

Segundo estudos promovidos pela UFPB/ANEEL (2001), a área é caracterizada da seguinte maneira:

“A região onde está situada a sub-bacia 37 faz parte do semi-árido, apresentando características peculiares como:

- rios intermitentes, com vazão nula em grande parte do ano;

- altas taxas de evaporação;
- baixas densidades de postos fluviométricos: dos 28 postos do cadastro da ANEEL, apenas treze puderam ser empregados como base para regionalização, alguns com séries mais curtas que a duração desejada;
- grande impacto antrópico, pelo desmatamento da vegetação nativa e, principalmente, pela alta densidade de reservatórios superficiais, a maioria sem informações cadastrais e operacionais.”

“Geologicamente, a região estudada é constituída por rochas ígneas, metamórficas e sedimentares, originadas desde o Pré-Cambriano até os dias atuais, resultantes da ação de fenômenos geológicos, relativamente bem caracterizados, no tempo e no espaço.”

“A sub-bacia 37 situa-se, geotectonicamente, sobre o Maciço Mediano Rio Piranhas, o qual ocupa a metade noroeste da bacia e sobre os sistemas de dobramentos denominados Piancó-Alto Brígida e Seridó. Ocorrem, também, acidentes de tectônica rígida, responsáveis pela formação das bacias sedimentares de afundamento tectônico (grandens e simi-branbens).”

“As grandes unidades de relevo que ocorrem nessa área, segundo o Mapa de Unidades de Relevo do Brasil, elaborado pelo IBGE (1995), a partir das unidades geomorfológicas mapeadas pelo Projeto RADAMBRASIL, são as seguintes: o Planalto Residual Sertanejo, o Patamar Sertanejo, o Planalto da Borborema, a Depressão Sertaneja, os Tabuleiros Costeiros e as Planícies Interioranas e Costeiras.”

“Os solos existentes na região guardam uma estreita correlação com os caracteres geológicos, morfológicos e climáticos desta bacia. Desta forma, no domínio das formações aluviais, onde se localizam as “planícies interioranas”, os solos são do tipo azonal, arenosos, argilosos (terraços inundáveis) e siltosos. Nas “planícies costeiras”, a capa pedológica é, igualmente, azonal, constituída de areias finas, às vezes retrabalhadas pela ação eólica formando as dunas recentes. No domínio dos “tabuleiros costeiros”, os solos apresentam-se bem desenvolvidos com a formação de horizontes bem definidos, sendo o nível mais superficial (horizonte A) relativamente espesso e rico em matéria orgânica vegetal. Nas regiões do Planalto da Borborema, Patamar Sertanejo e Depressão Sertaneja, os solos são zonados, porém pouco espesso, litólitos, podendo faltar algum horizonte (B ou C), principalmente na área da Depressão Sertaneja. Esta capa pedológica também não é superficialmente contínua, principalmente devido à ocorrência dos inselbergs graníticos e/ou migmatíticos. Na Depressão Sertaneja estes solos são mais rasos que no Planalto da Borborema,

provavelmente devido ao efeito combinado topografia/clima. Ainda sobre esta depressão encontram-se os solos do tipo “raña”, altamente pedregosos, devido à influência das rochas xistosas. Finalmente, sobre o Planalto Residual Sertanejo, os solos são zonados, rasos, arenosos, com o horizonte superficial pobre em termos de matéria orgânica.

“Toda a cobertura vegetal encontrada pertence ao que se convencionou denominar de Caatinga, uma vegetação do tipo savana estépica, ‘estacional-decidual, portanto com os estratos arbóreo e gramíneo-lenhoso periódicos e com numerosas plantas suculentas, sobretudo cactáceas’ (IBGE, 1995).”

“O clima apresenta, de modo geral, dois períodos definidos, sendo um mais longo, seco, intercalado por um período pluvial curto. A estação seca, de um modo geral, se estende por 8 meses do ano, ou às vezes mais.

A variabilidade espacial da precipitação, quando considerada em maior escala, define apenas uma região com algumas variações, em geral definidas por acidentes topográficos. Quando a variabilidade é considerada em menor escala, mostra diferenças (sem padrão definido) entre a ocorrência de precipitação em áreas relativamente próximas espacialmente. Esta variabilidade em pequena escala é determinada pela natureza convectiva das precipitações. As chuvas se iniciam eventualmente a partir de outubro, na chamada ‘pré-estação’, culminando com uma estação chuvosa concentrada entre fevereiro e maio.

“A sub-bacia possui, devido à baixa latitude, uma temperatura elevada em quase toda a sua extensão, sendo a temperatura média do mês mais frio sempre superior a 18 °C. O que faz variar o clima da área é a irregularidade do relevo e também a distribuição desigual das chuvas, tanto de um local para outro como de um ano para outro, sendo também irregular sua distribuição durante a estação chuvosa. A evaporação é alta em toda a bacia com taxas anuais entre 2.000 mm e 3.000 mm, com baixa variabilidade espacial e interanual.”

Segundo a classificação climática de Köppen, encontram-se na área os seguintes tipos climáticos:

AW’ – Quente e úmido, se estende pelo litoral setentrional no Rio Grande do Norte, avançando em certos trechos para o interior, abrangendo uma grande área do sertão do Rio Grande do Norte e Paraíba.

Bsh – Semi-árido quente. Abrange o restante da bacia.

### 4.3. DADOS HIDROLÓGICOS

Os dados hidrológicos usados nesse estudo, como já foi comentado, foram os mesmos trabalhados por Melo (2003), tendo como fonte de origem para os dados pluviométricos e fluviométricos necessários para elaboração do presente trabalho o banco de dados nacional disponibilizados pela ANEEL, de um total de 28 postos fluviométricos e 162 postos pluviométricos inseridos na área de estudo. Contudo, através de estudos realizados (UFPB/ANEEL, 2001), onde foi feito uma análise das séries, identificando falhas e aplicando testes de estacionariedade (teste de Wilkinox), apenas 13 postos fluviométricos passaram nos testes não-paramétricos e, portanto, são indicados em estudos de regionalização. Os demais postos possuem açudes construídos a montante, os quais interferiram no escoamento natural do rio na seção onde o posto está instalado, ocasionando a não homogeneidade das séries. Fazendo uso desta mesma análise e de seus resultados, foram escolhidos os postos indicados pela UFPB/ANEEL (2001) na presente pesquisa. Assim, tem-se a possibilidade de se comparar os resultados do modelo de redes neurais com os do modelo de regressão múltipla desenvolvido por Melo (2003) e com os dados observados dos 13 postos fluviométricos.

Para este trabalho, assim como foi para o de Melo (2003), foram selecionadas as vazões diárias correspondentes ao período chuvoso da região que se estende de fevereiro a maio de cada ano. Com isso, pode-se estabelecer, para cada ano, uma vazão média diária para esta estação.

Melo (2003), ainda chama atenção quanto às muitas falhas existentes nas séries, como muitas repetições de registros e interrupções, tomando-as mais curtas que a duração desejada e esclarece que não foram realizados preenchimentos das falhas e nem foi considerado um período comum para as séries das sub-bacias estudadas, para evitar perda de dados em séries já relativamente curtas, adotando-se aquelas séries isentas de falhas agravantes e tidas como estacionárias segundo os estudos já realizados pela UFPB/ANEEL (2001).

Segundo o estudo realizado pela UFPB/ANEEL (2001), os critérios usados na escolha dos postos fluviométricos finais foram:

1. “Exame da curva de descarga e análise de continuidade de volumes, com base nos relatórios de consistência da CPRM;
2. Representatividade da série em relação ao regime hidrológico da região (seqüência de anos secos e chuvosos);
3. Análise dos valores dos coeficientes de escoamento e vazão específica;

4. Análise dos períodos de falhas;
5. Resultados dos testes de estacionariedade;
6. Ficha de avaliação dos postos, com base no relatório de consistência da CPRM”.

A Figura 4.2, retirada do relatório da UFPB/ANEEL (2001), mostra a distribuição espacial dos postos pluviométricos e fluviométricos das sub-bacias estudadas.

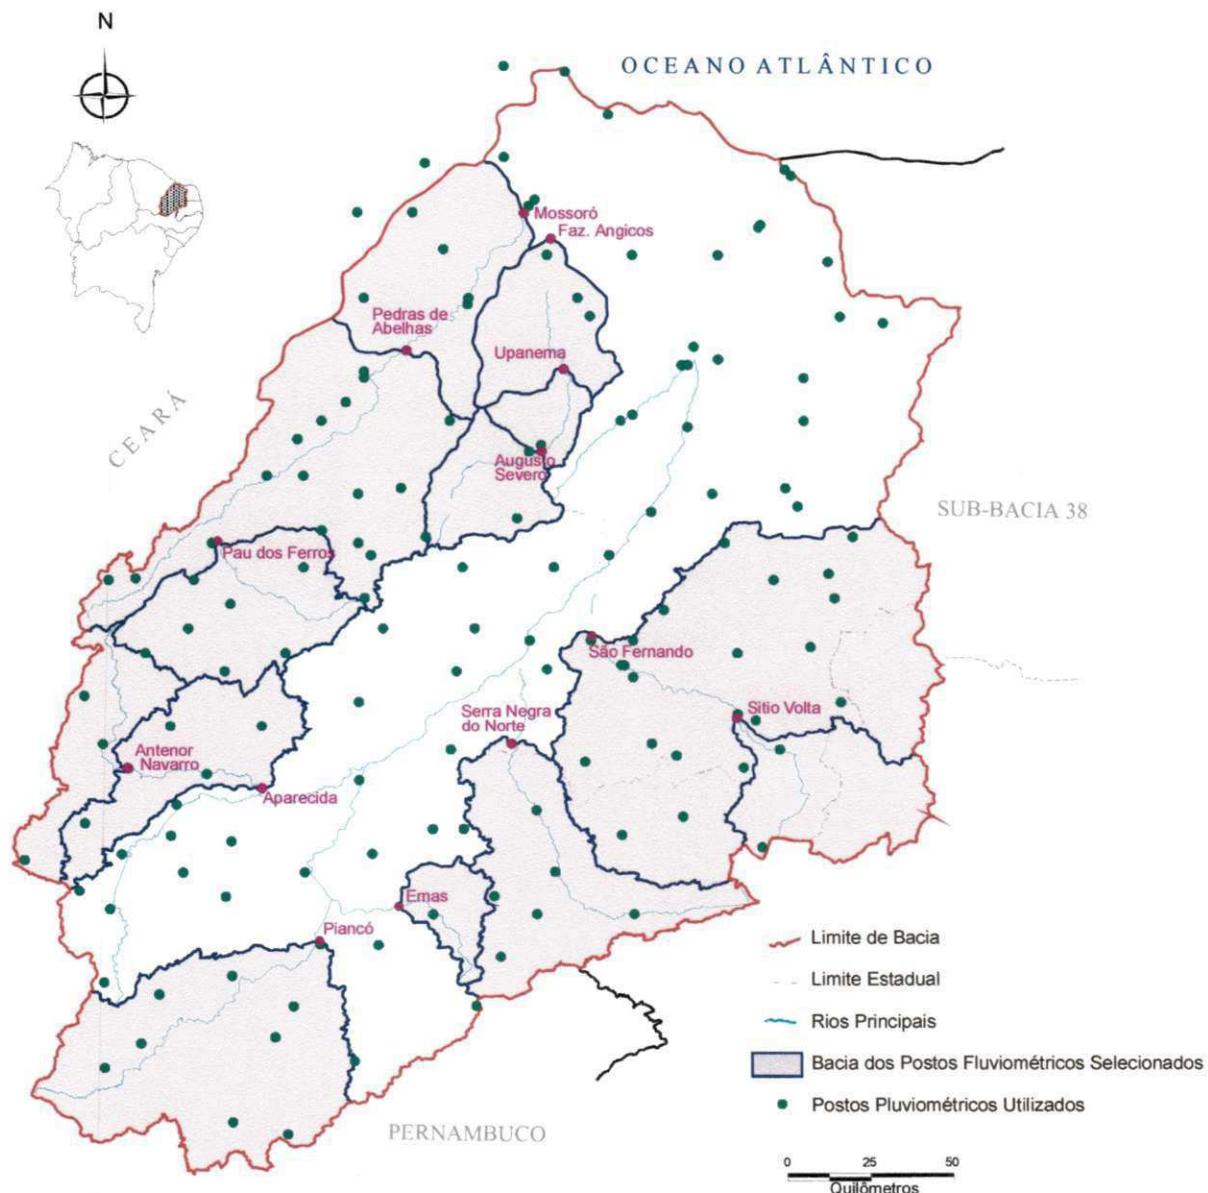


Figura 4.2 – Distribuição espacial dos postos pluviométricos e fluviométricos Seleccionados (Fonte: UFPB/ANEEL, 2001).

Os dados de pluviometria foram escolhidos seguindo alguns critérios para seleção dos postos, tais como ter pelo menos dez anos de dados e/ou quanto à sua localização e cobertura

geográfica de importância. A precipitação média diária durante a sazonalidade estudada para cada sub-bacia foi determinada através da média aritmética dos valores fornecidos pelos postos inseridos na mesma. No entanto, tais dados de precipitação precisavam ser convertidos do nível diário para o nível sazonal, isso foi feito por Melo (2003), agregando-se os valores médios diários de chuva dos meses de fevereiro a maio de cada ano e para cada sub-bacia. Porém, no caso das sub-bacias de Emas, nos anos de 1985 a 1999 e de Pau dos Ferros, de 1984 a 1992, observa-se apenas registros de vazão, não sendo possível obter dados de precipitação para tais períodos, motivo pelo qual esses anos foram retirados das séries destes postos.

As Tabelas 4.1 e 4.2, originalmente apresentadas por Melo (2003) em seu trabalho de pesquisa mostram a descrição dos postos fluviométricos e as séries de dados utilizados respectivamente, sendo que todos os dados de precipitação e vazão já estão nos níveis diários sazonais (apenas para a estação chuvosa) mostrando o comportamento das séries ao longo dos anos.

Contudo, nota-se uma deficiência na qualidade das séries históricas tanto pluviométricas quanto fluviométricas, com muitas lacunas e relativamente curtas, ficando longe do ideal desejado de séries longas com períodos coincidentes e sem interrupções. Percebe-se, na realidade, a existência de séries com extensões e períodos desiguais para cada sub-bacia, e isso certamente pode influenciar negativamente nos resultados a serem obtidos na modelagem.

Tabela 4.1 – Descrição das bacias dos postos fluviométricos (Melo, 2003)

<i>Código</i>	<i>Posto Fluviométrico</i>	<i>Área de Drenagem (km<sup>2</sup>)</i>	<i>Período de dados disponíveis</i>	<i>Número total de anos</i>	<i>Número de postos pluviométricos na bacia</i>
37030000	Pau dos Ferros	2.050	1964-83	20	10
37080000	Pedra de Abelhas	6.481	1964-99	36	25
37090000	Mossoró	9.447	1987-88 1990-99	12	32
37150000	Augusto Severo	1.083	1987-99	13	5
37185000	Upanema	1.414	1975-90 1993-99	23	6
37190000	Fazenda Angicos	2.547	1993-99	7	11
37260000	Antenor Navarro	1.514	1965-72 1985-99	22	7
37290000	Aparecida	3.429	1985-99	15	14
37340000	Piancó	4.550	1964-68 1970-89 1991-97 1999	33	11
37360000	Emas	395	1964-65 1967-72	8	5
37440000	Serra Negra	3.027	1922-60	39	9
37515000	Sítio Volta	1.794	1979-87	9	4
37570000	São Fernando	9.700	1963-87	25	23

Tabela 4.2 – Séries sazonais de vazão (m<sup>3</sup>/s) e precipitação (mm) utilizadas (Melo, 2003)

Ano	Antenor Navarro		Aparecida		Augusto Severo		Emas		Fazenda Angicos		Mossoró		Pau dos Ferros	
	Chuva	Vazão	Chuva	Vazão	Chuva	Vazão	Chuva	Vazão	Chuva	Vazão	Chuva	Vazão	Chuva	Vazão
1961														
1962														
1963														
1964							937,80	8,68					923,63	27,50
1965	642,87	6,92					816,62	9,49					705,60	26,95
1966													556,53	1,19
1967	876,80	19,60					1129,98	11,88					1084,1	52,05
1968	600,03	6,90					821,80	7,10					644,84	7,83
1969	679,28	5,98					545,60	3,10					509,14	0,37
1970	373,15	1,50					359,60	0,30					397,44	0,02
1971	577,00	1,33					931,14	4,67					698,51	0,62
1972	519,15	0,87					646,38	0,72					667,64	4,70
1973													718,68	9,44
1974													1197,6	67,94
1975													757,28	15,80
1976													678,44	29,35
1977													847,10	30,67
1978													560,11	7,49
1979													476,74	0,26
1980													689,12	19,03
1981													495,21	9,30
1982													473,16	0,32
1983													374,01	0,02
1984														4,30
1985	1145,7	49,12	1146,7	149,8				17,31						60,59
1986	596,00	3,35	598,00	22,24				18,09						22,52
1987	603,10	11,06	605,10	19,70	411,70	1,34		0,75			394,13	14,75		2,50
1988	684,50	5,54	686,50	21,23	626,10	4,97		9,40			682,55	25,68		0,49
1989	753,10	18,31	755,10	47,79	723,30	17,72		8,83						23,39
1990	212,70	0,02	213,70	2,32	396,30	0,15		0,34			381,55	3,47		0,02
1991	235,30	1,99	237,30	8,62	453,90	0,26		1,40			423,92	10,16		0,68
1992	625,90	3,08	627,90	16,77	393,40	8,43		0,60			491,02	13,52		0,52
1993	375,00	0,02	378,00	1,49	107,60	0,02		0,02	98,20	0,02	127,15	0,09		
1994	348,90	0,09	349,90	1,48	798,60	4,06		3,53	760,63	13,62	571,54	4,58		
1995	700,40	0,58	702,40	17,52	680,90	7,15		1,07	605,80	12,55	620,60	22,37		
1996	696,10	1,60	697,10	24,60	801,00	14,00		3,60	739,33	27,30	618,17	25,63		
1997	588,90	0,02	590,90	6,59	444,90	0,06		0,30	471,97	1,80	565,65	1,93		
1998	317,60	0,02	319,60	0,51	112,60	0,02		0,27	101,43	0,02	189,05	0,02		
1999	445,00	0,02	447,00	3,05	288,60	0,21		2,10	320,60	0,02	394,73	1,08		
Média	572,57	6,27	557,01	22,92	479,92	4,49	773,61	4,94	442,57	7,90	455,01	10,27	672,74	14,68
Desvio padrão	215,55	11,09	241,74	37,34	233,96	5,87	245,68	4,23	278,86	10,44	171,85	9,96	214,95	18,79

Tabela 4.2 – Continuação: Séries sazonais de vazão (m<sup>3</sup>/s) e precipitação (mm) utilizadas (Melo, 2003)

Ano	Pedra de Abelhas		Piancó		São Fernando		Sítio Volta		Upanema		Ano	Serra Negra do Norte	
	Chuva	Vazão	Chuva	Vazão	Chuva	Vazão	Chuva	Vazão	Chuva	Vazão		Chuva	Vazão
1961											1922	346,80	29,10
1962											1923	530,37	40,85
1963					520,32	29,37					1924	532,33	78,34
1964	859,98	62,95	774,90	45,47	748,27	67,49					1925	568,97	42,77
1965	674,27	66,53	572,65	12,08	564,59	71,38					1926	954,13	28,39
1966	517,31	3,92	378,18	0,85	388,02	8,49					1927	716,10	16,48
1967	976,72	107,95	1209,95	75,85	672,31	60,50					1928	452,17	9,84
1968	654,15	28,32	736,13	27,21	537,12	33,62					1929	765,07	30,92
1969	443,08	2,23			457,02	23,72					1930	414,27	10,69
1970	374,02	2,16	360,94	7,16	202,28	3,76					1931	613,77	7,60
1971	643,36	6,53	943,19	52,31	633,17	77,76					1932	165,23	0,25
1972	632,72	17,15	437,99	8,13	457,33	26,12					1933	263,67	16,52
1973	683,15	30,73	689,93	33,02	463,02	36,58					1934	782,40	34,39
1974	1076,1	172,44	1085,55	97,23	893,85	167,5					1935	730,07	45,39
1975	748,60	50,37	750,55	30,23	686,63	73,72			696,94	10,11	1936	351,26	5,45
1976	641,17	21,42	543,69	6,91	440,23	16,14			707,76	11,43	1937	634,52	25,19
1977	740,95	72,36	763,70	34,15	535,94	57,24			773,18	23,44	1938	368,24	15,85
1978	591,87	15,05	499,35	12,77	527,55	29,03			555,30	6,83	1939	502,83	9,86
1979	449,87	4,16	642,81	31,01	354,13	5,67	295,63	0,96	362,35	0,22	1940	636,80	16,75
1980	598,14	38,98	432,82	24,61	342,54	8,95	163,09	2,07	603,17	6,02	1941	387,82	4,39
1981	414,65	31,13	351,49	21,42	364,16	38,37	129,75	9,21	276,65	5,29	1942	202,87	2,64
1982	472,86	5,69	364,47	2,63	363,54	13,37	279,87	1,23	420,00	1,70	1943	283,17	0,93
1983	357,24	0,38	445,53	12,78	189,07	3,54	91,85	0,63	262,50	0,02	1944	475,77	9,93
1984	421,15	32,58	829,30	26,99	330,00	25,37	330,00	4,33	511,05	12,37	1945	729,00	15,58
1985	996,90	151,24	2052,30	166,87	495,10	177,9	495,10	39,36	1389,8	50,80	1946	385,92	7,30
1986	985,25	91,76	668,80	68,78	576,30	77,86	576,30	24,06	748,40	49,67	1947	799,52	12,43
1987	406,50	12,93	414,40	5,69	263,35	13,14	177,50	1,80	415,10	1,60	1948	597,00	15,91
1988	658,40	17,97	575,40	56,30					559,65	5,34	1949	602,37	7,17
1989	665,40	64,02	622,00	33,33					710,15	28,28	1950	625,05	23,21
1990	507,60	2,88							309,00	0,02	1951	364,52	1,52
1991	406,90	8,43	497,00	23,10							1952	515,18	7,22
1992	521,30	8,80	468,00	8,09							1953	227,44	0,93
1993	141,15	0,02	198,20	0,57					98,40	0,02	1954	588,68	8,02
1994	679,45	6,96	447,00	24,49					822,50	12,12	1955	531,78	7,89
1995	688,60	19,49	778,00	38,19					645,40	10,73	1956	615,17	7,15
1996	546,30	21,82	718,00	16,82					788,50	19,86	1957	582,08	10,50
1997	619,25	2,55	556,90	13,10					492,10	1,23	1958	160,70	0,02
1998	254,00	0,02							102,30	0,02	1959	472,75	12,99
1999	413,10	1,13	361,60	8,69					322,25	0,02	1960	598,15	7,97
Média	596,15	32,86	641,54	31,12	480,23	45,86	282,12	9,29	546,63	11,18	Média	514,72	16,11
Desvio padrão	209,07	42,09	335,97	33,28	168,03	45,47	165,42	13,53	282,56	14,63	Desvio padrão	187,14	15,782

#### 4.4. CARACTERÍSTICAS FÍSICAS

Faz-se necessário, para obtenção de um modelo hidrológico que represente adequadamente o complexo processo da transformação chuva-vazão, além das variáveis hidrológicas precipitação e vazão observadas, também as variáveis de natureza físicas das sub-bacias, uma vez que estas interferem no processo e, portanto, explicam a variável dependente vazão, a qual se quer conhecer. Para tanto, características físicas como área de drenagem ( $A$ ), comprimento do rio principal ( $L$ ), densidade de drenagem ( $D_d$ ), declividade média do rio ( $S$ ) entre outras, são de extrema importância e devem ser investigadas na tentativa de relacioná-las no modelo juntamente com a precipitação para se determinar a variável desejada vazão.

Estas características físicas da área de estudo foram extraídas por Melo (2003) através de cartas fornecidas pela SUDENE na escalas de 1:100.000, que foram digitalizadas e posteriormente calculadas tais características através de software de geoprocessamento para cada sub-bacia. Este trabalho realizado por Melo está disponível na Tabela 4.3.

Tabela 4.3 – Características físicas das sub-bacias estudadas (Melo, 2003)

<i>Características Físicas</i>	<i>Antenor Navarro</i>	<i>Aparecida</i>	<i>Augusto Severo</i>	<i>Emas</i>	<i>Fazenda Angicos</i>	<i>Mossoró</i>	<i>Pau dos Ferros</i>
Código	37260000	37290000	37150000	37360000	37190000	37090000	37030000
Área da Bacia (km <sup>2</sup> )	1.514	3.429	1.083	395	2.547	9.447	2.050
Perímetro da Bacia (km)	284,09	371,43	154,00	138,26	281,48	556,79	240,23
Cota Inicial (m)	800	800	250	850	250	700	620
Cota Final (m)	200	210	100	200	45	20	200
Desnível (m)	600	590	150	650	205	680	420
Comprimento Total da Drenagem (km)	1.555,81	3.668,13	1.158,13	494,40	2.256,57	7.783,24	2.516,77
Densidade de Drenagem (km/km <sup>2</sup> )	1,02761	1,06974	1,06937	1,25166	0,88597	0,82388	1,22769
Comprimento do Rio Principal (km)	79,37	142,31	60,36	49,59	141,99	241,15	65,13
Declividade do Rio Principal (km/m)	7,56	4,15	2,48	13,11	1,44	2,82	6,45
Precipitação Média Anual (mm)	824,76	826,31	789,37	778,62	708,55	792,21	863,23

Tabela 4.3 – Continuação: Características físicas das sub-bacias estudadas (Melo, 2003)

<i>Características Físicas</i>	<i>Pedra de Abelhas</i>	<i>Piancó</i>	<i>São Fernando</i>	<i>Sítio Volta</i>	<i>Upanema</i>	<i>Serra Negra do Norte</i>
Código	37080000	37340000	37570000	37515000	37185000	37440000
Área da Bacia (km <sup>2</sup> )	6.481	4.550	9.700	1.794	1.414	3.027
Perímetro da Bacia (km)	455,35	377,77	521,96	244,98	195,96	382,28
Cota Inicial (m)	700	650	600	600	250	720
Cota Final (m)	50	200	100	250	50	250
Desnível (m)	650	450	500	350	200	470
Comprimento Total da Drenagem (km)	7.060,82	6.942,51	9.442,01	1.341,44	1.534,30	3.278,88
Densidade de Drenagem (km/km <sup>2</sup> )	1,08947	1,52583	0,97340	0,74774	1,08507	1,08321
Comprimento do Rio Principal (km)	168,57	144,74	120,85	59,37	92,66	132,50
Declividade do Rio Principal (km/m)	3,86	3,11	4,14	5,90	2,16	3,55
Precipitação Média Anual (mm)	815,03	907,88	577,52	492,17	767,91	732,15

## 5. METODOLOGIA

### 5.1. DESCRIÇÃO GERAL DA METODOLOGIA

A metodologia seguida nesse trabalho tem duas fases preliminares: (a) seleção, coleta e tratamento dos dados e (b) construção do modelo, sendo cada fase composta de várias etapas. Neste trabalho buscou-se avaliar o modelo segundo três abordagens distintas, ou seja, analisou-se a capacidade da técnica de rede neural em simular a vazão sazonal segundo três aspectos de calibrações e validações diferentes, chamados de (i) validação cruzada; (ii) validação mista e (iii) validação clássica. Para isso, foi necessário realizar o tratamento e a separação dos dados para cada uma das abordagens diferentes de calibração e validação do modelo matemático para, por último, ser aplicado como modelo de previsão de vazão.

O que se pretende nesse trabalho é, fundamentalmente, agregar técnicas tradicionalmente aplicadas à regionalização de vazões à sua previsibilidade, ou seja, é compor uma metodologia que, através da criação de um modelo fundamentado na técnica de redes neurais seja capaz de simular e prever a vazão sazonal. Com isso, por um processo de transferência de funções e parâmetros, entre sub-bacias de mesma zona hidrológica, realizar a regionalização da previsão desta vazão.

Assim, após o modelo ser devidamente calibrado e ajustado, através da validação cruzada, este será empregado no prognóstico da vazão sazonal. Para isso, serão utilizados os parâmetros da RNA calibrados através dos dados observados de doze sub-bacias e, para a sub-bacia da validação, os dados de precipitações observadas serão substituídos por previsões de precipitações. Assim, a resposta do modelo será a previsão da vazão para a sub-bacia de interesse, e será possível a comparação desta vazão prevista com a vazão observada na estação fluviométrica da sub-bacia de verificação.

Com isso, será possível avaliar as incertezas em três níveis distintos: (i) com relação ao modelo de previsão de precipitação sazonal, (ii) com relação ao modelo hidrológico de simulação da vazão e (iii) finalmente, com relação à composição das últimas duas incertezas no processo de previsão de vazão média diária sazonal.

O fluxograma da Figura 5.1 descreve a metodologia aplicada nesse trabalho. O detalhamento de cada etapa será descrito abaixo:

1. Delimitação, seleção da região e coleta dos dados: Refere-se à escolha da região a ser estudada, que deve ser hidrologicamente homogênea, bem como, a coleta de informações e dados disponíveis para a região que viabilizem o estudo, são eles:

- Dados físicos: são os dados descritivos da região, como a área de drenagem, rios principais, declividade média dos rios principais, tipo de cobertura vegetal, relevo, formação geológica e pedológica, localização geográfica e política da região, caracterização climática, etc.
- Dados climatológicos: refere-se à coleta dos dados hidrológicos (precipitação e vazão) observados na região e, também, a geração de séries de precipitações previstas.

2. Construção do modelo de RNA: nesta etapa, uma vez averiguada a consistência das séries históricas a serem utilizadas, procede-se à calibração do modelo hidrológico de RNA através das características físicas mais relevantes das sub-bacias (como área de drenagem, comprimento do rio principal, declividade do rio, etc) e, também, dos dados hidrológicos. No presente estudo, calibrou-se o modelo para três situações distintas:

- Para a validação cruzada: onde o modelo de RNA foi calibrado com os dados de doze sub-bacias, para, então, ser validado na sub-bacia omitida durante a calibração, esse procedimento é repetido treze vezes, até que todas as sub-bacias tenham participado da validação do modelo;
- Para a validação mista: onde se divide a amostra, segundo agrupamentos de sub-bacias, em três grupos. Onde, o primeiro grupo, chamado de treinamento ou de calibração, é usado para a calibração do modelo e, simultaneamente, após a obtenção dos parâmetros, a cada calibração, o segundo grupo, chamado de teste de parada, é simulado, indicando, assim, o momento certo de parar o treinamento da rede. Finalmente, a validação do modelo é realizada para o terceiro grupo de sub-bacias, através dos parâmetros antes calibrados. Este procedimento é repetido, também, por treze vezes, sempre adiantando-se uma sub-bacia a cada conjunto, até que todas as sub-bacias participem de todas as fases.
- Para a validação clássica: trata-se, neste caso, de um método de validação muito empregada, onde se divide a amostra em duas partes fixas, uma para a calibração do modelo e a outra para a validação desse modelo.

3. Simulação da previsão da vazão sazonal nas bacias da validação: neste caso, será investigado o método de RNA e também o de Regressão Múltipla empregado por Melo (2003) na simulação da previsão da vazão sazonal nas bacias que, durante a validação cruzada, serviram para validar os modelos hidrológicos. Assim, com a previsão da precipitação sazonal como padrão de entrada dos modelos já calibrados pelas demais sub-bacias, estes servirão para estimar a previsão da vazão.

4. Comparação com a Regressão Múltipla (Melo, 2003): será possível, através da validação cruzada, comparar os desempenhos entre o modelo de RNA e o de Regressão Múltipla empregado por Melo (2003), tanto na simulação da vazão com dados observados de chuva, quanto na previsão da vazão feita a partir de dados de precipitação prevista.

5. Nesta etapa será possível, através de indicadores de desempenho, avaliar as incertezas em três níveis distintos:

- Análise das incertezas do modelo hidrológico na simulação da vazão através de dados de precipitação observada;
- Análise das incertezas do modelo de previsão de precipitação;
- Análise das incertezas do modelo de previsão da vazão, quando se propagam as duas últimas incertezas, obtendo a incerteza total do processo no processo da previsão;

6. Avaliação final da qualidade do modelo: é quando, diante dos resultados e das análises das incertezas, se pode julgar a eficiência dos modelos, tanto de RNA quanto o de Regressão Múltipla (Melo, 2003).

## 5.2. ETAPAS DA CONSTRUÇÃO DO MODELO DE RNA

A ferramenta usada na implementação da RNA foi o MATLAB. Sistema iterativo e linguagem de programação para computação técnica e científica em geral, o MATLAB permite a construção de “bibliotecas” de funções, denominada de *toolboxes*, que o torna apto a resolver classes particulares de problemas (Hanselman e Littlefield, 1999). A toolbox de Redes Neurais do MATLAB possui uma ampla versatilidade e flexibilidade, pois o seu uso possibilita a aplicação dos mais variados tipos de redes neurais, além de permitir a modificação de redes já existentes, como alterações no número de camadas ou mesmo de algoritmos de treinamento com uma particular facilidade de inserção. Uma vez treinada e extraído o conjunto ótimo de parâmetros da RNA, pode-se trabalhar na planilha eletrônica EXCEL e reproduzir este modelo já na fase de validação e na eventual comparação com o modelo de Regressão Múltipla (Melo, 2003).

Na implementação de uma rede neural artificial, algumas decisões devem ser tomadas, tais como a seleção dos dados – se de “treinamento” (expressão comumente utilizada para designar a calibração de uma rede neural) ou de validação, a arquitetura da rede, o algoritmo de treinamento e o número de iterações necessárias (Hines, 1997).

Na Figura 5.2, tem-se um fluxograma proposto por Hines (1997), que indica os passos necessários para a implementação de uma rede neural. Segundo o autor, a rede pode não convergir, ou seja, não alcançar um resultado desejado devido às seguintes razões:

- i. O algoritmo de treinamento converge para um mínimo local;
- ii. A rede não tem o número de graus de liberdade necessário para achar a relação entrada-saída;
- iii. Não há dados suficientes para executar o traçado desejado.

Quando ocorrer o primeiro caso, deve-se reiniciar os pesos e ruídos ou parâmetros da rede de forma a recomençar um novo treinamento. Um termo opcional, que tem a finalidade de evitar esse tipo de ocorrência, é a *taxa de momento* que, segundo Thomé e Marques (2003), é um valor positivo menor que um, cuja utilização visa imprimir uma dinâmica no treinamento, tal que, eventualmente, possibilite o algoritmo livrar-se de mínimos locais durante o processo de busca pelo mínimo global (ponto de menor erro). No segundo caso, a solução é a adição de mais camadas e/ou neurônios à rede. O último caso só pode ser resolvido com a alocação de mais dados para o conjunto de calibração da rede.

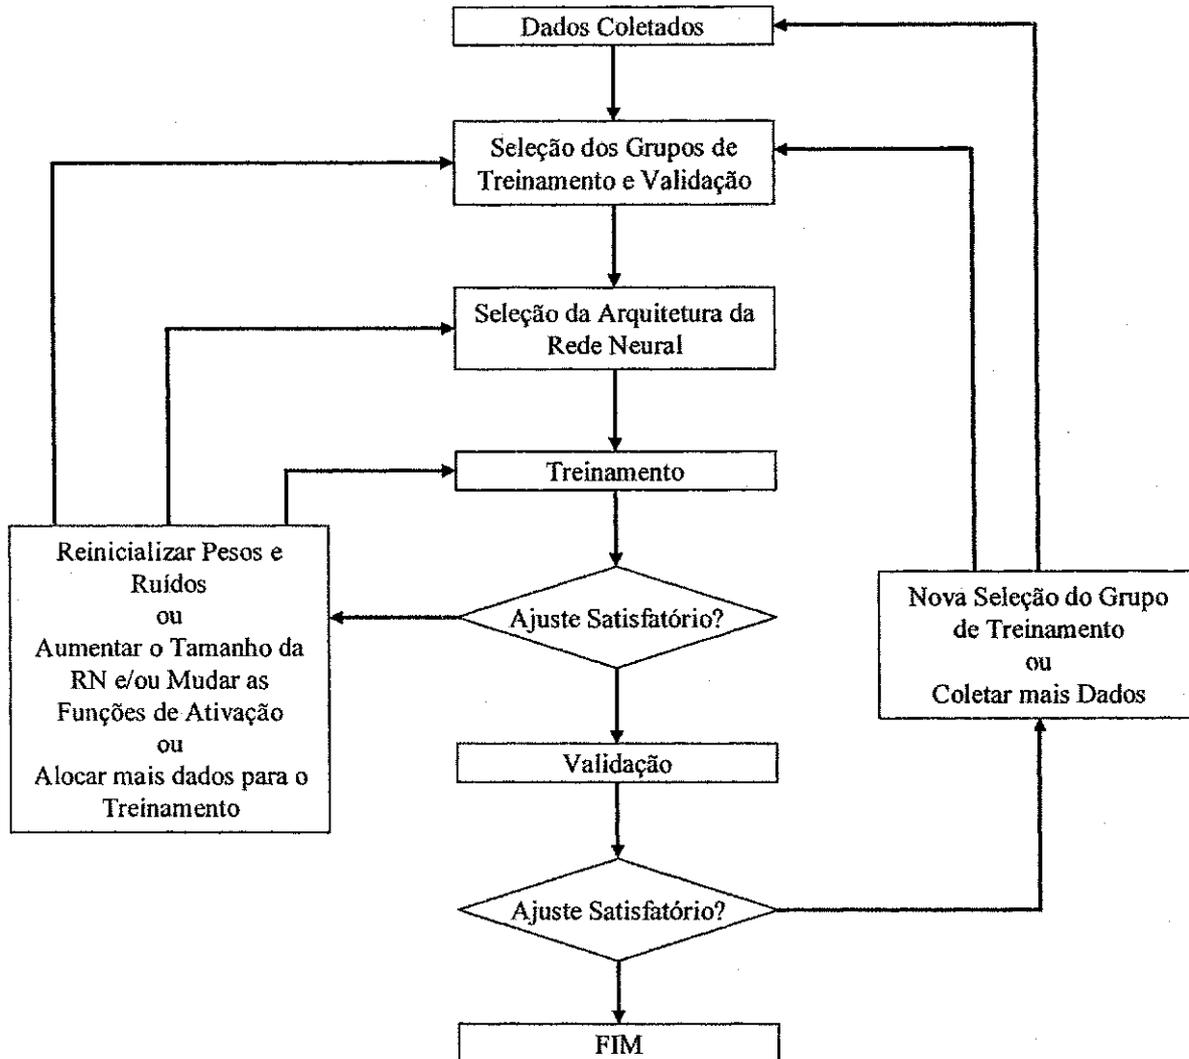


Figura 5.2 – Fluxograma do processo de treinamento e validação de uma RNA com aprendizado supervisionado (HINES, 1997).

### 5.3. VALIDAÇÃO DO MODELO

#### 5.3.1. CALIBRAÇÃO E VALIDAÇÃO CRUZADA

Uma vez definida a topologia e as relações matemáticas da rede neural, pode-se aplicar o modelo nas mais diversas maneiras. A primeira delas é na calibração e validação cruzada. Este procedimento foi usado por Melo (2003) e também escolhido nesse trabalho, uma vez que se tem como referencial o modelo clássico de regressão múltipla desenvolvido no trabalho de Melo (2003). Assim, pode ser realizada uma avaliação comparativa entre este e o presente trabalho com RNAs. Este tipo de validação, apesar de ser bastante difundido na literatura é passível de críticas, uma vez

que a calibração é realizada com todas as bacias, excetuando-se apenas a que será usada para validar o modelo. Contudo, representa de fato a finalidade desse trabalho, ou seja, a exploração ao máximo de todas as informações disponíveis para posterior uso em bacias com poucos dados, o que na prática ocorre num processo de regionalização.

O método é bastante simples e foi aplicado para as 13 sub-bacias em estudo, seguindo as seguintes etapas:

- a) selecionou-se os dados de 12 sub-bacias para a fase de calibração do modelo e os de uma para a validação;
- b) ajustou-se o modelo com as 12 sub-bacias para a determinação do conjunto ótimo de parâmetros da rede neural;
- c) realizou-se a validação do modelo, já ajustado pelas demais sub-bacias, utilizando-se os dados de entrada da sub-bacia selecionada para a realização da validação e comparou-se a resposta da rede neural com os dados observados de vazão da mesma.
- d) repetiram-se os passos anteriormente descritos, até que todas as sub-bacias participassem da fase de validação do modelo.

A Tabela 5.1 apresenta a conformação dos conjuntos de dados para a calibração e validação dos modelos com base na divisão por grupos de sub-bacias, da seguinte forma:

Tabela 5.1 – Conformação dos conjuntos de dados para a calibração e validação por divisão com base nas sub-bacias

<i>Grupos das sub-bacias</i>	<i>Calibração</i>	<i>Validação</i>
Grupo 1	AP; AS; EM; FA; MO; PF; PA; PI; SF; SV; UP e SN	AN
Grupo 2	AN; AS; EM; FA; MO; PF; PA; PI; SF; SV; UP e SN	AP
Grupo 3	AN; AP; EM; FA; MO; PF; PA; PI; SF; SV; UP e SN	AS
Grupo 4	AN; AP; AS; FA; MO; PF; PA; PI; SF; SV; UP e SN	EM
Grupo 5	AN; AP; AS; EM; MO; PF; PA; PI; SF; SV; UP e SN	FA
Grupo 6	AN; AP; AS; EM; FA; PF; PA; PI; SF; SV; UP e SN	MO
Grupo 7	AN; AP; AS; EM; FA; MO; PA; PI; SF; SV; UP e SN	PF
Grupo 8	AN; AP; AS; EM; FA; MO; PF; PI; SF; SV; UP e SN	PA
Grupo 9	AN; AP; AS; EM; FA; MO; PF; PA; SF; SV; UP e SN	PI
Grupo 10	AN; AP; AS; EM; FA; MO; PF; PA; PI; SV; UP e SN	SF
Grupo 11	AN; AP; AS; EM; FA; MO; PF; PA; PI; SF; UP e SN	SV
Grupo 12	AN; AP; AS; EM; FA; MO; PF; PA; PI; SF; SV e SN	UP
Grupo 13	AN; AP; AS; EM; FA; MO; PF; PA; PI; SF; SV e UP	SN

### 5.3.2. CALIBRAÇÃO E VALIDAÇÃO MISTA

Nesta abordagem é avaliada a capacidade da RNA em representar um conjunto maior de dados na fase de validação. Enquanto na validação cruzada o modelo era testado apenas com os dados de uma única sub-bacia por vez, nesse método o modelo é submetido a representar os dados de três sub-bacias juntas por vez. Isso foi introduzido com intuito de se aprofundar na avaliação desta técnica e também para que se evitassem análises precipitadas ou tendenciosas sobre a qualidade do modelo mediante resultados obtidos simplesmente através da validação cruzada. Neste

trabalho, chamou-se esse método de validação mista por ser, efetivamente, uma combinação entre o método de validação cruzada e um outro bastante divulgado na literatura especializada em redes neurais, onde se divide a amostra de dados segundo três conjuntos, que são (i) conjunto de treinamento ou calibração da rede; (ii) conjunto de teste de parada e (iii) conjunto de validação. Esse método é eficiente no trato com redes neurais, pois identifica, através do conjunto de parada, o ponto em que o modelo perde a capacidade de generalização e estabelece, portanto, o ponto de parada no treinamento, uma vez que, a rede após sucessivos treinamentos, testa seus parâmetros simultaneamente no conjunto de parada, obtendo, assim, indicativos de como esta poderá se comportar a novos dados. Finalmente, o conjunto de parâmetros que conduziu as respostas do modelo a um melhor ajustamento, tanto na fase de calibração quanto na de teste de parada, será o usado na validação do modelo.

Assim, a metodologia desenvolvida nessa etapa segue os seguintes passos:

- (a) Separou-se a amostra de dados nos três conjuntos a serem empregados (conjunto de calibração ou treinamento, teste de parada e validação);
- (b) Calibrou-se o modelo através do conjunto de treinamento e por meio dos parâmetros obtidos, simulou-se, simultaneamente, o conjunto de teste de parada;
- (c) Escolheu-se o melhor conjunto de parâmetros para a RNA mediante avaliação da estabilidade e dos coeficientes de determinação obtidos tanto na calibração do modelo quanto na simulação do conjunto de teste de parada;
- (d) Validou-se a rede neural já parametrizada, mediante ajuste aos dados das demais sub-bacias, por meio da apresentação ao modelo do conjunto de dados de entrada das sub-bacias selecionadas para validação e comparou-se a resposta da rede à vazão observada;
- (e) Repetiram-se os passos anteriormente descritos até que, adiantando-se uma sub-bacia a cada conjunto, todas as sub-bacias participassem de todas as etapas (calibração, teste de parada e validação), totalizando 13 situações nas simulações feitas incluindo dados de Serra Negra e em 12 quando da não inclusão destes;

A Figura 5.3 mostra o esquema desse método, onde, por exemplo, no caso 1, admitiu-se a seguinte ordem arbitrária de sub-bacias com seus respectivos dados: AN, AP, AS, EM, FA e MO fazendo parte do conjunto de calibração da rede, enquanto que PF, PA e PI são as sub-bacias que auxiliaram na escolha dos parâmetros, ou seja, formam o conjunto de teste de parada e, finalmente, SF, SV, UP e SN integram as sub-bacias que servirão na validação do modelo. Posteriormente, para os demais casos, como se percebe na mesma figura, adianta-se uma sub-bacia para cada conjunto a

ser trabalhado, de forma que todas participem de todas as fases, que são a calibração, teste de parada e validação.

Caso 1	AN AP AS EM FA MO	PF PA PI	SF SV UP SN
Caso 2	AN AP AS EM FA MO PF	PA PI SF	SV UP SN
Caso 3	AN AP AS EM FA MO PF PA	PI SF SV	UP SN
Caso 4	AN AP AS	EM FA MO PF PA PI	SF SV UP SN
Caso 5	AN AP AS EM	FA MO PF PA PI SF	SV UP SN
Caso 6	AN AP AS EM FA	MO PF PA PI SF SV	UP SN
Caso 7	AN AP AS EM FA MO	PF PA PI SF SV UP	SN
Caso 8	AN AP AS EM FA MO PF	PA PI SF SV UP SN	
Caso 9	AN AP AS EM FA MO PF PA	PI SF SV UP SN	
Caso 10	AN AP AS EM FA	MO PF PA PI SF SV UP SN	
Caso 11	AN AP AS EM FA MO	PF PA PI SF SV UP SN	
Caso 12	AN AP AS EM FA MO PF	PA PI SF SV UP SN	
Caso 13	AN AP AS EM FA MO PF PA	PI SF SV UP SN	

**Legenda:**

□ Conjunto da calibração

▒ Conjunto do teste de parada

▓ Conjunto da validação

Figura 5.3 – Representação da distribuição e organização dos conjuntos criados na calibração e validação mista.

### 5.3.3. CALIBRAÇÃO E VALIDAÇÃO CLÁSSICA

Essa última abordagem, na busca de se medir a eficiência da técnica de redes neurais como modelo hidrológico capaz de simular e prever vazões, foi possível devido às últimas análises do comportamento do modelo feitas com relação à validação cruzada e mista. Esse tipo de validação é tida como clássica no meio hidrológico, onde se divide a amostra de dados em dois conjuntos fixos, sendo um destinado a calibrar o modelo e o outro destinado à sua validação. Os passos seguidos para implementação desse método foram:

- (a) separação da amostra em dois conjuntos seguindo a forma: os dados de seis sub-bacias para o conjunto de calibração da rede neural e os dados das outras seis sub-bacias para servirem para a fase de validação do modelo.
- (b) calibração do modelo com o conjunto de dados da calibração;
- (c) validação do modelo com o conjunto de dados reservados a essa finalidade e comparação entre a resposta da rede e a vazão observada;

## 5.4. PREVISÃO DA PRECIPITAÇÃO E DA VAZÃO

### 5.4.1. EXTRAÇÃO DA PREVISÃO DE PRECIPITAÇÃO

Os modelos globais de circulação atmosférica, sobre os trópicos, são capazes de simular aspectos importantes da precipitação sazonal e em larga escala (Marengo *et al.*, 2003). Hoje em dia, há previsões experimentais produzidas por modelos atmosféricos regionais com definição espacial de quilômetros e com definição temporal diária (Galvão *et al.*, 2005).

Segundo Galvão *et al.* (2005), os estudos mostram que a observação da temperatura na superfície do mar, sobre os oceanos, permite aos Modelos de Circulação Global Atmosférico (MCGAs) simularem a variabilidade interanual da precipitação sobre o Nordeste com uma elevada exatidão. Assim, com os recentes avanços é possível produzir previsões sazonais de confiança para a precipitação sobre a região.

Os dados de previsão de precipitação, usados neste trabalho, foram disponibilizados pela Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME). Para a sua geração, a FUNCEME usou o modelo atmosférico regional RSM (*Regional Spectral Model*) do *National Center for Environmental Prediction* (NCEP), dos Estados Unidos, acoplado ao modelo global ECHAM 4.5 do *Max Planck Institute*, de Hamburgo, Alemanha. O RSM foi executado, para a região Nordeste do Brasil, para produzir previsões diárias de precipitação durante seis meses, a partir do dia 1 de janeiro de cada ano de 1971 a 2000.

As estimativas da precipitação diária foram realizadas em simulações de dez membros diferentes para o período estipulado em uma grade retangular de 60 X 60 km. Interpolações foram realizadas para obter a precipitação em pontos fora da grade que, no caso de estudo, foram as coordenadas do centróide de cada sub-bacia. Assim, para cada membro, obteve-se uma série simulada de precipitações previstas diferente. É necessária a correção das anomalias desses dados por meio da Equação 5.1 de normalização.

$$P_{pc} = \bar{P}_o + \left( \frac{\sigma_o}{\sigma_s} \right) (P_s - \bar{P}_s) \quad (5.1)$$

onde:

$P_{pc}$  = Precipitação diária prevista corrigida;

$\overline{P_o}$  = Precipitação média diária observada (média móvel de 15 dias antes do evento atual e 15 dias depois entre todos os anos da série);

$\sigma_o$  = Desvio padrão móvel de 30 dias da precipitação diária observada (15 dias antes do evento atual e 15 dias depois entre todos os anos da série);

$\sigma_s$  = Desvio padrão móvel de 30 dias da precipitação simulada (15 dias antes do evento atual e 15 dias depois);

$P_s$  = Precipitação simulada a ser corrigida (evento atual);

$\overline{P_s}$  = Precipitação média móvel diária simulada (15 dias antes do evento atual e 15 dias depois);

Então, para cada membro efetuou-se a correção da precipitação simulada e, a partir disso, obteve-se, através dos dez membros, um valor médio de previsão de precipitação diária para cada sub-bacia em cada ano tratado. No entanto, estes dados simulados de precipitações tinham que ser convertidos da escala diária, em que se encontravam, para a sazonal, e isso foi realizado da mesma forma que foi para os dados de precipitação diária observada: acumularam-se os dados de precipitações previstas entre os meses de fevereiro a maio de cada ano e para cada sub-bacia. As simulações, no entanto, apresentam algumas limitações:

- As séries disponíveis corrigidas foram as dos anos de 1971 a 1999 e, com isso, parte das séries das sub-bacias que possuíam dados observados antes desse período não puderam ser empregados nessa etapa; vale salientar que as séries de dados fluviométricos já eram relativamente curtas;
- Existem limitações de cobertura geográfica, uma vez que, tais simulações estão definidas geograficamente entre a longitude  $-39^{\circ}58'37''$  a  $-0^{\circ}32'24''$  e latitude  $-12^{\circ}05'45''$  a  $-6^{\circ}13'52''$ . Assim, como cerca da metade das sub-bacias aqui tratadas não estão dentro dessa área de abrangência do modelo, estas não puderam ser estudadas nessa etapa.

A Tabela 5.2 apresenta as sub-bacias que estão dentro da área de cobertura do modelo com suas coordenadas e respectivos anos coincidentes com os da série de dados observados, bem como a quantidade de anos para cada sub-bacia.

Tabela 5.2 – Sub-bacias atendidas pelo modelo de previsão de precipitação

<i>Sub-bacias</i>	<i>Longitude</i>	<i>Latitude</i>	<i>Anos extraídos</i>	<i>Quant. de anos</i>
Pau dos Ferros	-38°07'33"	-6°18'00"	1971-1983	13
Antenor Navarro	-38°33'11"	-6°41'22"	1971-72 1986-99	16
Aparecida	-38°16'49"	-6°43'33"	1985-1999	15
São Fernando	-36°46'16"	-6°32'05"	1971-1987	17
Sítio Volta	-36°31'33"	-6°48'00"	1979-1987	9
Emas	-37°34'16"	-7°08'06"	1971-1972	2
Piancó	-38°12'27"	-7°32'38"	1971-89 1991-97 1999	27

Nota-se, na Tabela 5.2, que a sub-bacia de Emas possui apenas dois anos coincidentes. Assim, decidiu-se por não incluir esta nessa etapa de simulação da previsão de vazão média diária, restando apenas seis sub-bacias a serem estudadas.

#### 5.4.2. PREVISÃO DA VAZÃO

Uma vez extraídos os dados de previsão de precipitação sazonal, estes poderão substituir os dados de precipitação observada na fase de teste do modelo para, com isso, ter-se a previsão da vazão média diária sazonal referente à sub-bacia de interesse. Para tal, fez-se uso dos modelos de RNAs e de Regressão Múltipla (Melo, 2003) já calibrados e testados conforme a validação cruzada. Assim, pode-se também comparar a performance entre estes métodos empíricos na previsão. Por exemplo, na previsão da vazão para o posto da sub-bacia de Pau dos Ferros, utilizou-se os modelos já calibrados pelas demais sub-bacias excetuando-se esta, que será avaliada. Da mesma forma procedeu-se para com as outras cinco sub-bacias que foram consideradas.

### 5.5. ÍNDICES DE DESEMPENHO

Os indicadores de desempenhos usados para avaliação e comparação entre os resultados dos modelos de RNA e regressão múltipla de Melo (2003), foram o coeficiente de determinação ( $R^2$ ); o erro padrão da estimativa (EPE) e o erro relativo (ER), dados pelas seguintes expressões:

- **Coeficiente de Determinação ( $R^2$ ):** O coeficiente de determinação indica quanto a função de regressão explica as variações entre as variáveis envolvidas.

$$R^2 = \frac{\sum (Q_{obs} - \overline{Q_{obs}})(Q_{calc} - \overline{Q_{calc}})}{\sqrt{\sum (Q_{obs} - \overline{Q_{obs}})^2 (Q_{calc} - \overline{Q_{calc}})^2}} \quad (5.2)$$

- **Erro Padrão de Estimativa (EPE):** O valor ótimo desta medida estatística é zero, tendendo a zero tão quão próximo seja o valor estimado do observado.

$$EPE = \sqrt{\frac{\sum_{i=1}^n (Q_{obs}^i - Q_{calc}^i)^2}{n-1}} \quad (5.3)$$

- **Erro Relativo (ER):** Este índice estatístico reflete a magnitude do erro percentual entre as vazões médias diárias sazonais observadas e a simuladas. Valores negativos indicam superestimação e positivos, subestimação em relação aos escoamentos sazonais observados, tendo resultado ótimo tendendo a zero.

$$ER(\%) = \frac{\sum_{i=1}^n (Q_{obs}^i - Q_{calc}^i)}{\sum_{i=1}^n (Q_{obs}^i)} 100 \quad (5.4)$$

onde  $Q_{obs}$  e  $Q_{calc}$  são as variáveis que estão sendo correlacionadas e representam a vazão observada e a vazão calculada pelo modelo, respectivamente;  $\overline{Q_{obs}}$  e  $\overline{Q_{calc}}$  são os valores médios da série de vazão observada e da série de vazão calculada, respectivamente.

## 6. RESULTADOS E DISCUSSÃO

### 6.1. CONSTRUÇÃO DO MODELO DE RNA

Determinou-se a topologia da RNA por tentativas. Na primeira avaliação, com uma camada escondida, obteve-se dez diferentes estruturas de redes, com estas variando de um até dez neurônios na camada intermediária.

Os resultados dessas simulações podem ser vistos na Tabela 6.1. Nota-se que, as redes com apenas uma camada escondida e que possuem mais de dois neurônios nesta apresentam indícios de superajustamento. Apesar de que, no treinamento, o modelo apresente respostas com um bom ajuste, com relação ao coeficiente de determinação (Eq. 5.2) se mantendo acima de 80%, o mesmo não ocorre na fase de validação, quando pode-se observar que para a rede com dez neurônios o coeficiente de determinação chegou a níveis muito baixos.

A rede com apenas um neurônio na camada escondida é aquela com maior estabilidade, porém o ponto ótimo para as redes com uma camada intermediária ocorre para o caso onde se têm dois neurônios. Esta rede, além de apresentar uma boa estabilidade, tanto na fase de calibração quanto na de validação, apresenta coeficientes de determinação médios superiores à rede com apenas um neurônio na camada escondida. Apesar de, na simulação de número oito, esta estrutura não tenha conseguido obter parâmetros capazes de generalização, com um coeficiente de determinação de apenas 16%; as chances de sucesso com esta estrutura são grandes, cerca de 90%, uma vez que, das dez simulações realizadas com esta estrutura obteve-se sucesso em nove.

Tabela 6.1 – Coeficientes de determinação obtidos na investigação da estrutura da rede neural artificial com uma camada escondida

Nº de Iterações	1 Neurônio		2 Neurônios		3 Neurônios		4 Neurônios		5 Neurônios	
	Treino	Valid.								
	$R^2_T$ (%)	$R^2_V$ (%)								
1	70	69	76	76	82	28	81	52	82	63
2	70	69	76	76	80	89	81	36	84	15
3	70	69	76	93	81	59	82	60	84	35
4	70	69	79	84	82	63	83	12	83	55
5	70	69	79	84	81	70	82	70	84	6
6	70	69	76	83	81	4	82	39	83	0
7	70	69	76	74	81	66	82	70	84	3
8	70	69	79	16	82	83	83	6	83	0
9	70	69	75	89	82	75	83	0	83	0
10	70	69	76	93	82	6	82	54	83	4
$R^2_{Médio}$	70	69	77	77	81	54	82	40	83	18

Tabela 6.1 – Continuação: Coeficientes de determinação obtidos na investigação da estrutura da rede neural artificial com uma camada escondida

Nº de Iterações	6 Neurônios		7 Neurônios		8 Neurônios		9 Neurônios		10 Neurônios	
	Treino	Valid.	Treino	Valid.	Treino	Valid.	Treino	Valid.	Treino	Valid.
	$R^2_T$ (%)	$R^2_V$ (%)	$R^2_T$ (%)	$R^2_V$ (%)						
1	84	0	13	11	83	1	87	0	85	3
2	83	4	84	69	85	61	84	11	84	0
3	83	0	77	0	83	0	85	18	87	2
4	80	2	84	0	74	7	81	9	85	0
5	83	2	82	2	84	0	84	6	87	1
6	84	0	83	1	86	0	86	0	52	1
7	85	48	84	1	13	1	84	0	84	0
8	83	10	2	0	84	5	84	0	40	1
9	30	4	85	0	86	3	85	0	84	0
10	84	0	85	1	84	0	12	0	86	0
$R^2_{Médio}$	78	7	68	9	76	8	77	5	77	1

A Figura 6.1 mostra a variação do coeficiente de determinação médio para cada estrutura analisada para redes com uma única camada escondida. Percebe-se claramente uma diminuição deste coeficiente na fase de validação quando se têm redes com mais de três neurônios na camada intermediária. Embora isso não se repita também na calibração, nota-se visualmente que, para este caso, a melhor rede é aquela com dois neurônios na camada escondida, pois consegue manter o mesmo nível de qualidade do ajuste obtido na calibração também na validação, sendo aquele que apresenta maior coeficiente de determinação médio para ambos os ajustes.

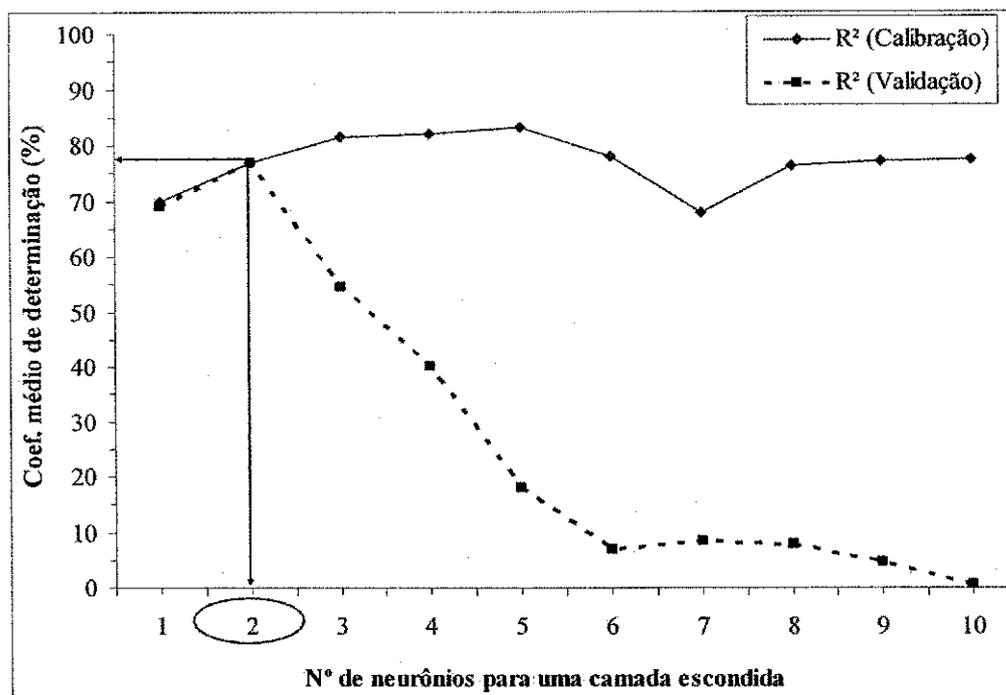


Figura 6.1 – Variação do coeficiente de determinação médio com o número de neurônios para uma camada escondida.

Novas experiências foram feitas, agora variando também o número de camadas intermediárias. A Tabela 6.2 mostra os coeficientes de determinação obtidos na fase de calibração e validação para três estruturas de redes neurais, usando duas camadas escondidas. Com a experiência adquirida, verifica-se que, para as estruturas 3-2-1-1 e 3-3-2-1, ocorrem vestígios de superajustamento. As redes não conseguem generalizar seus parâmetros de forma adequada na validação, não alcançando um bom ajuste das suas saídas às desejadas, uma vez que, para estes dois casos, os coeficientes médios de determinação estão na faixa de 42 a 43%. Com isso, não há mais necessidade de se continuar aumentando o número de neurônios nestas camadas.

Ainda pela Tabela 6.2, observa-se que a estrutura 3-1-1-1 é comparável com a estrutura 3-2-1 (Tabela 6.1). Apresentam-se como as estruturas mais estáveis, sendo que a primeira não consegue atingir a convergência apenas na simulação 5, alcançando um nível de 90% de convergência. Com isso, seu coeficiente de determinação médio caiu para 63% no treinamento e para 68% na validação.

Tabela 6.2 – Coeficientes de determinação obtidos no ajuste para a calibração e validação para estruturas de RNA com duas camadas escondidas

<i>Estruturas com duas camadas escondidas</i>						
<i>Nº de Iterações</i>	<i>3-1-1-1</i>		<i>3-2-1-1</i>		<i>3-3-2-1</i>	
	<i>Treino</i> $R^2_T$ (%)	<i>Valid.</i> $R^2_V$ (%)	<i>Treino</i> $R^2_T$ (%)	<i>Valid.</i> $R^2_V$ (%)	<i>Treino</i> $R^2_T$ (%)	<i>Valid.</i> $R^2_V$ (%)
1	70	76	81	49	84	68
2	70	76	81	53	84	75
3	70	76	15	76	83	57
4	70	76	81	49	83	46
5	0	0	81	53	84	25
6	70	76	81	49	82	13
7	70	76	0	0	83	0.4
8	70	76	81	53	83	59
9	70	76	79	0.7	0.5	3
10	70	76	81	52	83	76
$R^2_{\text{Médio}}$	63	68	66	43	75	42

Nota-se, através dos resultados, que topologias de redes com um pequeno número de neurônios são as mais adequadas para este estudo, mostrando-se instáveis já com duas camadas escondidas. No entanto, ainda foi investigado redes com três camadas escondidas. O resultado em termos de  $R^2$  obtido nas fases de calibração e validação do modelo pode ser encontrado na Tabela 6.3. Percebe-se que, para este caso, nenhuma das estruturas mostrou-se satisfatória no ajuste para ambas as fases, revelando-se sempre muito instáveis. Nota-se claramente a existência de superajustamento para esta topologia de rede, que é quando o modelo se especializa nos dados da calibração e, como consequência, apresenta uma baixa taxa de acurácia para com os novos dados da validação, atingindo na fase de validação coeficiente médio de determinação de 56% para a estrutura 3-1-1-1-1 e de 44% para a estrutura 3-3-2-1-1.

Tabela 6.3 – Coeficientes de determinação obtidos no ajuste para a calibração e validação para estruturas de RNA com três camadas escondidas

<i>Estruturas com três camadas escondidas</i>						
<i>Nº de Iterações</i>	<i>3-1-1-1-1</i>		<i>3-2-1-1-1</i>		<i>3-3-2-1-1</i>	
	<i>Treino</i> $R^2_T$ (%)	<i>Valid.</i> $R^2_V$ (%)	<i>Treino</i> $R^2_T$ (%)	<i>Valid.</i> $R^2_V$ (%)	<i>Treino</i> $R^2_T$ (%)	<i>Valid.</i> $R^2_V$ (%)
1	70	77	82	50	84	37
2	4	13	82	50	85	49
3	70	77	80	89	84	66
4	70	77	82	50	83	6
5	70	77	80	70	84	0.1
6	20	36	82	50	80	88
7	19	0	70	77	85	41
8	81	49	82	50	9	11
9	70	77	0	0	84	70
10	70	77	6	9	83	67
$R^2_{\text{Médio}}$	54	56	65	50	76	44

A Figura 6.2 apresenta o comportamento do coeficiente médio de determinação obtido nas fases de calibração e validação, com as várias topologias de redes testadas com mais de uma camada intermediária. Destacam-se os resultados para a estrutura 3-1-1-1, tida como a melhor topologia encontrada para redes com mais de uma camada escondida. Para as topologias 3-2-1-1 e 3-3-2-1 ocorre um aumento do  $R^2$  médio para a fase de treinamento da rede sob pena, devido ao superajustamento, de diminuição deste índice para a fase de validação. O mesmo pode ser notado nos exemplos de topologia com três camadas internas, desde a 3-2-1-1-1 até a 3-3-2-1-1.

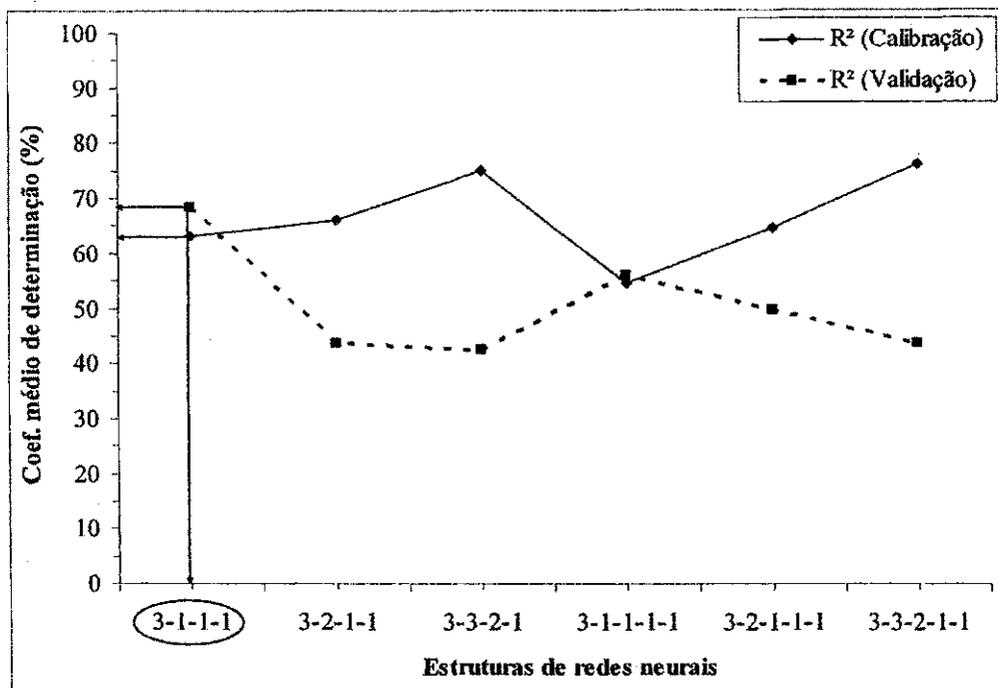


Figura 6.2 – Variação do coeficiente de determinação médio para estruturas de redes com mais de uma camada escondida.

A análise final, a respeito de qual topologia será adotada, recai então sobre as estruturas 3-2-1 e 3-1-1-1. Para esta última, o processamento dos neurônios nas camadas intermediárias não se dá de forma paralela, configurando numa rede com poucas conexões. Tendo como vantagem principal uma boa estabilidade associada a um pequeno número de parâmetros, que são apenas oito. A primeira estrutura, que também apresenta uma boa estabilidade, possui onze parâmetros. No entanto, como foi mostrado, a topologia 3-2-1 apresentou-se com uma maior capacidade de ajustar-se às saídas desejadas, visto a superioridade do índice de desempenho adotado nessa investigação para ambas as fases de calibração e validação do modelo. Esse resultado está de acordo com as afirmações encontradas na literatura, que asseguram que redes com uma única camada escondida de neurônios sigmóides, que recebem entradas diretamente e, então, transmitem suas saídas para uma camada de neurônios lineares, tem provado ser capazes de aproximar qualquer função contínua com

satisfatória exatidão, sendo considerado como aproximador universal de funções (Hines, 1997; Demuth e Beale, 1998; Valença e Ludermir, 1999a).

Logo, baseado nesse resultado, a arquitetura do modelo de rede neural que será empregada nesse trabalho terá a configuração 3-2-1, ou seja, três neurônios na camada de entrada, dois neurônios na camada escondida e um neurônio na camada de saída. Assim, a configuração da rede neural usada nesse trabalho tem o formato da Figura 6.3.

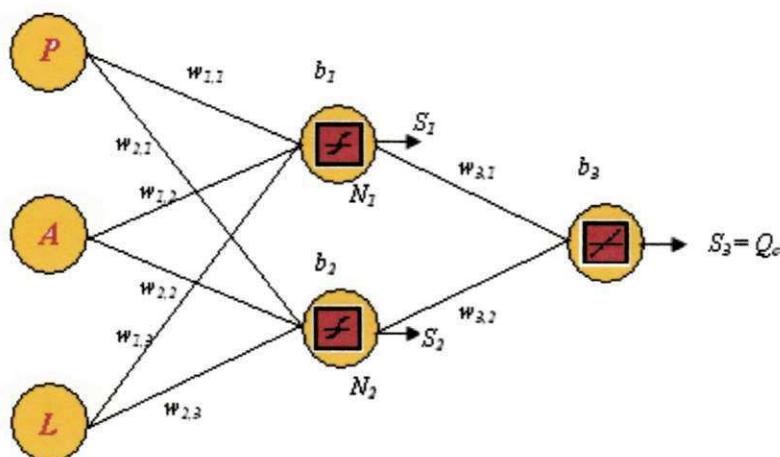


Figura 6.3 – Arquitetura da rede neural.

onde:

P = Precipitação sazonal;

A = Área de drenagem;

L = Comprimento do rio principal;

$W_{ij}$  = Pesos (parâmetros da rede neural);

$b_i$  = Bias ou ruídos (parâmetros da rede neural);

$N_i$  = Neurônios de processamentos;

$S_i$  = Saídas dos neurônios;

$Q_c$  = Vazão média diária sazonal calculada pela rede.

Esta topologia de rede neural é do tipo múltiplas camadas MLP, conexões unidirecionais (*feed-forward*), tendo três neurônios na camada de entrada, cada um responsável pelo recebimento

de um padrão de entrada ou variável explicativa no sistema (precipitação, área e comprimento do rio principal); dois neurônios na camada escondida trabalhando com funções de ativação tangente hiperbólica e um neurônio na camada de saída, onde, por meio de uma função linear, integra-se às saídas propagadas das EP's e se extrai a resposta referente à vazão média diária sazonal.

Os neurônios da entrada não realizam nenhum processamento nos dados, apenas os armazenam e, através das conexões, os repassa já ponderados para os neurônios da camada intermediária, verdadeiros responsáveis pela identificação do problema e processamento dos dados. Assim, os neurônios intermediários integram essas informações para processamento e, posteriormente, propagam através das conexões estes sinais novamente ponderados até o neurônio da saída, responsável pela integração de todos os sinais a ele advindos e pela adição de mais um parâmetro. Dessa forma, baseado na Figura 6.3, chega-se à Equação 6.6 geral do modelo de rede neural artificial desenvolvida nesse trabalho da seguinte forma:

$$N_1 = P \cdot w_{1,1} + A \cdot w_{1,2} + L \cdot w_{1,3} + b_1 \quad (6.1)$$

$$N_2 = P \cdot w_{2,1} + A \cdot w_{2,2} + L \cdot w_{2,3} + b_2 \quad (6.2)$$

$$S_1 = \left[ \frac{2}{(1 + \ell^{(-2 \cdot N_1)})} - 1 \right] \cdot w_{3,1} \quad (6.3)$$

$$S_2 = \left[ \frac{2}{(1 + \ell^{(-2 \cdot N_2)})} - 1 \right] \cdot w_{3,2} \quad (6.4)$$

$$S_3 = S_1 + S_2 + b_3 \quad (6.5)$$

$$S_3 = Q_c = \left[ \frac{2}{(1 + e^{(-2 \cdot N_1)})} - 1 \right] \cdot w_{3,1} + \left[ \frac{2}{(1 + e^{(-2 \cdot N_2)})} - 1 \right] \cdot w_{3,2} + b_3 \quad (6.6)$$

## 6.2. ANÁLISE DO AJUSTE E VALIDAÇÕES DO MODELO

Como foi mencionado, um dos objetivos de se empregar o mesmo método de validação utilizado por Melo (2003) foi o de poder comparar os resultados obtidos com o modelo de Regressão Múltipla e o de RNA. Melo (2003), ao realizar o tratamento dos dados, retirou o ano de 1985 da série do posto de Piancó, por este ser um ano anômalo, uma vez que, o elevado registro da precipitação sazonal, de 2052,3 mm, é um fato incomum para a região. Para que a comparação entre os desempenhos dos modelos tenha como base a igualdade de condições, decidiu-se também por desconsiderar este ano da série do posto de Piancó. Assim, realizou-se o presente estudo com um total de 261 pares de dados chuva-vazão, obtidos das 162 estações pluviométricas e 13 estações fluviométricas, já comentadas anteriormente.

Melo (2003) selecionou quatro variáveis físicas independentes, para serem relacionadas no modelo matemático, com a finalidade de explicarem a variável desejada vazão, porém, apenas duas passaram no teste  $F$  de significância, sendo elas: a área de drenagem ( $A$ ) e o comprimento do rio principal ( $L$ ); justificando, com isso, a eliminação das variáveis densidade de drenagem ( $D_d$ ) e declividade média do rio ( $S$ ) do modelo.

No presente trabalho, ainda se tentou implementar todas estas variáveis no modelo de redes neurais, na tentativa de apresentar uma melhor resposta, porém, não foi notada nenhuma sensibilidade do modelo às variáveis já descartadas por Melo (2003), de forma que, os dados de entrada do modelo de redes neurais foram a área de drenagem ( $A$ ); o comprimento do rio principal ( $L$ ) e a variável meteorológica precipitação média sazonal ( $P$ ). A variável observada vazão média diária sazonal ( $Q$ ) também é apresentada à rede, porém, não como entrada, mas sim como exemplo de resposta desejada.

Para uma pré-avaliação do comportamento dos modelos, fez-se uma análise inicial do ajuste obtido entre as vazões observadas e as calculadas para ambos os modelos com todos os dados disponíveis de todas as sub-bacias juntas (ver Figuras 6.4 e 6.5). Em princípio, o modelo desenvolvido por Melo apresentou um coeficiente de determinação de 67%, próximo do valor obtido pelo modelo de redes neurais, que foi de 69%. Assim, para o modelo de regressão múltipla apenas 33% das variações entre as variáveis não foram explicadas, enquanto que para o modelo de RNA 31% dessas variações não foram explicadas pelo modelo.

Verificou-se, em especial, que mais uma vez o evento do ano de 1985, agora da série do posto de São Fernando, foi o principal responsável pela depreciação deste índice de desempenho (ver Figura 6.4), fato que, sem o mesmo, o modelo de RNA melhora consideravelmente os resultados no ajuste, aumentando o  $R^2$  em cerca de 10%. Isso é evidenciado pelo fato que nesse ano, para tal posto, a precipitação sazonal registrada é de apenas 495,10 mm, visto que, para o mesmo ano, nos postos vizinhos, os registros de precipitação sazonal variam na faixa de 1000 a 1400 mm. Essa precipitação registrada fica aquém dos padrões normais necessários para gerar uma vazão sazonal elevada, de 177,9 m<sup>3</sup>/s, como a que foi registrada no posto fluviométrico em questão. Porém, para a presente análise de validação cruzada, esse registro será mantido, por ter sido usado nos dados que ajustaram o modelo de regressão múltipla de Melo (2003). No entanto, nas demais análises de validações mista e clássica, foi retirado esse ano da série de dados deste posto.

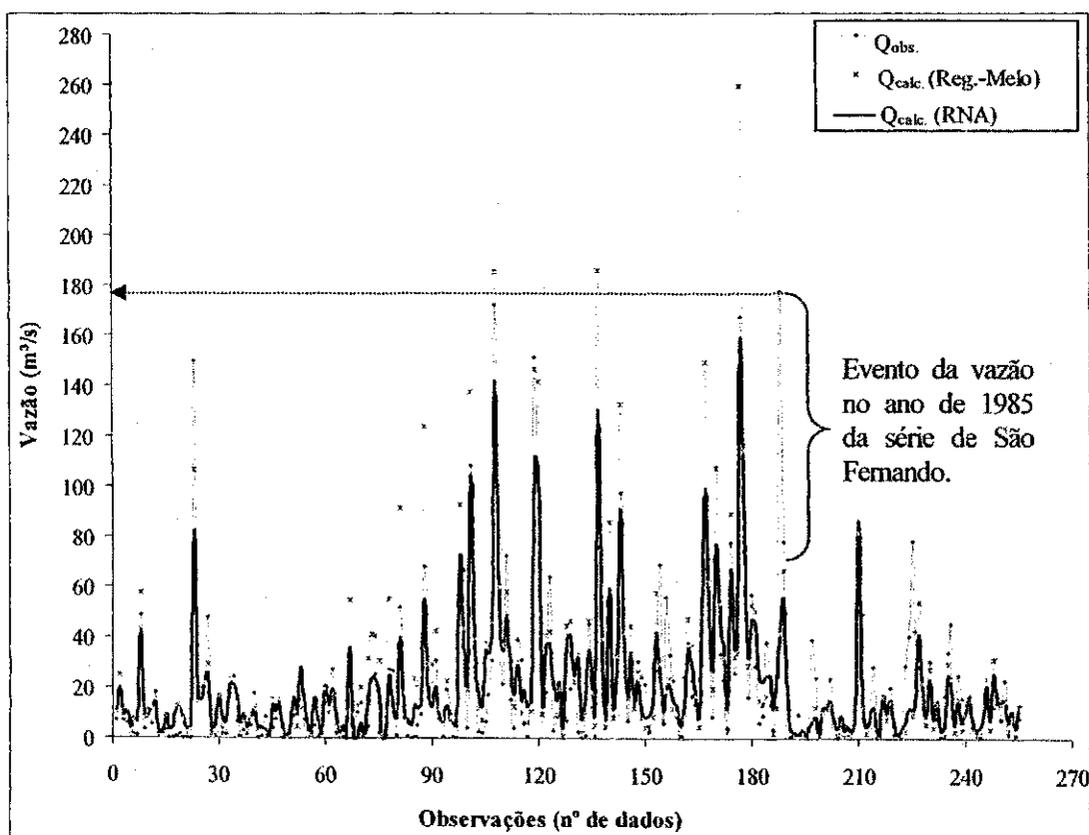


Figura 6.4 – Comportamento do ajuste obtido com os modelos de regressão múltipla de Melo (2003) e RNA para todos os dados de todas as sub-bacias juntas.

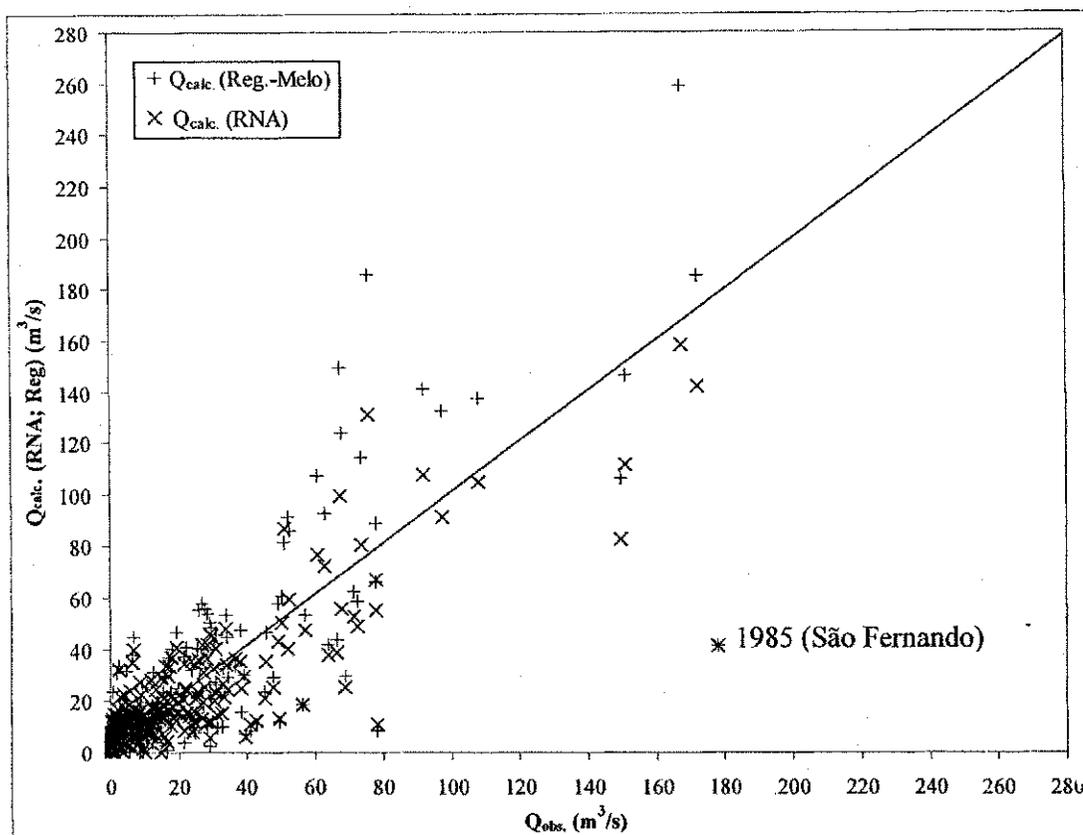


Figura 6.5 – Correlação entre as vazões observadas e as calculadas pelos modelos de regressão múltipla de Melo (2003) e RNA na simulação de todos os dados disponíveis.

### 6.2.1. ANÁLISE DOS RESULTADOS NA VALIDAÇÃO CRUZADA

Conforme a Tabela 5.1, para os diversos grupos formados para a calibração cruzada, tem-se na Tabela 6.4 a síntese de todos os resultados obtidos nessa etapa para a fase de calibração dos modelos de RNA e Regressão Múltipla de Melo (2003). Os indicadores de desempenho, postos de forma a facilitar a comparação entre ambos os resultados, indicam uma superioridade do modelo de redes neurais artificiais sobre o de regressão múltipla. Com todos os outros índices variando na mesma ordem, o coeficiente de determinação está variando entre 65 e 74% para RNA e entre 60 e 71% para a Regressão. Nos grupos 10 e 13 de calibração ocorreram os melhores ajustes para o modelo de RNA com  $R^2 = 74\%$ . O mesmo se observa para a Regressão Múltipla no grupo 10, onde o modelo obteve  $R^2 = 71\%$ . Isto pode ser explicado, uma vez que, para o caso do grupo 10 os dados da sub-bacia de São Fernando não constituem o conjunto de calibração, sendo reservado, neste caso, para a validação do modelo. Assim, como já explicado, o modelo não se submete a dados potencialmente anômalos, como os de chuva e vazão do ano de 1985 desta série. No caso do grupo

13, não foram usados no ajuste os dados de Serra Negra que apresentavam inconsistências (Melo, 2003).

Tabela 6.4 – Comparação entre os índices de desempenho dos modelos de RNA e Regressão Múltipla de Melo na fase de calibração

Sub-bacias da calibração	%R <sup>2</sup>		EPE		%ER	
	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)
Grupo 1	70,0	66,0	16,1	19,8	0,0	37,6
Grupo 2	70,0	66,0	15,5	21,8	0,0	-22,3
Grupo 3	68,0	65,0	16,4	31,8	-1,5	-56,1
Grupo 4	65,0	69,0	16,2	46,0	-1,5	-91,2
Grupo 5	71,0	67,0	15,7	24,6	0,0	-37,0
Grupo 6	72,0	69,0	15,4	20,0	-0,5	-13,4
Grupo 7	68,0	62,0	16,5	21,3	-1,7	-1,1
Grupo 8	65,0	60,0	15,1	17,9	-0,2	4,6
Grupo 9	70,0	68,0	16,1	17,5	-1,9	-0,1
Grupo 10	74,0	71,0	12,7	13,8	0,0	4,5
Grupo 11	69,0	66,0	16,1	21,4	-1,6	-14,1
Grupo 12	71,0	67,0	16,0	18,8	0,0	-10,4
Grupo 13	74,0	66,0	15,5	29,8	0,0	-45,0

O erro relativo (ER) cometido pelo modelo de RNA foi muito baixo, se encontrando em termos absolutos na faixa de 0,0 a 1,9%, já o modelo de Regressão apresentou ER em termos absolutos variando entre 0,1 a 91,2%.

Esta superioridade da técnica de RNA sobre a de Regressão no ajuste na fase de calibração deve ser analisada com cautela, pois, se por um lado este resultado evidencia a alta capacidade deste modelo em se ajustar a relações complexas e não lineares com grandes quantidades de dados, deve-se frisar que isso provavelmente acontece devido ao fato deste modelo possuir um elevado número de parâmetros, Apesar da rede trabalhada ter uma estrutura relativamente pequena (3-2-1), ou seja, tem apenas dois neurônios na camada escondida, mesmo assim ela possui onze parâmetros contra quatro existentes no modelo de Regressão de Melo (2003).

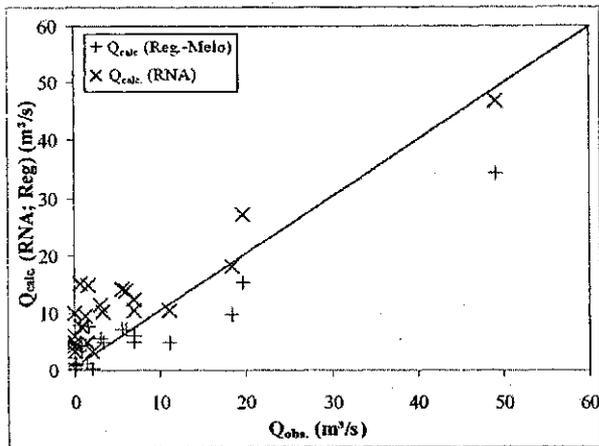
Na Tabela 6.5, tem-se o resumo dos resultados no ajuste dos modelos aqui tratados na fase de validação. Nota-se que nesta fase ocorre quase que um equilíbrio entre os dois modelos, com uma ligeira superioridade do método clássico de Regressão Múltipla. Os resultados aqui obtidos reforçam a análise anterior. Verifica-se que, diferentemente da calibração, os modelos de RNA e Regressão ajustados nos agrupamentos 10 e 13, quando submetidos à validação, para representarem a vazão nas sub-bacias de São Fernando e Serra Negra, respectivamente, apresentaram uma depreciação nos seus resultados, com RNA, obtendo no ajuste aos dados de São Fernando um  $R^2 = 50\%$  e para Serra Negra  $R^2 = 12\%$ , sendo estes os dois piores resultados dentre todos. O mesmo se

observa com relação ao modelo proposto por Melo (2003), onde no ajuste para os dados de São Fernando tem-se  $R^2 = 51\%$  e para Serra Negra  $R^2$  foi igual a  $13\%$ .

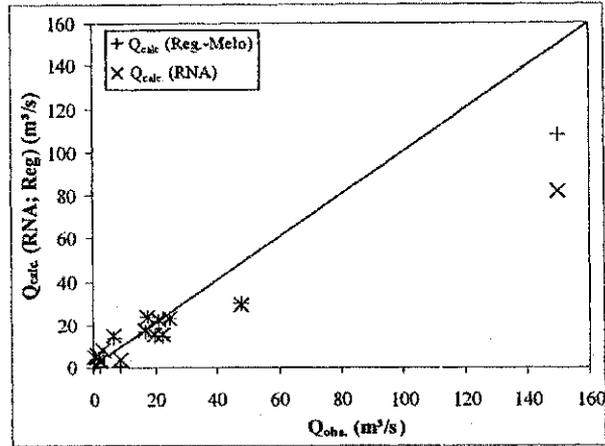
Tabela 6.5 – Comparação entre os índices de desempenho dos modelos de RNA e Regressão Múltipla de Melo na fase de validação

Sub-bacias da validação	%R <sup>2</sup>		EPE		%ER	
	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)
Antenor Navarro	86,0	89,0	7,1	4,9	-90,4	3,0
Aparecida	96,0	97,0	19,4	13,0	20,6	18,4
Augusto Severo	51,0	51,0	4,8	8,4	-47,3	-104,0
Emas	70,0	70,0	12,3	2,6	-160,6	-3,2
Fazenda Angicos	78,0	80,0	5,9	5,2	-40,1	-21,7
Mossoró	56,0	58,0	76,7	26,1	-650,9	-184,1
Pau dos Ferros	86,0	86,0	8,2	30,3	-3,2	-130,8
Pedra de Abelhas	85,0	85,0	20,4	17,4	3,7	-16,5
Piancó	61,0	62,0	16,7	24,2	-1,9	-4,2
São Fernando	50,0	51,0	33,2	38,1	16,4	43,3
Sítio Volta	64,0	66,0	13,4	13,6	73,2	77,8
Upanema	61,0	56,0	9,6	10,8	-4,9	23,2
Serra Negra	12,0	13,0	16,4	16,5	19,4	27,0

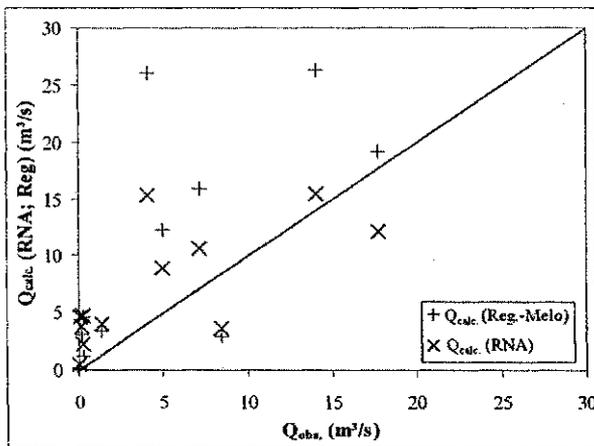
A Figura 6.6 apresenta graficamente o resultado para a validação entre os valores calculados pelo método de RNA e por Regressão Múltipla de Melo e o observado em relação à reta de igual valor. Pode-se, então, fazer um paralelo entre o comportamento gráfico visual encontrado nesta figura e o índice de desempenho Erro Relativo (ER) da Tabela 6.5. Este índice é o que mais reflete a variação dos resultados entre os dois modelos. Valores negativos denotam superestimação e positivos referem-se à subestimação dos resultados. Quanto maior este desvio maior será a distância dos pontos entre a vazão calculada e a observada em relação à reta de igual valor (reta 45°). Percebe-se uma variação deste com o modelo de RNA entre 1,9 a 650,9% e para o modelo de Melo está entre 3 a 184,1%. A ênfase destes valores extremos é para a sub-bacia de Mossoró (Figura 6.6 f), onde ambos os modelos superestimaram a vazão. Nesse caso, ambos os resultados são ruins, porém não anulam a importância dos métodos no contexto desse trabalho. A importância de se considerar vários índices de desempenho pode ser notada quando se observam casos como o resultado da validação para a sub-bacia de Emas (Tabela 6.5 e Figura 6.6 d). Neste, o modelo de RNA obteve um bom coeficiente de determinação de 70%, porém, o erro relativo foi bastante expressivo, de aproximadamente 160%. O mesmo pode ser notado com o modelo de Regressão Múltipla, onde para a sub-bacia de Pau dos Ferros (ver Tabela 6.5 e Figura 6.6 g) este obteve  $R^2 = 86\%$ , mas quanto ao erro relativo este foi de aproximadamente 130%.



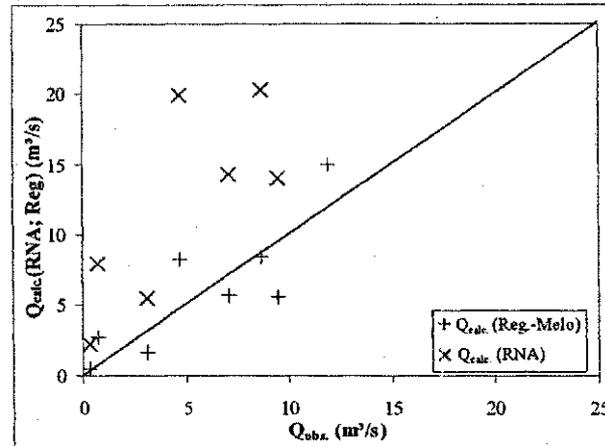
(a) Antenor Navarro



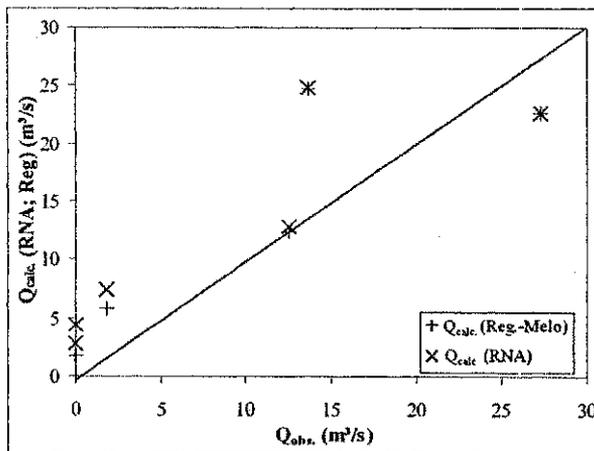
(b) Aparecida



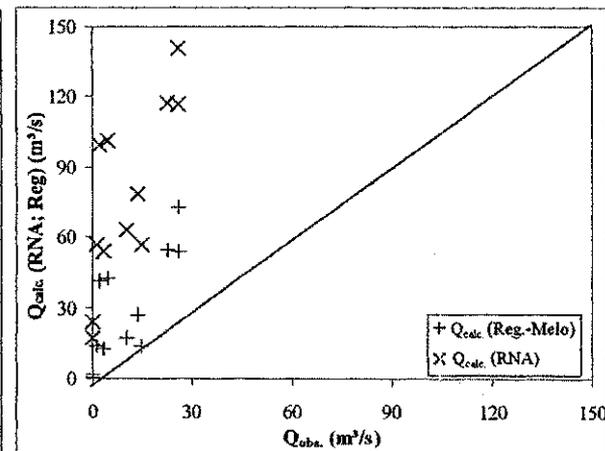
(c) Augusto Severo



(d) Emas

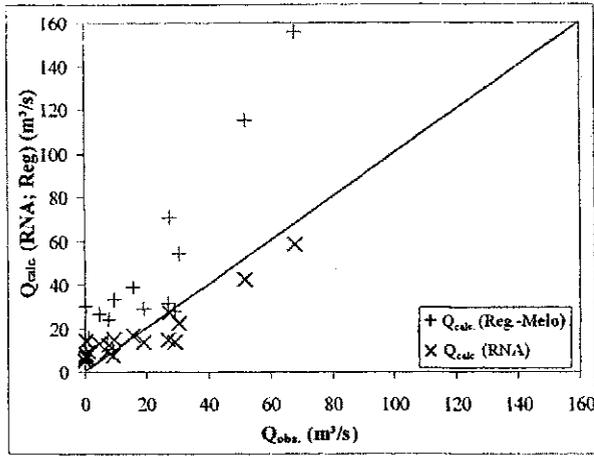


(e) Fazenda Angicos

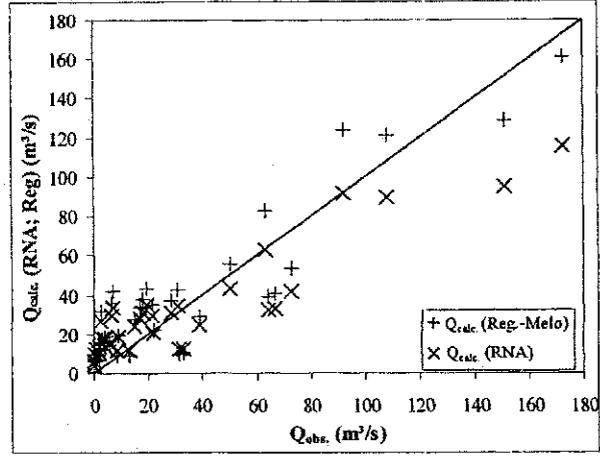


(f) Mossoró

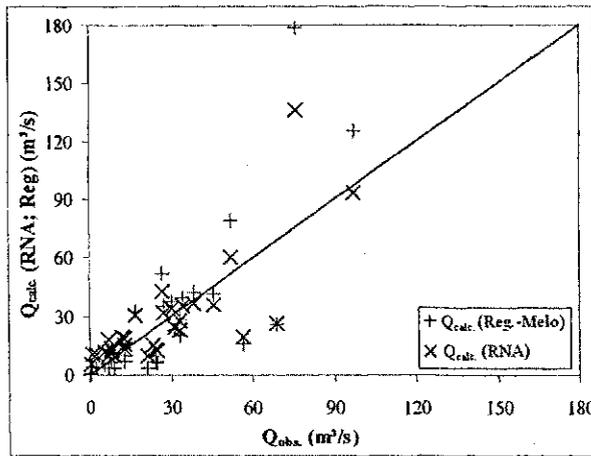
Figura 6.6 – Resultados da validação cruzada, aplicado aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro; (b) Aparecida; (c) Augusto Severo; (d) Emas; (e) Fazenda Angicos; (f) Mossoró; (g) Pau dos Ferros; (h) Pedra de Abelhas; (i) Piancó; (j) São Fernando; (k) Sítio Volta; (l) Upanema e (m) Serra Negra.



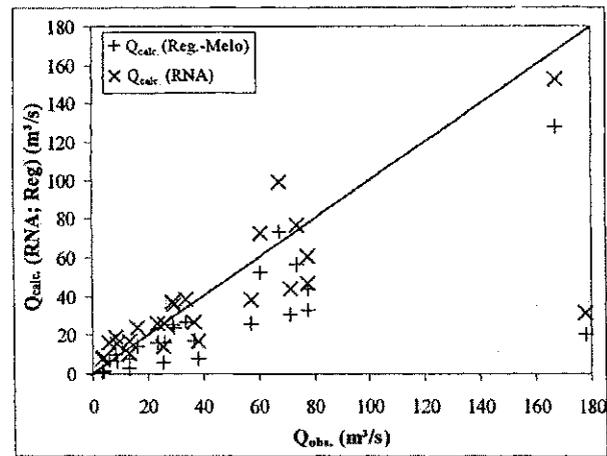
(g) Pau dos Ferros



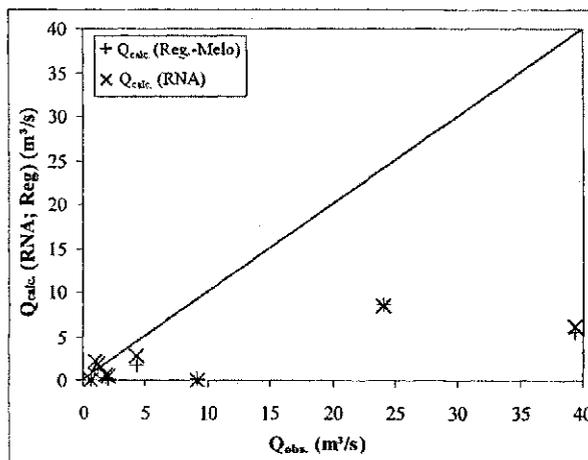
(h) Pedra de Abelhas



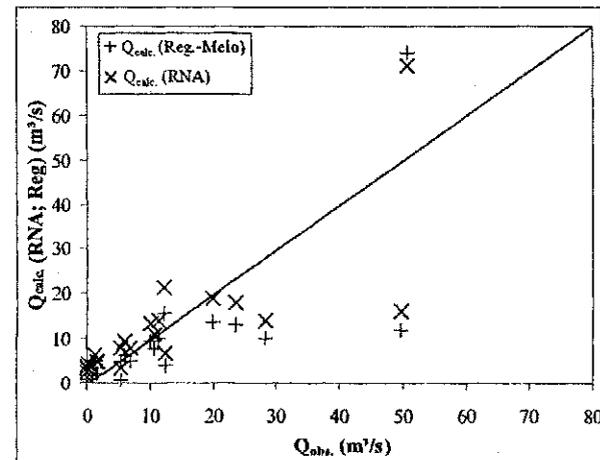
(i) Piancó



(j) São Fernando



(k) Sítio Volta



(l) Upanema

Figura 6.6 – Continuação: Resultados da validação cruzada, aplicado aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro; (b) Aparecida; (c) Augusto Severo; (d) Emas; (e) Fazenda Angicos; (f) Mossoró; (g) Pau dos Ferros; (h) Pedra de Abelhas; (i) Piancó; (j) São Fernando; (k) Sítio Volta; (l) Upanema e (m) Serra Negra.

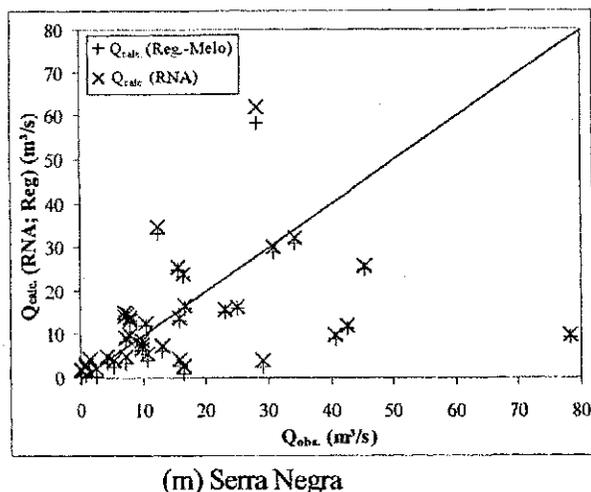
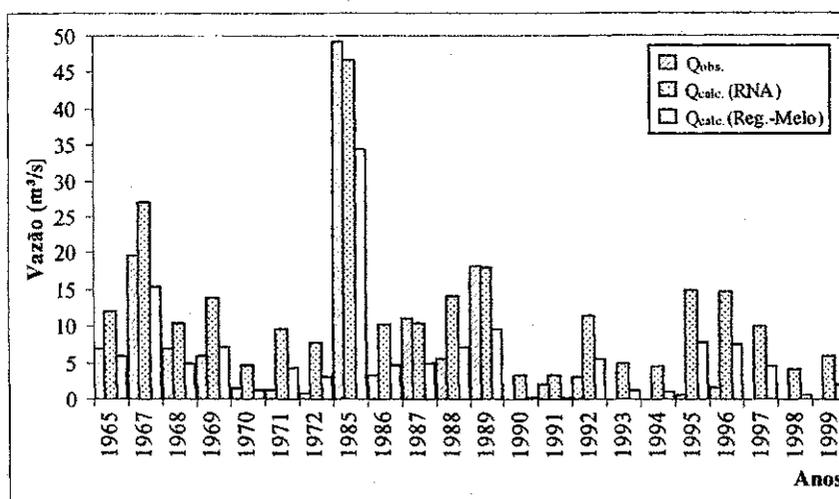


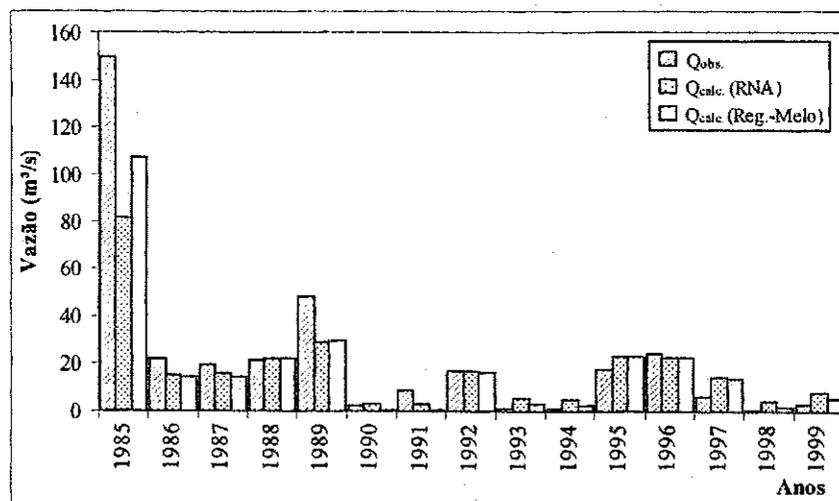
Figura 6.6 – Continuação: Resultados da validação cruzada, aplicado aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro; (b) Aparecida; (c) Augusto Severo; (d) Emas; (e) Fazenda Angicos; (f) Mossoró; (g) Pau dos Ferros; (h) Pedra de Abelhas; (i) Piancó; (j) São Fernando; (k) Sítio Volta; (l) Upanema e (m) Serra Negra.

Melo (2003) havia advertido sobre a não utilização da sub-bacia de Serra Negra devido ao baixo coeficiente de determinação obtido no ajuste dos dados da mesma na fase da validação. Isto ocorre, provavelmente, pela composição de dois fatores. Um primeiro diz respeito ao período de dados desta sub-bacia ser bastante distinto dos demais, uma vez que seus dados se encontram num período que vai da década de 20 à década de 60, não coincidindo temporalmente com nenhuma outra série de dados. Em segundo lugar, tal série antiga, devido à falta de equipamentos adequados e de pessoal qualificado, certamente traz consigo graves falhas, causadas por erros de anotações ou mesmo de interpretações. Assim, como se pode perceber, através do coeficiente de determinação baixo, o modelo de redes neurais também não conseguiu ajustar-se adequadamente aos dados desta sub-bacia. No entanto, observa-se que, para o modelo de Regressão Múltipla de Melo (2003), apesar do ajuste para o grupo 13 da Tabela 6.4 não contar com a referida sub-bacia de Serra Negra, ao contrário do que se esperava, o resultado teve uma pequena depreciação quando comparado com o do ajuste para todas as sub-bacias. Um coeficiente de determinação de 67% foi obtido no ajuste com todas as sub-bacias e de 66% no caso do grupo 13. Isto não se repetiu para RNA, havendo uma melhoria nos resultados. Nesse caso, o modelo obteve coeficiente de determinação de 69% no ajuste com todas as sub-bacias e de 74% no grupo 13. Isto significa que, os possíveis ruídos, existentes nos dados da sub-bacia de Serra Negra, são atenuados no processo e que a técnica de RNA possui uma maior sensibilidade a esses possíveis erros contidos nos dados.

Para uma melhor visualização do comportamento temporal dos modelos no ajuste da vazão durante a validação, a Figura 6.7 apresenta o desempenho das saídas dos modelos de RNA e Regressão de Melo (2003) na representação da vazão média diária sazonal, bem como a comparação com esta variável observada ao longo do tempo. De maneira geral, nota-se um bom desempenho dos modelos, havendo, portanto, uma tendência na representação dos eventos extremos, ou seja, ambos os modelos tendem a acompanhar os picos dos eventos de vazão, salvo casos como o de Mossoró (ver Figura 6.7f), onde se constata uma superestimação, como já foi mencionado. Porém, como será visto na validação mista e clássica, esta sub-bacia é de fundamental importância para a calibração dos modelos.

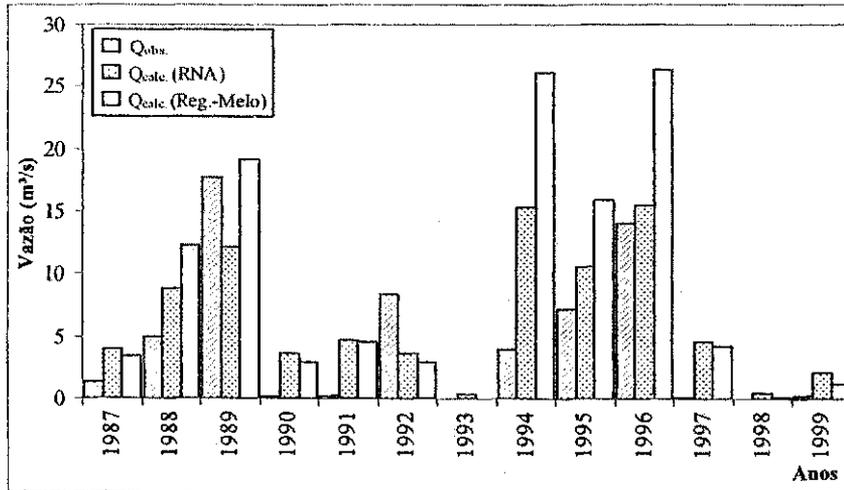


(a) Antenor Navarro

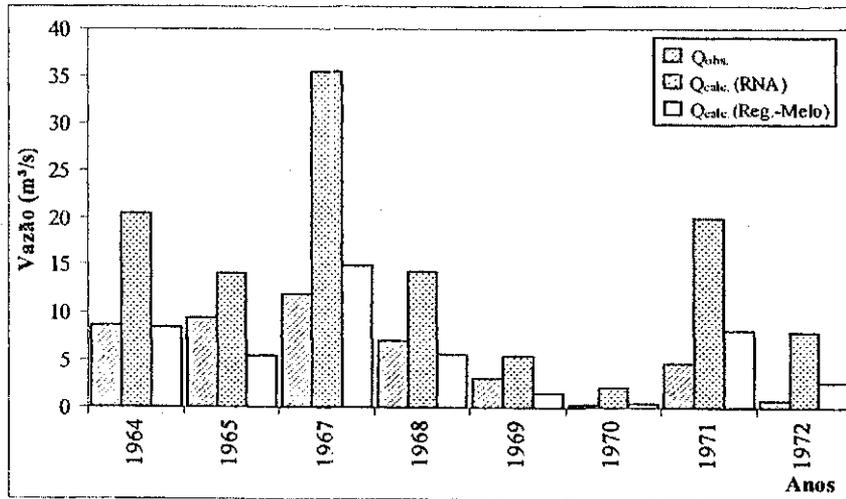


(b) Aparecida

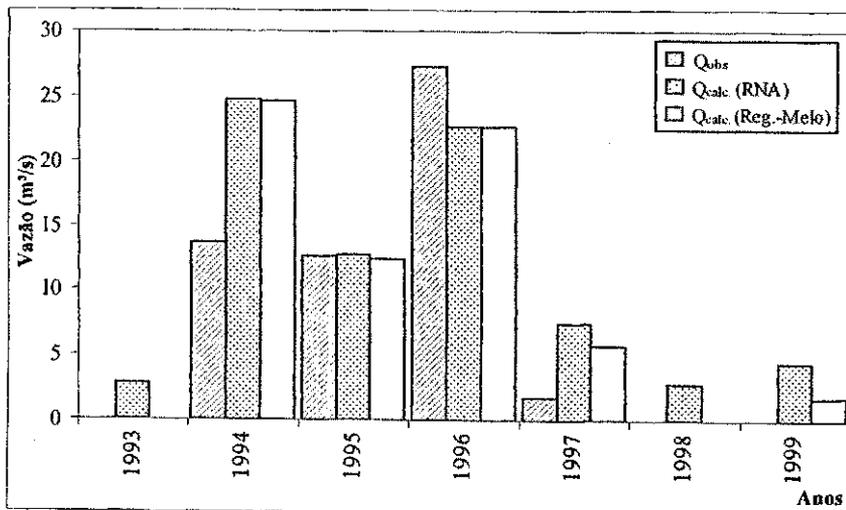
Figura 6.7 – Resultado da validação cruzada no ajuste com RNA e Regressão de Melo (2003) aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro, (b) Aparecida, (c) Augusto Severo, (d) Emas, (e) Fazenda Angicos, (f) Mossoró, (g) Pau dos Ferros, (h) Pedra de Abelhas, (i) Piancó, (j) São Fernando, (k) Sítio Volta, (l) Upanema e (m) Serra Negra.



(c) Augusto Severo

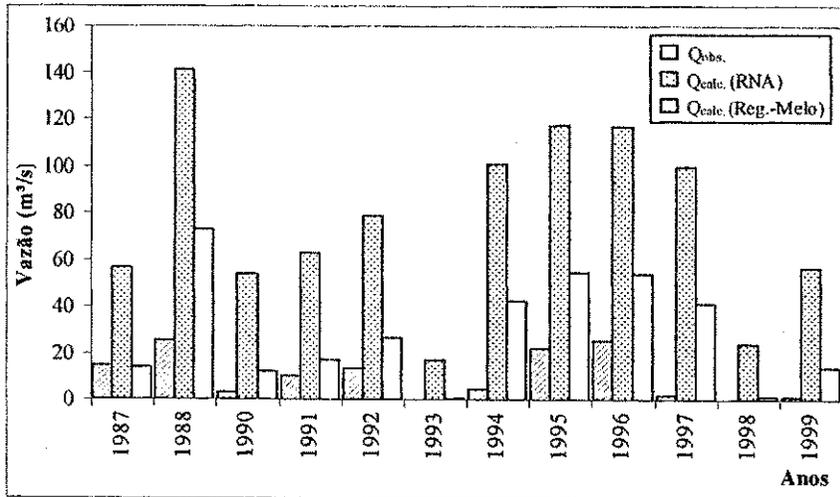


(d) Emas

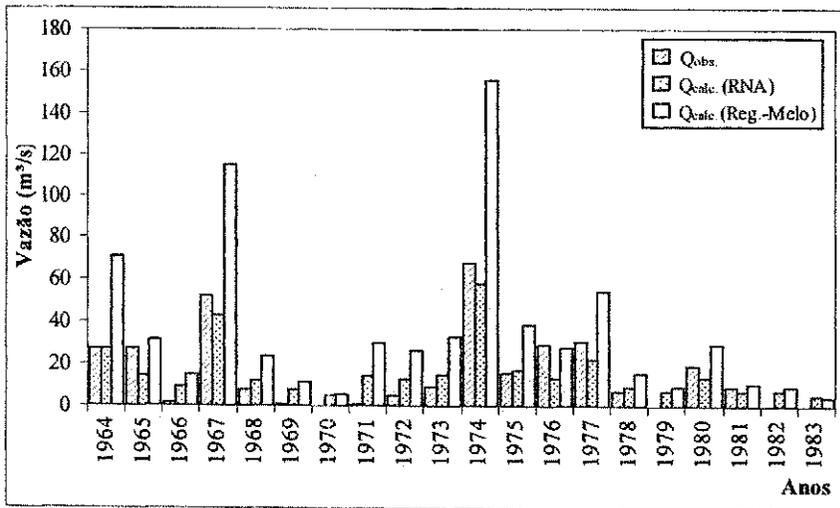


(e) Fazenda Angicos

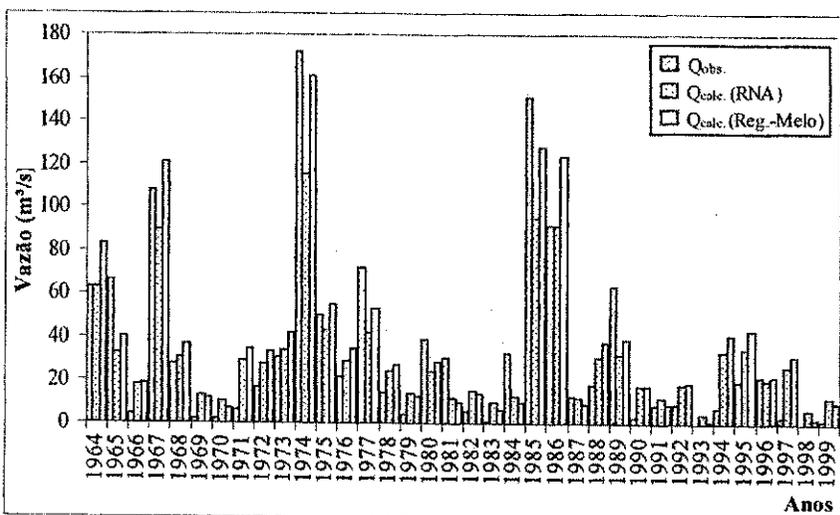
Figura 6.7 – Continuação: Resultado da validação cruzada no ajuste com RNA e Regressão de Melo (2003) aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro, (b) Aparecida, (c) Augusto Severo, (d) Emas, (e) Fazenda Angicos, (f) Mossoró, (g) Pau dos Ferros, (h) Pedra de Abelhas, (i) Piancó, (j) São Fernando, (k) Sítio Volta, (l) Upanema e (m) Serra Negra.



(f) Mossoró

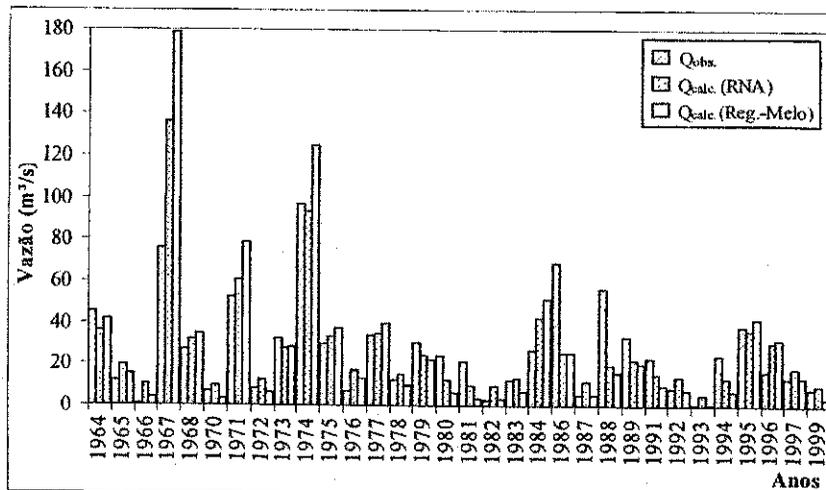


(g) Pau dos Ferros

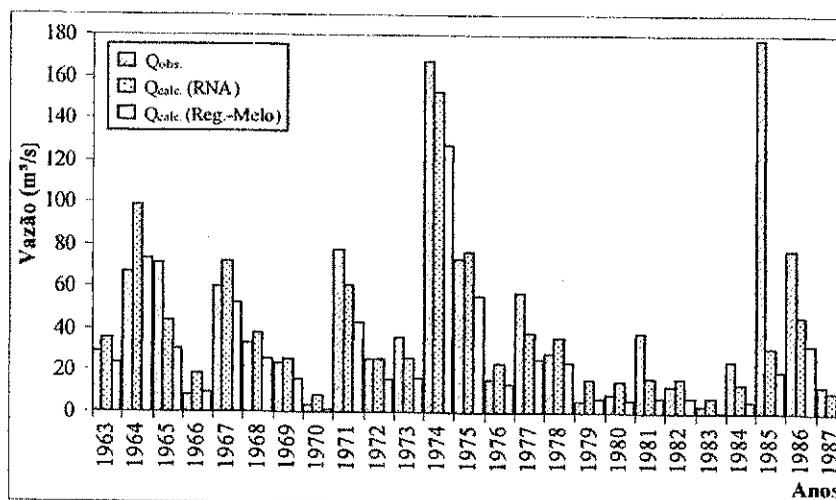


(h) Pedra de Abelhas

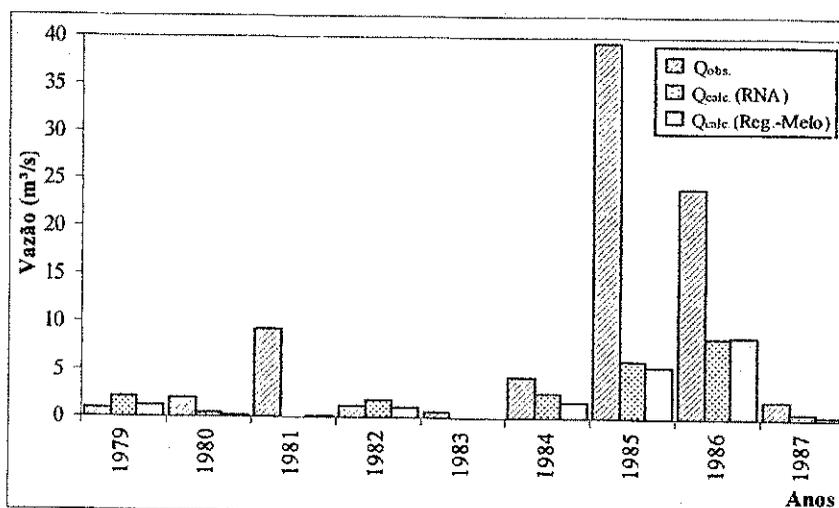
Figura 6.7 – Continuação: Resultado da validação cruzada no ajuste com RNA e Regressão de Melo (2003) aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro, (b) Aparecida, (c) Augusto Severo, (d) Emas, (e) Fazenda Angicos, (f) Mossoró, (g) Pau dos Ferros, (h) Pedra de Abelhas, (i) Piancó, (j) São Fernando, (k) Sítio Volta, (l) Upanema e (m) Serra Negra.



(i) Piancó

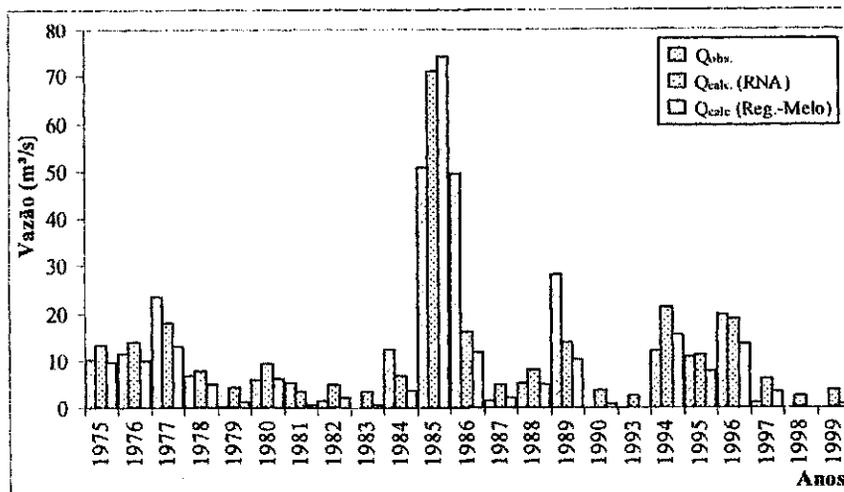


(j) São Fernando

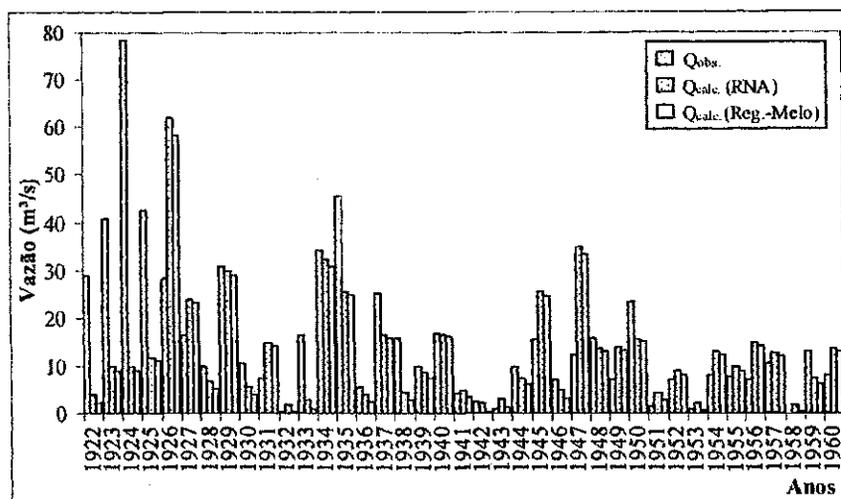


(k) Sítio Volta

Figura 6.7 – Continuação: Resultado da validação cruzada no ajuste com RNA e Regressão de Melo (2003) aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro, (b) Aparecida, (c) Augusto Severo, (d) Emas, (e) Fazenda Angicos, (f) Mossoró, (g) Pau dos Ferros, (h) Pedra de Abelhas, (i) Piancó, (j) São Fernando, (k) Sítio Volta, (l) Upanema e (m) Serra Negra.



(l) Upanema



(m) Serra Negra

Figura 6.7 – Continuação: Resultado da validação cruzada no ajuste com RNA e Regressão de Melo (2003) aos dados das sub-bacias hidrográficas dos postos fluviométricos de: (a) Antenor Navarro, (b) Aparecida, (c) Augusto Severo, (d) Emas, (e) Fazenda Angicos, (f) Mossoró, (g) Pau dos Ferros, (h) Pedra de Abelhas, (i) Piancó, (j) São Fernando, (k) Sítio Volta, (l) Upanema e (m) Serra Negra.

No caso de Serra Negra (Figura 6.7 m) é notória uma subestimação nos resultados dos modelos para os quatro primeiros anos (1922-1925), enquanto que, visualmente, para os demais anos desta série, os modelos caracterizam bem a variável vazão a ser determinada. Diante dessa observação, com o intuito de se verificar os dados dessa sub-bacia, tentou-se realizar uma eliminação parcial nos seus dados. Foram retirados conjuntos de dados de cinco em cinco anos, desde o início desta série, para se avaliar uma possível melhora nos resultados da validação para a mesma. Estes estão dispostos na Tabela 6.6, onde, percebe-se uma sensível melhora nos resultados com a eliminação dos cinco primeiros anos, de 1922 a 1926. Como se pode ver, o coeficiente de

determinação que antes não passava de 13% agora atingiu 50% no ajuste da validação para ambos os modelos. A Figura 6.8 mostra esse caso, onde se vê uma boa aproximação dos pontos à reta de igual valor, refletindo o baixo erro relativo cometido pelos modelos, de 0,06% para RNA e de 9,3% para o modelo de Regressão Múltipla proposto por Melo (2003).

Tabela 6.6 – Resultados da validação para o posto de Serra Negra com tratamento dos dados

Anos	$R^2$ (%)		EPE		ER (%)	
	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)
1922 - 1960	12,00	13,00	16,40	16,50	19,40	27,00
1927 - 1960	50,00	50,00	7,50	7,60	0,06	9,30
1932 - 1960	47,00	47,00	7,80	7,90	1,70	11,60
1937 - 1960	32,00	34,00	6,90	6,80	-12,90	-1,80

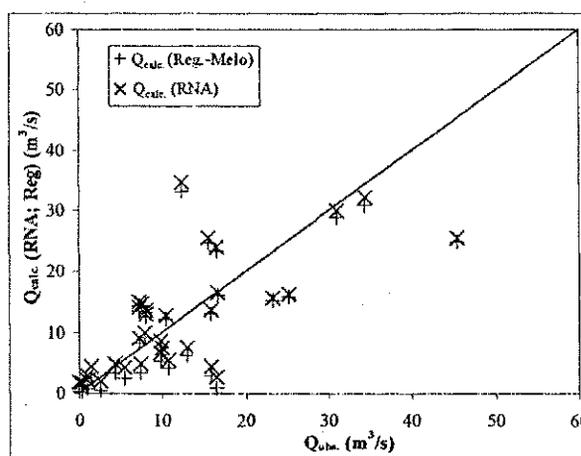


Figura 6.8 – Correlação da validação para Serra Negra entre os resultados obtidos com o modelo de RNA e o de Melo extraídos os cinco primeiros anos de sua série de dados.

Esse novo resultado, onde se observa uma melhoria no ajuste da resposta do modelo de RNA aos dados tratados da série de Serra Negra, levou a um questionamento: seria prudente continuar com tais dados no desenvolvimento das próximas etapas da pesquisa? Pois antes, como se pode ver na Tabela 6.5, o coeficiente de determinação na validação para Augusto Severo e São Fernando também foi de aproximadamente 50%. Para que não restassem dúvidas e para que não fosse omitida tal descoberta, preferiu-se realizar as próximas etapas de validação com e sem a nova série de dados da sub-bacia de Serra Negra. Com isso, pode-se avaliar com maior clareza o comportamento e a sensibilidade do modelo de RNA à inclusão de tais dados.

## 6.2.2. ANÁLISE DOS RESULTADOS NA VALIDAÇÃO MISTA

### 6.2.2.1. VALIDAÇÃO MISTA COM OS DADOS TRATADOS DE SERRA NEGRA

Este método de avaliação da técnica de RNA foi proposta na intenção de se aprofundar o entendimento das relações existentes entre as variáveis físicas e hidrológicas. Constatou-se relações importantes entre a qualidade do ajuste do modelo e as características físicas das sub-bacias, que puderam ser comprovadas na validação clássica. Todos os dados foram utilizados nesta fase, menos os considerados anômalos do ano de 1985 da série de Piancó e de São Fernando, além dos retirados da série de Serra Negra (1922-1926).

A Tabela 6.7 apresenta os resultados obtidos para os casos descritos na Figura 5.3. Como se pode ver, o modelo de RNA, para todos os casos, consegue um ótimo desempenho ao se ajustar aos dados da fase de calibração, com  $R^2$  igual ou superior a 80%. No ajuste aos dados do conjunto de teste de parada, obteve coeficiente de determinação inferior a 50% para quatro casos (casos: 5, 11, 12, 13) e na fase de validação para cinco casos (casos: 2, 7, 8, 11, 12).

Tabela 6.7 – Resultados do modelo de RNA para a validação mista com os dados tratados de Serra Negra

Casos	Calibração			Teste de parada			Validação		
	$R^2$ (%)	EPE	ER (%)	$R^2$ (%)	EPE	ER (%)	$R^2$ (%)	EPE	ER (%)
1	93,00	4,93	1,02	71,00	86,45	-175,60	71,26	256,82	-574,30
2	92,00	5,70	-0,61	67,00	21,76	-9,51	44,00	15,10	-23,80
3	87,00	10,60	-0,37	70,00	25,75	-17,30	55,00	17,70	-15,10
4	78,00	13,80	-1,80	78,00	295,90	-642,30	77,00	14,70	-8,30
5	80,00	14,40	-1,40	39,00	11,20	-3,65	80,00	11,90	-32,20
6	80,00	14,30	-0,16	50,00	8,50	0,83	85,00	14,90	6,14
7	81,00	13,40	-0,58	86,00	11,90	-16,60	33,00	34,20	-278,20
8	82,00	12,50	-0,13	85,00	13,80	-10,20	3,00	196,20	-683,80
9	82,00	10,20	-0,29	71,00	17,25	-0,81	61,40	21,23	-28,54
10	87,00	9,11	0,00	60,00	6,13	-62,50	63,00	35,13	-57,61
11	82,00	7,36	-0,04	27,00	126,50	-852,10	26,00	765,50	-1177,00
12	87,00	6,26	-0,03	14,00	16,90	39,22	18,00	40,40	83,00
13	90,00	5,52	0,00	32,00	102,00	-288,80	53,20	97,80	-212,20

O importante que se pode observar é que ocorre uma depreciação do resultado a partir do caso 7, principalmente na fase de validação. Isto acontece exatamente quando a sub-bacia de Mossoró saiu do conjunto de calibração e passou a integrar outros. Esta sub-bacia é relevante dentro do conjunto de calibração da rede neural, porque apresenta o maior valor da variável comprimento do rio ( $L$ ) e também a segunda maior área de drenagem ( $A$ ). Este é o motivo pelo qual os modelos aqui tratados também não se ajustaram a esta com exatidão na validação cruzada. Outra sub-bacia de extrema importância é a de São Fernando, por ocupar a maior área em relação às demais sub-bacias estudadas na região.

A Figura 6.9 apresenta, em termos percentuais, a magnitude relativa da área de drenagem e do comprimento do rio principal referente a cada sub-bacia, tendo, por exemplo, a sub-bacia de São Fernando (SF) ocupando uma área de 22% de toda a região estudada; porém, seu rio principal, em relação aos das demais sub-bacias, possui uma magnitude de 8%.

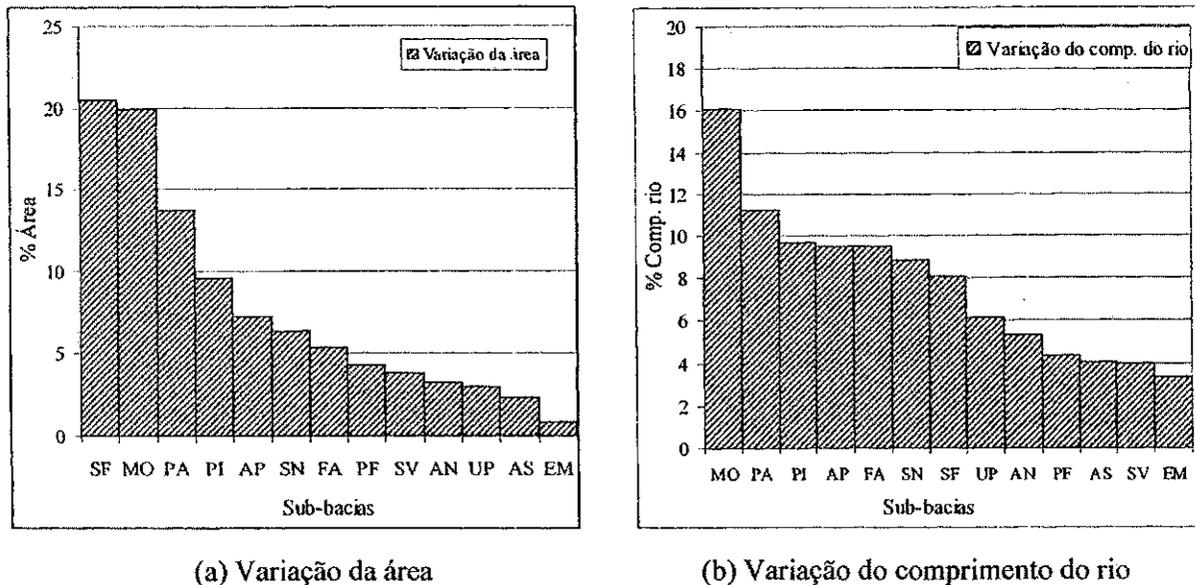


Figura 6.9 – Variação espacial das variáveis: (a) área de drenagem e (b) comprimento do rio principal.

É importante frisar que, independente da inclusão dos dados tratados de Serra Negra, o que existe é uma estreita relação entre estas características físicas das sub-bacias e a qualidade do ajustamento do modelo nas três fases. Na verdade ocorre uma tendência de melhoramento nos resultados quando se tem conjuntos de amostras representativas do universo de dados, com especial atenção para o conjunto de calibração da RNA. Assim, pode-se citar como exemplos os casos 1 e 4, expostos na Tabela 6.7. Esses oferecem um dos melhores resultados da RNA no ajustamento em termos do coeficiente de determinação para as três fases, obtendo para o caso um  $R^2$  de 93% na calibração, 71% no teste de parada e 71% na validação. No entanto, na fase de validação o índice *EPE* foi de 257 e o *ER* de -574%. Conforme visto na Figura 6.10, enquanto a vazão observada não ultrapassa 200 m<sup>3</sup>/s, o modelo responde com uma vazão próxima a 1500 m<sup>3</sup>/s. O mesmo acontece no caso 4 quanto à fase de teste de parada. Pela mesma figura, nota-se que, para ambos os casos o modelo não conseguiu capturar, no treinamento, relações necessárias para poder generalizá-las nas demais situações. O que se percebe (Figura 6.10a e 6.10c) é que o modelo não se ajustou adequadamente aos dados da sub-bacia de São Fernando para estes casos, por ser a sub-bacia de maior porte e ter ficado fora do conjunto de calibração da RNA.

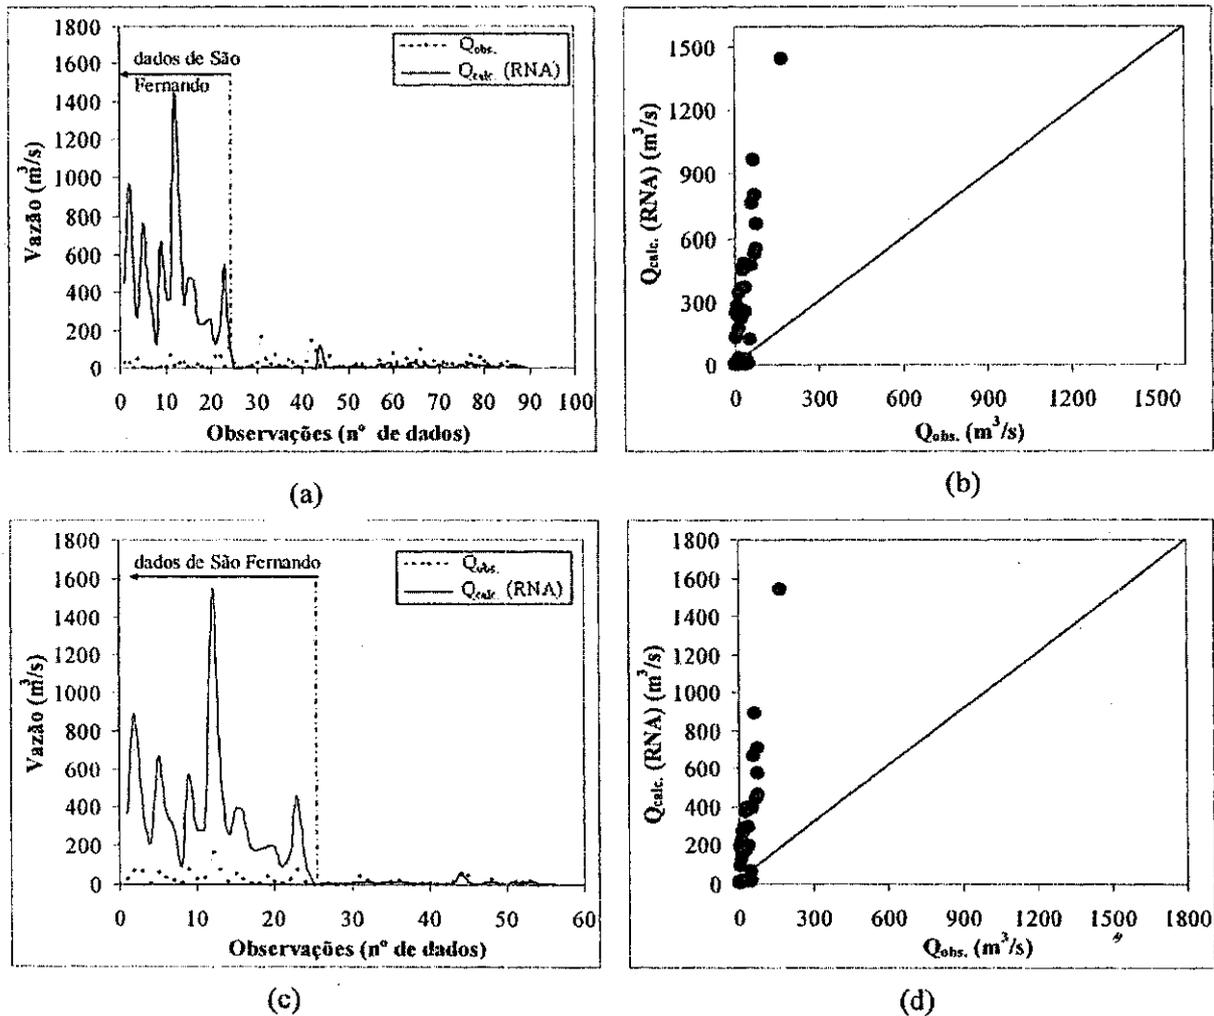


Figura 6.10 - (a) Caso 1 – Ajuste na fase de validação, (b) Caso 1 - Correlação na fase de validação, (c) Caso 4 – ajuste na fase teste de parada e (d) Caso 4 - Correlação na fase teste de parada.

O caso 11 foi o de pior desempenho da rede neural, neste o *ER* chega a -852,1% no ajuste do conjunto teste de parada e -1177% na validação. Então, apesar do modelo se ajustar bem aos dados da calibração com  $R^2 = 82\%$ , não conseguiu ajustar-se nas demais fases de testes. Isto acontece justamente no momento em que o conjunto de calibração da RNA fica sem nenhuma representatividade de bacias de grande porte, como a de Mossoró e São Fernando, que nesse caso estavam integrando o conjunto de teste de parada e de validação respectivamente. Como pode ser visto nas Figuras 6.11a e 6.11c, o modelo se ajusta bem aos dados das demais sub-bacias, porém, não para os dados de Mossoró e São Fernando. Esta mesma situação se repete para os casos 12 e 13.

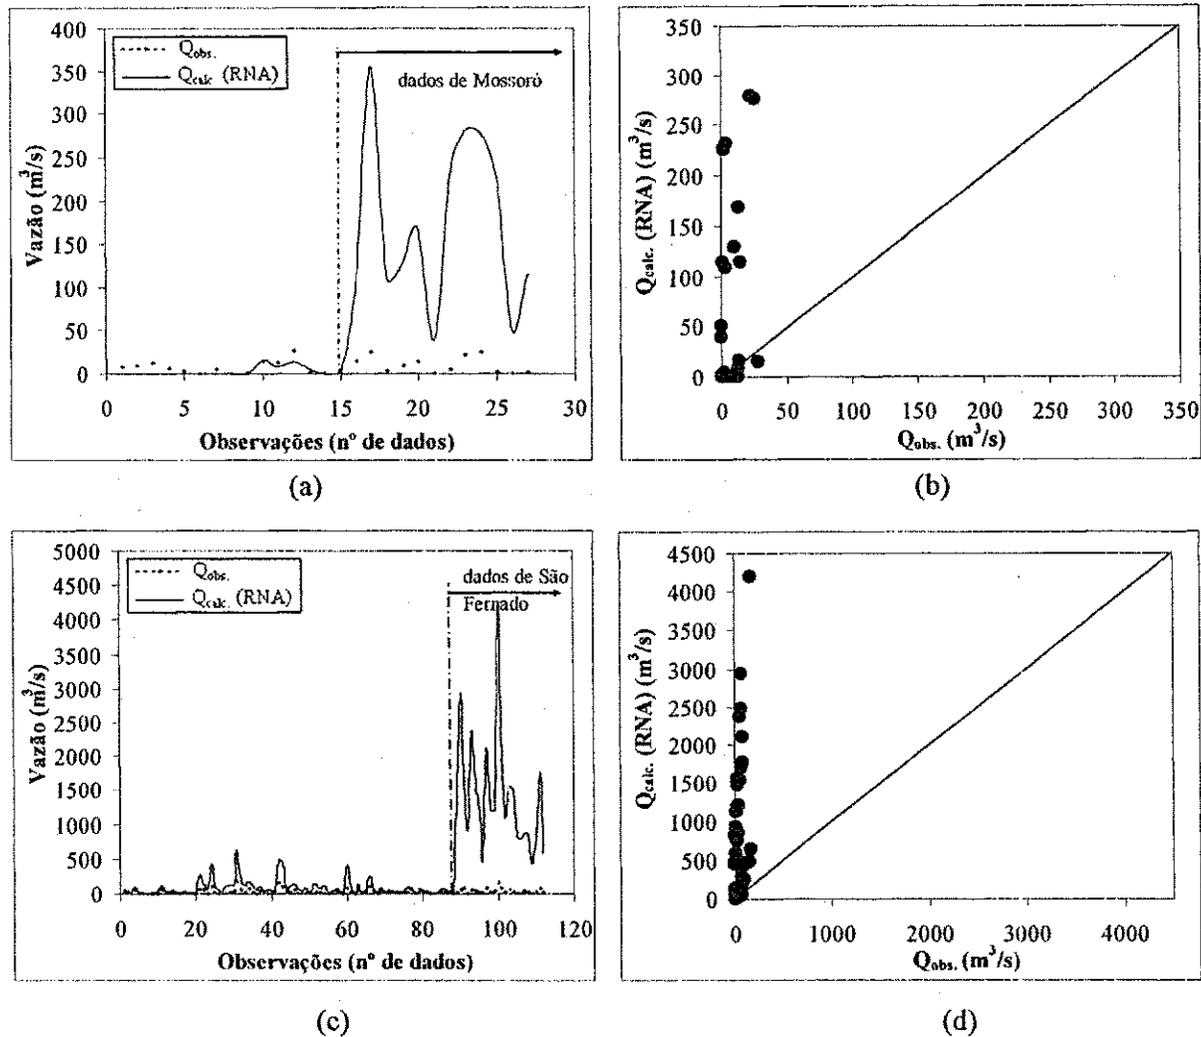


Figura 6.11 - (a) Caso 11 – Ajuste na fase teste de parada, (b) Caso 11 - Correlação na fase teste de parada, (c) Caso 11 – Ajuste na fase de validação e (d) Caso 11 - Correlação na fase de validação.

As Figuras 6.12a e 6.12b apresentam, para o caso 11 e para cada conjunto trabalhado, a variação da magnitude, em termos percentuais, da área e do comprimento do rio principal, respectivamente. Analisando-as, nota-se, em particular, que o conjunto de calibração da rede foi composto apenas por sub-bacias de pequeno porte, abaixo de 7% de magnitude em relação às demais, enquanto que as sub-bacias que compõem os conjuntos de teste de parada e de validação, as quais deverão ser representadas pelo modelo, chegam a apresentar tamanhos correspondentes a até 20% de toda a área estudada. A variável comprimento do rio também pouco variou, ficando, para o conjunto da calibração, sempre abaixo daqueles as quais o modelo seria testado. Isto reforça a hipótese até aqui levantada, ou seja, para que se possa esperar respostas adequadas de um modelo como o de RNA, faz-se necessário conjuntos amostrais que representem bem o universo de dados, principalmente o de treinamento da rede, e isso está de acordo com a filosofia empregada aos

modelos conexionistas, ou seja, como estes foram inspirados no cérebro humano quanto ao funcionamento e na forma de responder a novos estímulos com base em exemplos anteriormente vistos, o mesmo pode ser observado para esta técnica, RNA poderá responder adequadamente a dados inéditos desde que estes estejam contidos numa faixa de valores ou conhecimentos já adquiridas pelo modelo em situações passadas, ou seja, no treinamento.

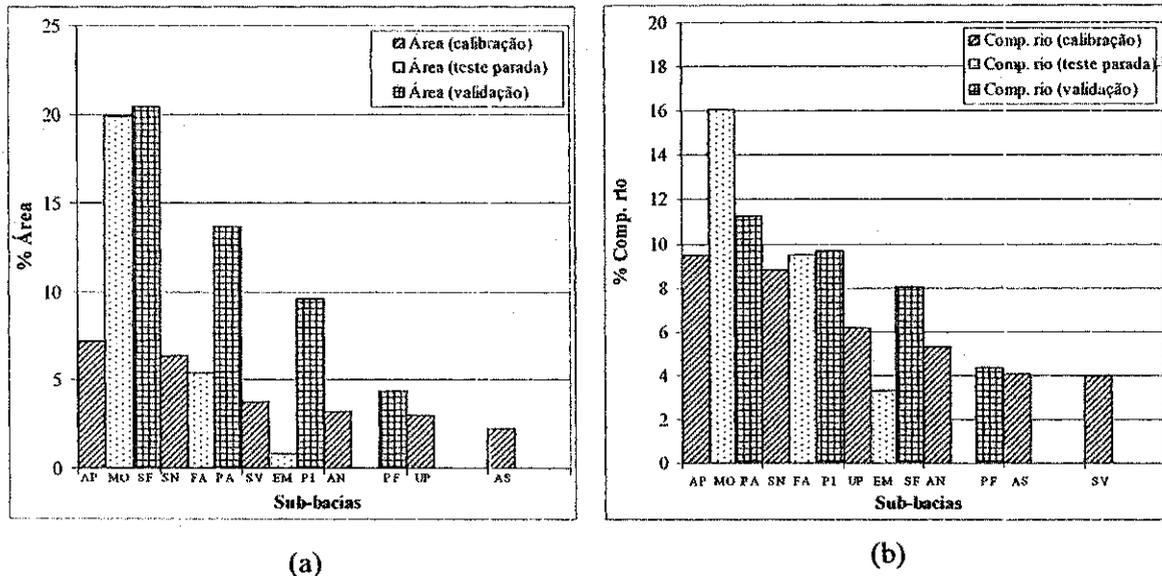


Figura 6.12 - (a) Variação da magnitude das áreas no caso 11 e (b) Variação da magnitude do comprimento dos rios no caso 11.

Assim, a alocação dos dados para formação dos conjuntos a serem trabalhados é uma das mais importantes fases a serem realizadas e pensadas para a obtenção de um bom êxito no trabalho com RNA. Os resultados dessa etapa de trabalho demonstram que não é recomendável se dividir a amostra de dados de forma aleatória, mas sim que seja antes realizado um pré-processamento dos dados que possa ajudar na melhor escolha, visando sempre amostras que representem todo o conjunto de dados a ser trabalhado. Isto será posto em prática na validação clássica, onde a amostra de dados será dividida em duas partes fixas mediante observância destas questões aqui levantadas.

O caso 6 foi um dos melhores no ajuste para as três fases segundo todos os indicadores de desempenho (Figura 6.13). Nessa combinação as sub-bacias de Mossoró e São Fernando estão contidas no conjunto de treinamento da RNA. Com isso, a rede neural foi informada da existência de padrões de dados extremos. No entanto, essa combinação ainda não é a considerada ideal, pois ainda existem carências de informações sobre as características de sub-bacias de pequeno porte, como a de Emas. Porém, há uma nítida tendência de melhoramento dos resultados quando a amostra de dados é representativa, variando entre valores baixos, médios e altos.

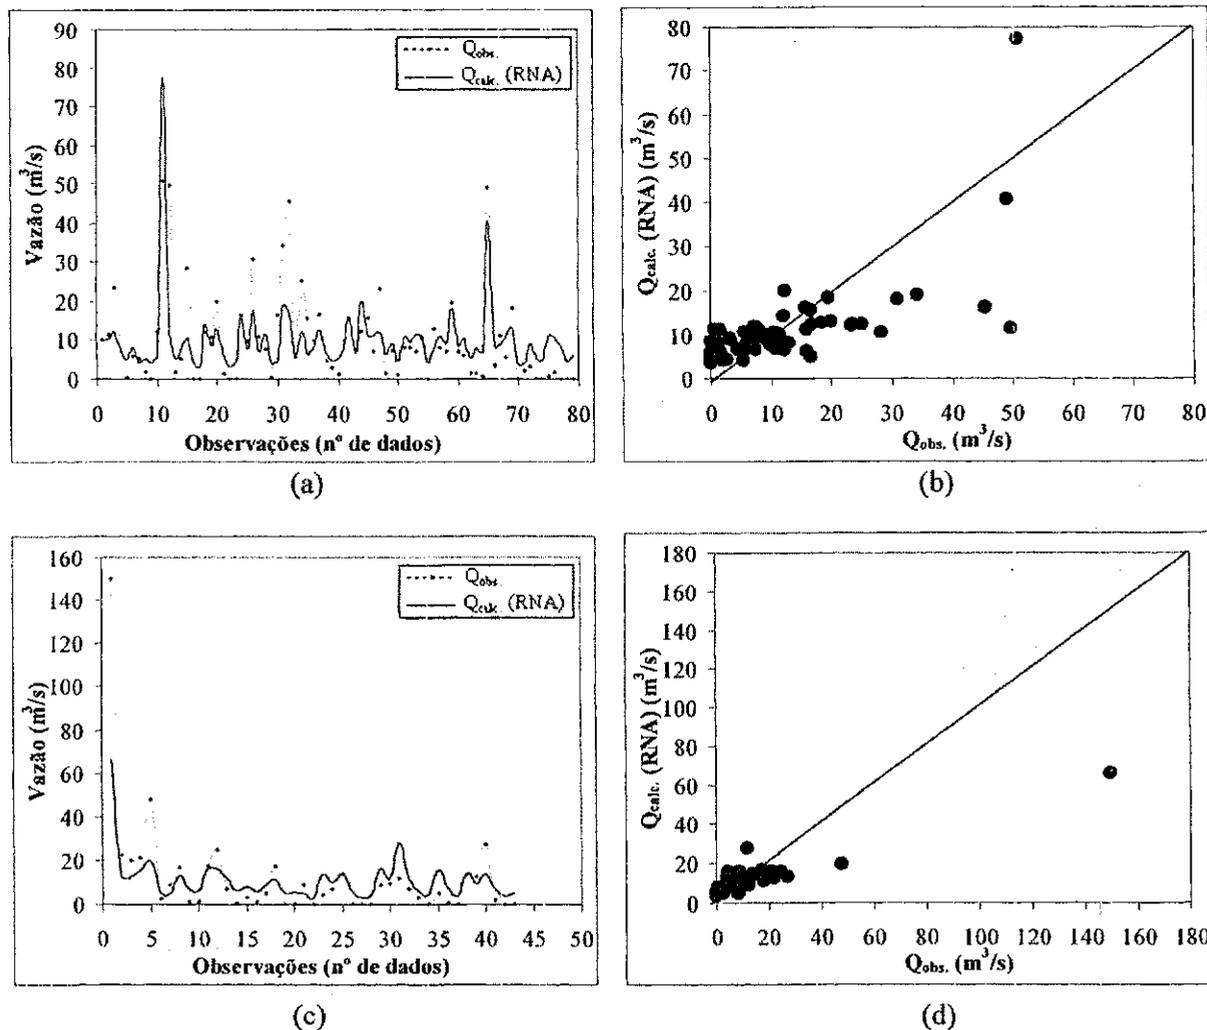


Figura 6.13 - (a) Caso 6 – Ajuste na fase teste de parada, (b) Caso 6 - Correlação na fase teste de parada, (c) Caso 6 – Ajuste na fase de validação e (d) Caso 6 - Correlação na fase de validação.

A Figura 6.14 mostra as variações, em termos percentuais, das variáveis físicas, como a área de drenagem e o comprimento do rio principal para os três conjuntos de sub-bacias trabalhados para o caso 6. Nesta, percebe-se uma boa distribuição de ambas as variáveis. Mas, é notória a carência de sub-bacias de menor porte dentre as que compõem o conjunto de calibração da rede, bem como de maiores dentre as que compõem os conjuntos de teste e validação da rede. Certamente, uma permuta entre estas unidades de sub-bacias, dentre os conjuntos, possa oferecer um ponto ótimo de equilíbrio, e isso será avaliado mais adiante.

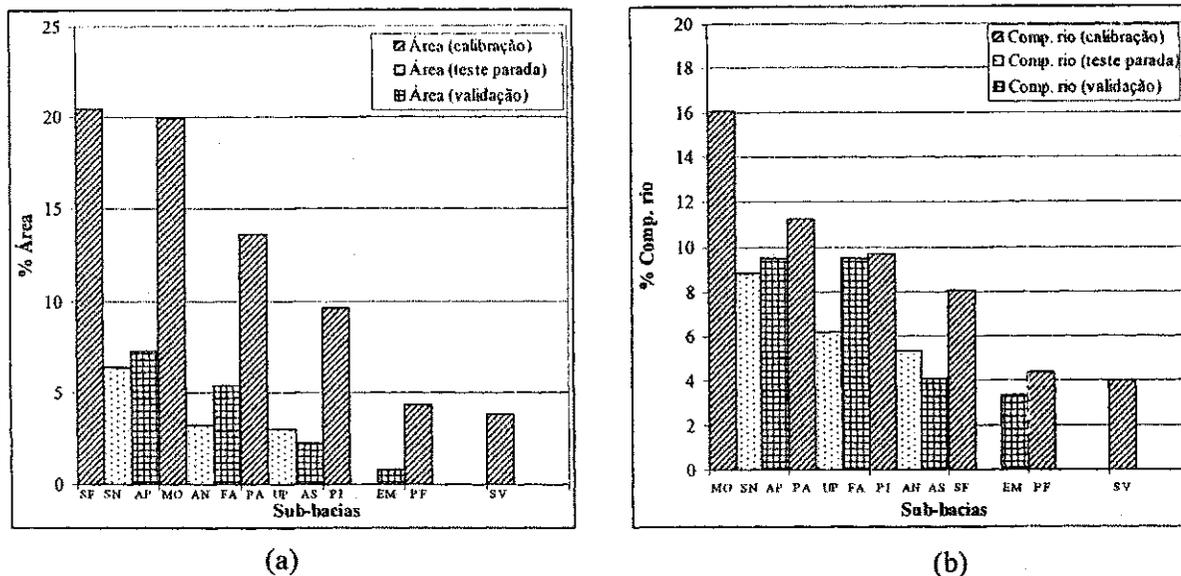


Figura 6.14 - (a) Variação da magnitude das áreas no caso 6 e (b) Variação da magnitude do comprimento dos rios no caso 6.

### 6.2.2.2. VALIDAÇÃO MISTA SEM OS DADOS DE SERRA NEGRA

Essa etapa é análoga a anterior, com o diferencial de não se considerar os dados da sub-bacia de Serra Negra. Assim, tem-se a amostra de dados dividida em três partes distintas para comporem os conjuntos de calibração, teste de parada e validação, contando, nesse caso, com um total de 221 pares de dados registrados de chuva-vazão.

A Tabela 6.8 apresenta os índices de desempenho alcançados pelo modelo de RNA para cada caso da validação mista. A princípio, com relação ao estudo anterior, do caso 1 até o caso 4 apenas os resultados da validação mudaram, pois foram retirados destes os dados da sub-bacia de Serra Negra. Para todos os 4 primeiros casos, quando comparados aos da Tabela 6.7, houve uma pequena melhora no ajuste da vazão calculada pelo modelo aos dados observados da validação sem os de Serra Negra, com o coeficiente de determinação aumentando de 71% para 75% no caso 1, de 44% para 49% no caso 2, de 55% para 57% no caso 3 e de 77% para 79% no caso 4.

Tabela 6.8 – Resultados do modelo de RNA para a validação mista sem os dados de Serra Negra

Casos	Calibração			Teste de parada			Validação		
	$R^2$ (%)	EPE	ER (%)	$R^2$ (%)	EPE	ER (%)	$R^2$ (%)	EPE	ER (%)
1	93,00	4,93	1,02	71,00	86,50	-175,60	75,00	324,80	-752,40
2	92,00	5,70	-0,61	67,00	21,80	-9,51	49,00	20,30	-53,10
3	87,00	10,60	-0,37	70,00	25,70	-17,30	57,00	21,40	-32,40
4	78,00	13,80	-1,85	78,00	295,90	-642,30	79,00	17,14	-5,53
5	80,00	14,40	-1,39	48,00	11,80	-29,30	82,00	14,30	-14,70
6	80,00	14,30	-0,16	66,00	14,17	7,90	39,00	6,43	-57,80
7	81,00	13,40	-0,58	91,00	13,00	-19,30	33,00	41,80	-332,50
8	83,00	13,00	-0,51	91,00	15,60	-1,60	2,00	62,30	-233,90
9	78,00	12,90	-0,22	55,00	5,86	-44,50	59,00	25,60	-56,10
10	88,00	9,50	-1,10	25,00	1559,30	-10881,20	63,00	98,90	-176,00
11	86,00	7,10	0,00	25,00	14,90	22,90	28,00	36,90	63,30
12	90,00	6,00	-1,92	3,00	264,30	-653,30	61,00	47,93	-103,00

Do caso 5 até o 7, Serra Negra integrava antes os dados do conjunto teste de parada e nessa nova edição seus dados foram substituídos pelos de Antenor Navarro, Aparecida e Augusto Severo, respectivamente. Observa-se que, para os três novos casos, também houve pequenas melhorias no ajuste aos dados do teste de parada, com o  $R^2$  que antes era de 39% agora passou a ser 48% no caso 5, de 50% passou a ser 66% no caso 6 e, finalmente, de 86% passou a ser 91% no caso 7.

A partir do caso 8 até o caso 13, os dados de Serra Negra antes integravam os dados do conjunto de calibração. Nesta nova avaliação também ocorreram melhoras no ajuste da resposta do modelo à vazão desejada quando da eliminação dos dados deste posto, exceto no caso 9, onde antes o coeficiente de determinação era de 82% e agora diminuiu para 78%. Porém, um fato intrigante é que, apesar de haver melhorias no ajuste da fase de calibração com a extinção dos dados de Serra Negra do conjunto de treinamento da rede (casos 8 a 12), não houve melhorias relevantes no ajuste nas demais fases de teste e validação, contrariando o fato de que com dados mais apurados poderia se chegar a melhores resultados. Nesses casos, em geral, ocorreu uma pequena depreciação dos resultados para a fase de teste de parada e uma pequena melhora para a fase de validação. No entanto, isto pode ser entendido pelo fato de que, como já mencionado, estes últimos casos apresentam conjuntos com tendência a homogeneidade, ou seja, com dados físicos pouco variáveis, constituídos por sub-bacias de portes semelhantes, configurando amostras pouco representativas do universo de dados.

Assim, as melhorias com a exclusão dos dados de Serra Negra foram tímidas, não evidenciando razão principal nos casos onde não houve ajustes satisfatórios. Observaram-se as mesmas causas antes citadas, ou seja, também nessa etapa nota-se que, nos casos de melhores ajustes, as sub-bacias responsáveis pela calibração do modelo possuem uma boa variabilidade do

seu tamanho, ou da variável física área ( $A$ ) e, por conseguinte, do comprimento do rio principal ( $L$ ), que tende a aumentar potencialmente com a área, assim como, da magnitude dos eventos sazonais, uma vez que observa-se vazões maiores em bacias grandes e, gradualmente, menores em bacias de menor porte. De forma inversa, percebe-se que, nos casos onde isso não ocorreu, o modelo não consegue representar a vazão desejada de forma satisfatória na validação, apesar de ter um bom ajuste na calibração.

Isso leva a concluir que, apesar das sub-bacias em estudo participarem da mesma zona hidrologicamente homogênea, o comportamento hidrológico em cada sub-bacia se dá de forma distinta, ou seja, para uma entrada (chuva) no sistema (sub-bacia), a resposta (vazão) será ajustada às suas condições físicas inerentes. Assim, sub-bacias de pequeno porte não conseguirão, através do modelo, representar a vazão de sub-bacias maiores na validação e vice-versa.

### 6.2.3. ANÁLISE DOS RESULTADOS NA VALIDAÇÃO CLÁSSICA

Para avaliar as análises feitas durante a validação mista, este método de avaliação do modelo de RNA foi proposto para analisar o comportamento das saídas oferecidas pelo modelo quando este possui amostras representativas do universo de dados. Para isso, construiu-se várias combinações, priorizando sempre a representatividade variada dos dados no conjunto de calibração da rede neural. Como foi constatado na validação cruzada e mista, a inclusão dos dados de Serra Negra não acarretou resultados positivos, por isso, para essa etapa do trabalho, decidiu-se por excluí-los.

#### *a) Combinação 1*

A primeira combinação de sub-bacias está mostrada na Figura 6.15, onde se escolheu bacias com magnitudes de tamanho intercaladas na formulação dos dois conjuntos a serem trabalhados, porém, com os exemplos extremos de sub-bacias sempre no conjunto de treinamento da rede, de forma que o modelo de RNA possa interpretar e interpolar suas respostas através deste. Neste caso, a extensão da série alocada para a calibração da rede equivale a 52% e para validação 48%.

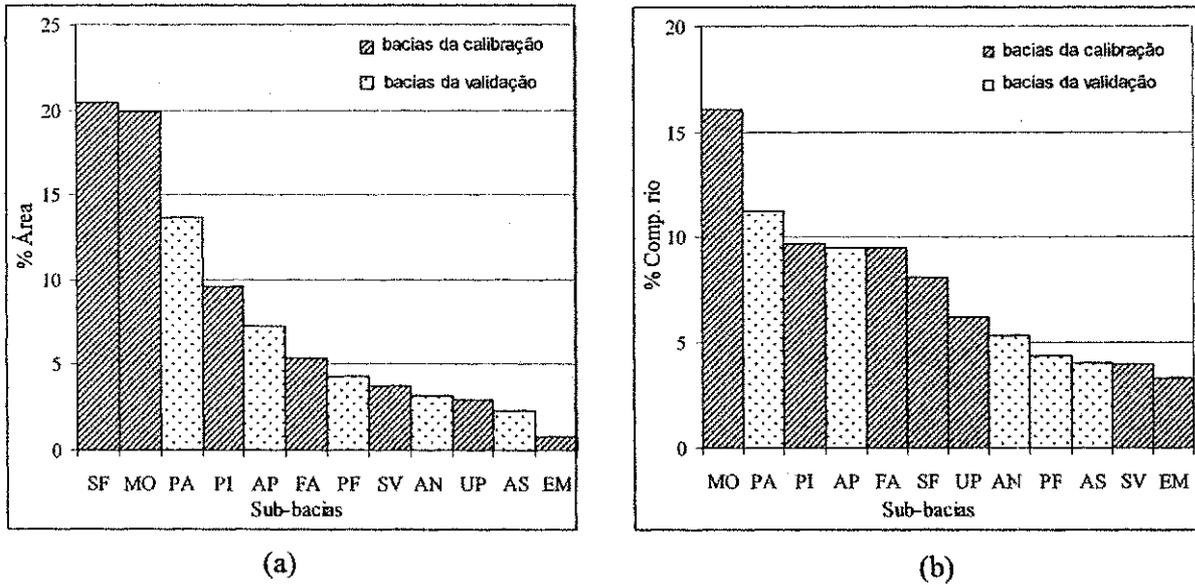


Figura 6.15 - (a) Variação da área para a combinação 1 da validação clássica e (b) variação do comprimento do rio para a combinação 1 da validação clássica.

Neste caso, o modelo alcançou no ajuste aos dados da calibração um  $R^2$  de 82% e de 73% para a validação, como pode ser visto na Tabela 6.9. O comportamento do ajuste das saídas do modelo pode ser visto na Figura 6.16. Nota-se, nas Figuras 6.16c e 6.16d, que o modelo subestimou três picos na fase de validação contidos na série no posto de Pedra de Abelhas. Observando-se a Figuras 6.16a, referente ao comportamento do ajuste das saídas calculadas às observadas na calibração, nota-se a existência de apenas um grande evento. Certamente, se existissem mais eventos desse tipo no conjunto de treinamento da rede, esta poderia melhorar ainda mais seu desempenho na fase de validação, conseguindo explicar melhor todos os picos.

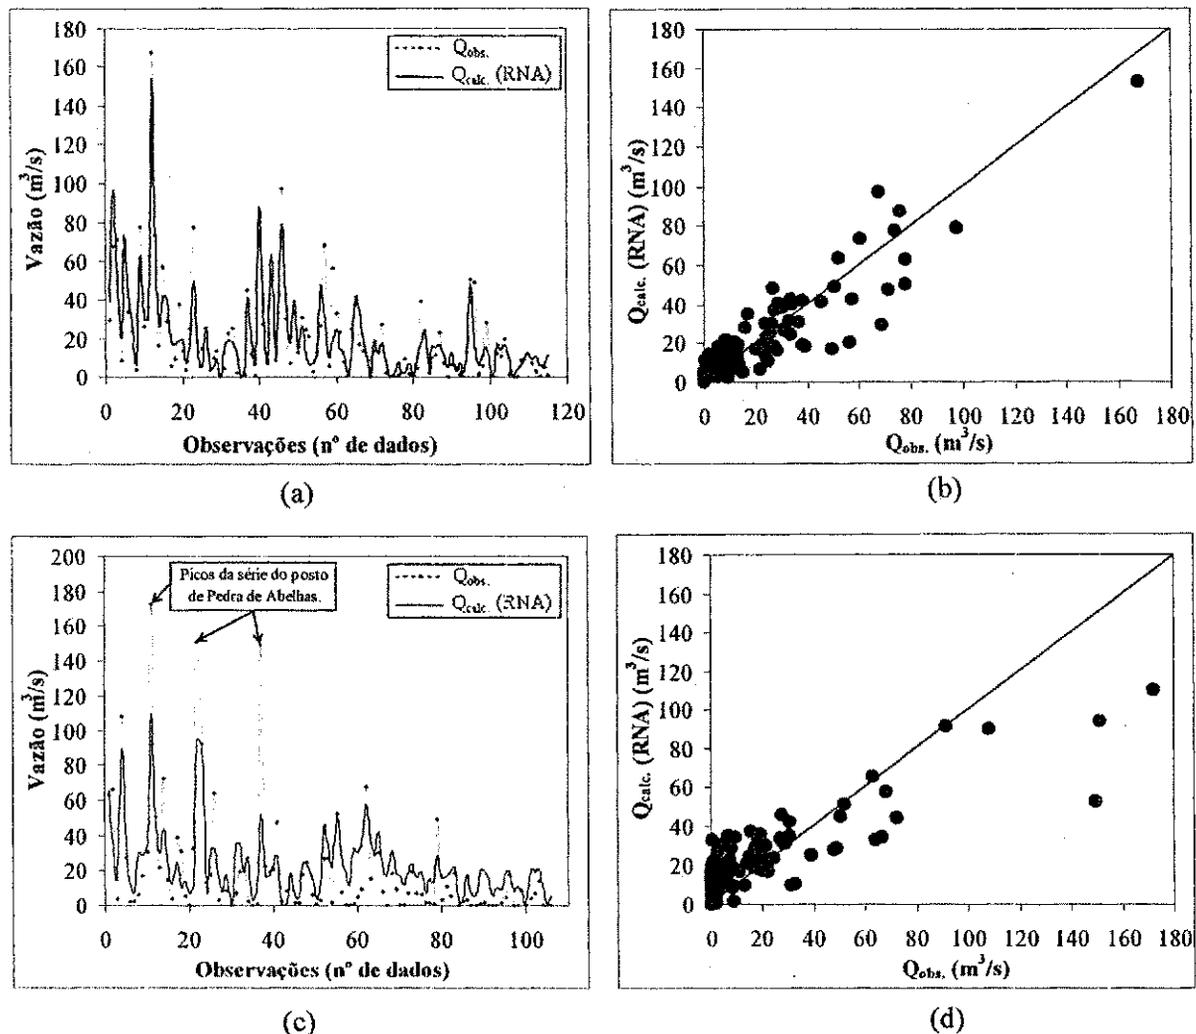


Figura 6.16 - (a) Comportamento do modelo na calibração da combinação 1 para validação clássica (b) Correlação na calibração da combinação 1 da validação clássica (c) Comportamento do modelo na validação da combinação 1 para validação clássica e (d) Correlação na validação da combinação 1 da validação clássica.

### b) Combinação 2

Uma segunda combinação realizada pode ser vista na Figura 6.17. Neste caso houve apenas uma troca de sub-bacias, com Antenor Navarro saindo do conjunto de calibração e passando a integrar o de validação, e a de Upanema que, antes, na combinação 1, pertencia ao de validação e agora passa a integrar o de calibração. Isto foi feito visto que estas possuem características semelhantes, com tamanhos parecidos. Assim, pode-se avaliar a sensibilidade do modelo a esta permuta. A extensão da série para o conjunto de calibração e de validação não se alterou, permanecendo a relação 52% e 48% da combinação 1.

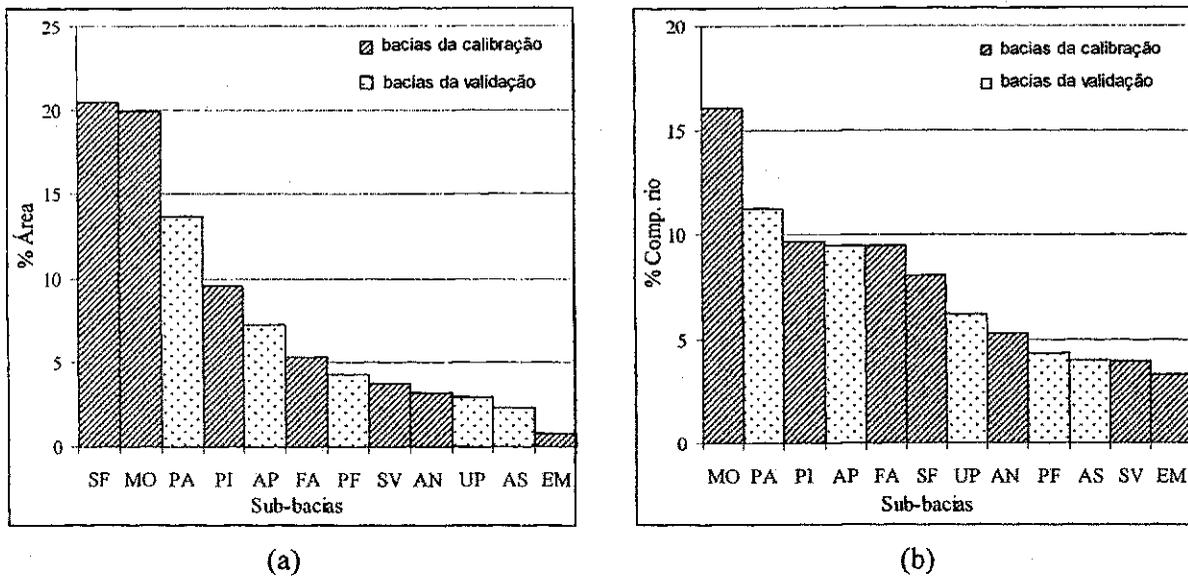


Figura 6.17 - (a) Variação da área para a combinação 2 da validação clássica e (b) Variação do comprimento do rio para a combinação 2 da validação clássica

Para este novo caso os indicadores de desempenhos praticamente se mantiveram inalterados (ver Tabela 6.9), com o coeficiente de determinação permanecendo o mesmo na fase de validação. Pouco se alterou também no comportamento gráfico visual do ajuste da vazão calculada à observada como pode ser notado na Figura 6.18.

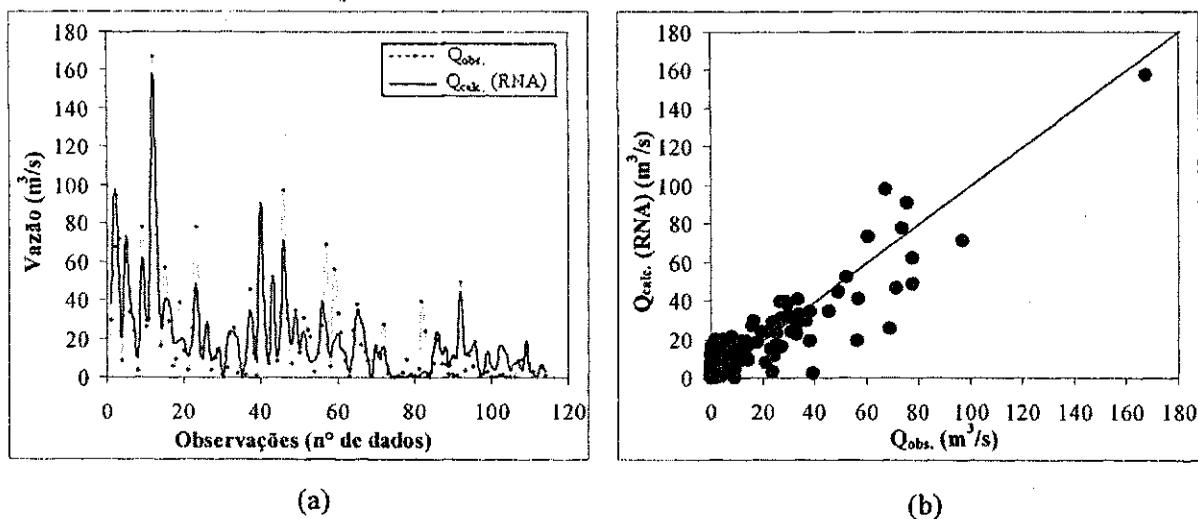


Figura 6.18 - (a) Comportamento do modelo na calibração da combinação 2 para validação clássica (b) Correlação na calibração da combinação 2 da validação clássica (c) Comportamento do modelo na validação da combinação 2 para validação clássica e (d) Correlação na validação da combinação 2 da validação clássica.

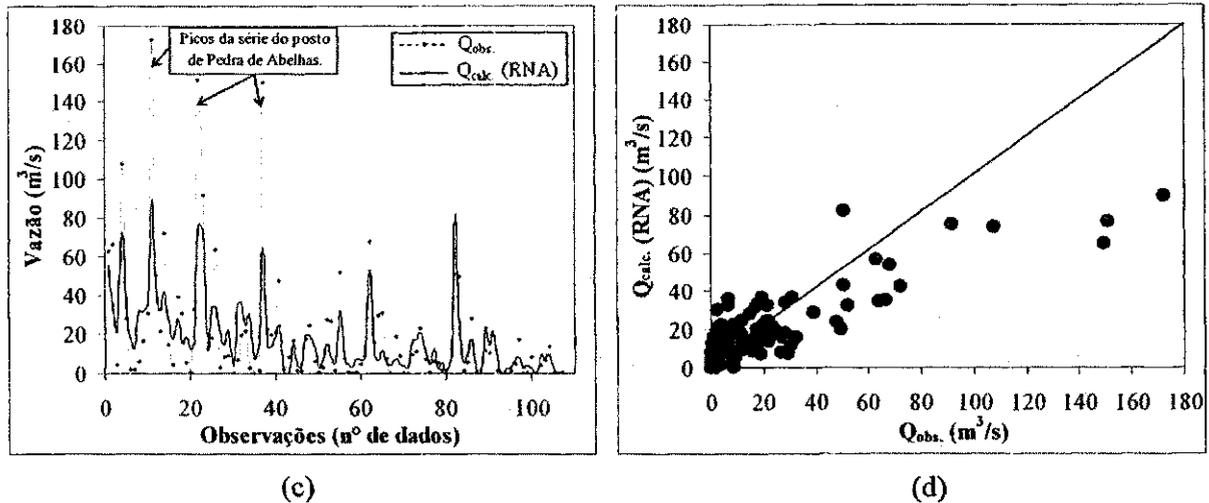


Figura 6.18 – Continuação: (a) Comportamento do modelo na calibração da combinação 2 para validação clássica (b) Correlação na calibração da combinação 2 da validação clássica (c) Comportamento do modelo na validação da combinação 2 para validação clássica e (d) Correlação na validação da combinação 2 da validação clássica.

### c) Combinação 3

Outra combinação foi realizada transferindo os dados da sub-bacia Sítio Volta para o conjunto de validação, resultando numa extensão da série para a calibração inferior à da validação, ficando com uma equivalência de 48% contra 52%; respectivamente. Contudo, o quadro novamente permaneceu estável, com uma sensível melhora nos resultados da calibração e também da validação.

A Figura 6.19 demonstra a distribuição dos dois conjuntos, cada um integrado por seis sub-bacias. Neste caso, as sub-bacias de Sítio Volta e Pau dos Ferros possuem características semelhantes, e podem ser entendidas pelo modelo através da interpolação entre as características existentes das sub-bacias Fazenda Angicos e Antenor Navarro, quanto à variável área, e entre Antenor Navarro e Emas para a variável comprimento de rio, como pode ser visto na Figuras 6.19a e 6.19b.

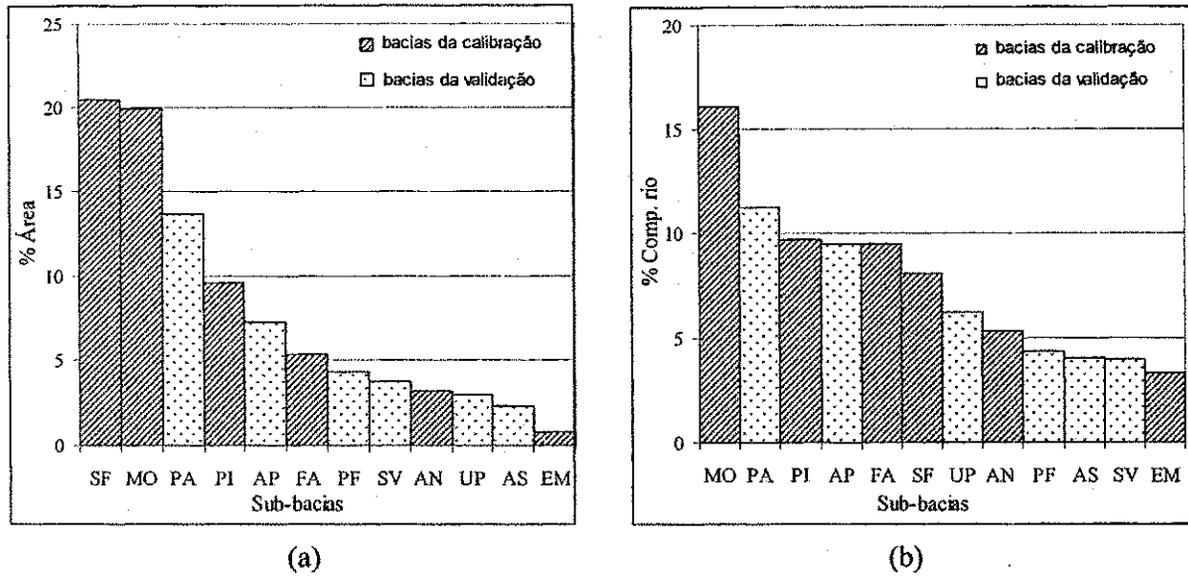


Figura 6.19 - (a) Variação da área para a combinação 3 da validação clássica e (b) variação do comprimento do rio para a combinação 3 da validação clássica

A série de dados alocados para treinar a rede neural foi menor do que a do conjunto de validação. Mesmo assim, o modelo conseguiu obter um bom resultado, superando, inclusive, as combinações 1 e 2 feitas para essa etapa de validação clássica. Neste caso, o modelo atingiu um coeficiente de determinação de 84% no ajuste da fase de calibração e de 75% no ajuste da validação (ver Tabela 6.9). Os comportamentos desses ajustes estão expressos na Figura 6.20.

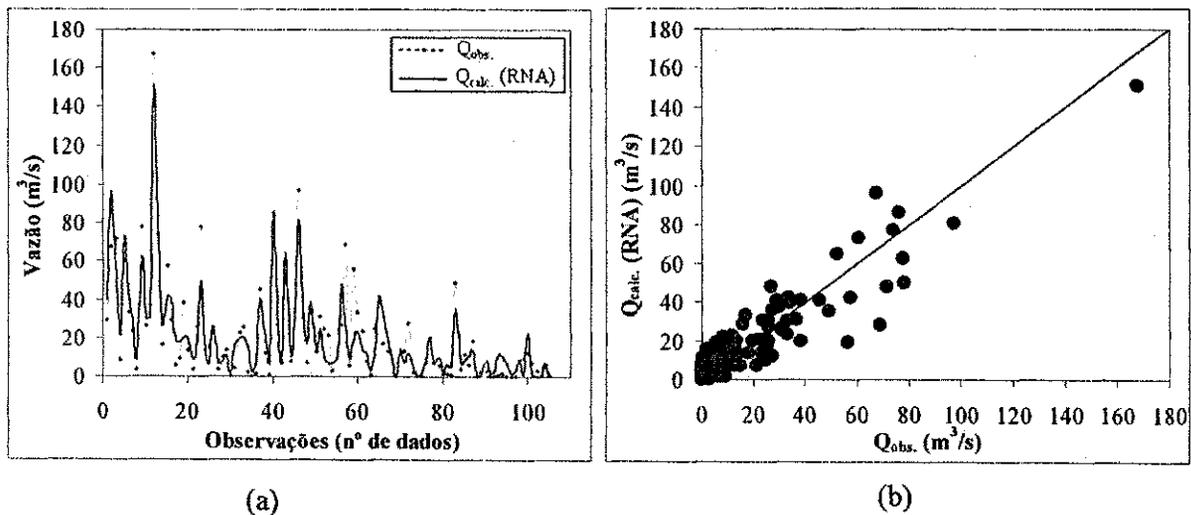


Figura 6.20 - (a) Comportamento do modelo na calibração da combinação 3 para validação clássica, (b) Correlação na calibração da combinação 3 da validação clássica, (c) Comportamento do modelo na validação da combinação 3 para validação clássica e (d) Correlação na validação da combinação 3 da validação clássica.

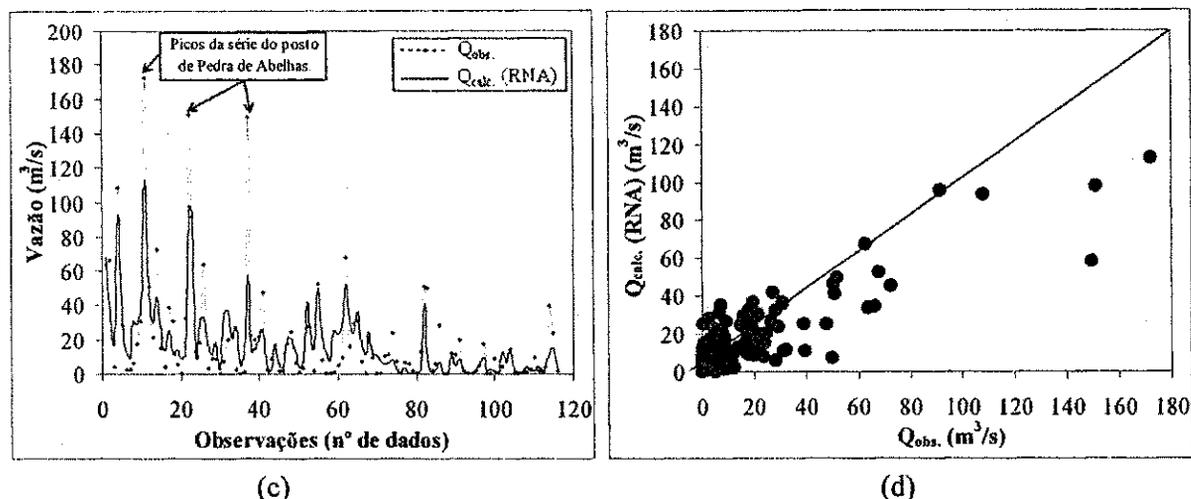


Figura 6.20 – Continuação: (a) Comportamento do modelo na calibração da combinação 3 para validação clássica, (b) Correlação na calibração da combinação 3 da validação clássica, (c) Comportamento do modelo na validação da combinação 3 para validação clássica e (d) Correlação na validação da combinação 3 da validação clássica.

Para todas as combinações feitas, primando-se sempre a boa variabilidade da amostra de dados, obteve-se êxito com o modelo de RNA tanto na calibração quanto na validação. A Tabela 6.9 abaixo resume todos os indicadores de desempenho alcançados no ajuste das saídas do modelo de RNA aos dados de vazões observados para as três combinações realizadas nesta fase de validação clássica.

Tabela 6.9 – Índices de desempenho obtido pelo modelo de RNA para as três combinações da validação clássica

Combinações	Calibração			Validação		
	$R^2$ (%)	EPE	ER (%)	$R^2$ (%)	EPE	ER (%)
1	82,00	10,70	-0,30	73,00	18,40	-20,30
2	80,00	11,40	-0,50	73,00	18,40	9,80
3	84,00	10,70	-0,40	75,00	16,30	7,30

### 6.3. RESULTADOS DA PREVISÃO DE VAZÃO

Até o presente momento trabalhou-se com a simulação de eventos observados, tanto na fase de calibração do modelo de RNA quanto na de validação. Nesse caso, o termo usual para a precipitação sazonal observada é de *previsão perfeita*, ou seja, teoricamente isenta de erros, uma vez que tais eventos foram observados. Assim, os erros cometidos na representação da vazão média

diária sazonal eram de competência do modelo hidrológico. Agora, pretende-se avaliar esse modelo hidrológico, já devidamente calibrado e validado, em conjunto com um modelo meteorológico na previsão da vazão propriamente dita. Para isso, faz-se necessário obter dados de previsão de chuva sazonal, fornecida por um modelo meteorológico, para servirem como padrão de entrada para o modelo hidrológico. Assim, os erros cometidos nessa etapa serão de competência do modelo hidrológico e do modelo meteorológico.

### 6.3.1. PREVISÃO DA PRECIPITAÇÃO SAZONAL

Os indicadores de desempenho foram calculados de forma análoga aos já conhecidos na avaliação do ajuste da vazão. A Tabela 6.10 apresenta estes índices obtidos na comparação das previsões das precipitações sazonais realizadas pelo modelo meteorológico RSM aos dados observados de precipitação.

Tabela 6.10 – Índices de desempenho do modelo RSM na previsão da precipitação sazonal

Sub-bacias	$R^2$ (%)	EPE	ER (%)
Antenor Navarro	48,0	169,4	-4,7
Aparecida	52,0	180,0	-9,9
Pau dos Ferros	28,0	191,7	3,9
Piancó	47,0	150,4	-5,1
São Fernando	41,0	138,2	2,6
Sítio Volta	49,0	192,3	-47,6
Todas juntas	51,0	162,0	-5,2

Nota-se, em geral, um baixo rendimento do modelo, onde, na última linha tem-se, para os dados de todas as sub-bacias juntas, um coeficiente de determinação da ordem de 51%. Nesse caso, apesar do Erro Relativo (ER) ser baixo, apenas 5,2% em módulo, houve uma grande dispersão entre a precipitação prevista e a observada (ver Figura 6.21). Assim, apenas cerca de 50% das variações existentes entre as variáveis causa/efeito da precipitação foram captadas pelo modelo meteorológico. No entanto, deve-se ressaltar que tal modelo apresentou um bom comportamento quanto à tendência de representação dos picos dos eventos de chuvas (ver Figura 6.22).

Observa-se que, no caso de Pau dos Ferros, em relação aos demais, o modelo RSM apresentou uma depreciação considerável nos seus resultados, obtendo um coeficiente de determinação de apenas 28%. Isso, possivelmente, pode ser explicado, pelo fato dessa sub-bacia estar contida, geograficamente, no limite de cobertura do modelo, tendo, para esse caso, um número inferior de valores gerados da precipitação a serem interpolados através da grade.

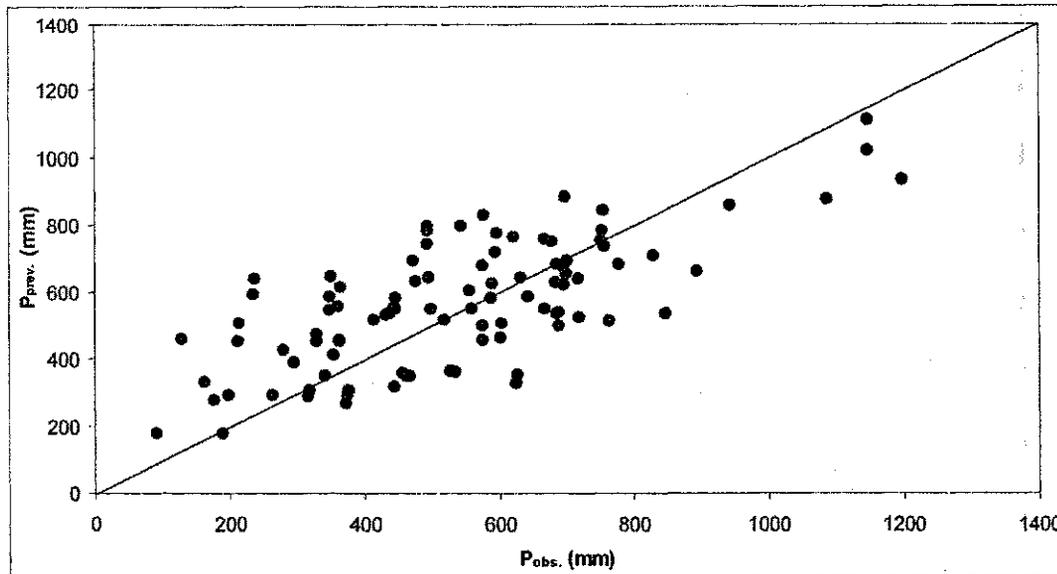


Figura 6.21 - Correlação entre a precipitação prevista pelo modelo RSM e a observada para os dados de todas sub-bacias juntas.

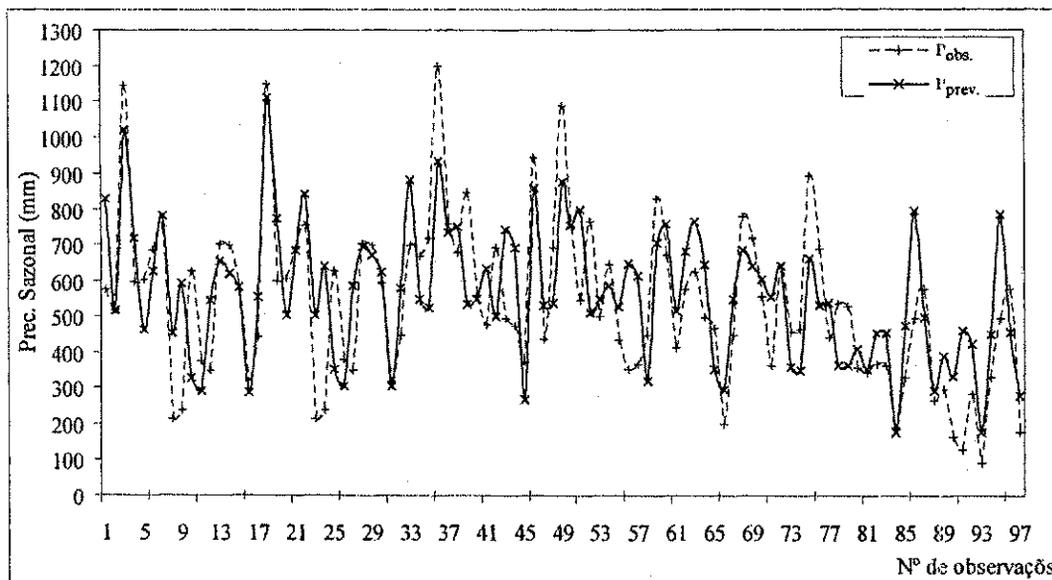


Figura 6.22 - Comportamento do modelo RSM na previsão da precipitação sazonal para os dados de todas as sub-bacias juntas.

A Tabela 6.11 mostra os resultados de todas as previsões das precipitações sazonais para cada sub-bacia. Nota-se que, o modelo de previsão de precipitação utilizado, como foi dito, tende acompanhar as variações temporais da precipitação; porém, não a contento, ficando aquém do necessário para a obtenção de uma previsão confiável, refletindo o alto nível de incertezas associado à previsibilidade dessa variável. Isso, naturalmente, poderá afetar negativamente os resultados da previsão da vazão.

Tabela 6.11 – Séries sazonais de precipitação observada ( $P_{obs}$ ) e prevista ( $P_{prev}$ ) em mm.

Ano	Antenor Navarro		Aparecida		Pau dos Ferros		Piancó		São Fernando		Sítio Volta		
	$P_{obs}$	$P_{prev}$	$P_{obs}$	$P_{prev}$	$P_{obs}$	$P_{prev}$	$P_{obs}$	$P_{prev}$	$P_{obs}$	$P_{prev}$	$P_{obs}$	$P_{prev}$	
1971	577,0	829,7			698,5	884,4	943,2	859,0	633,2	640,7			
1972	519,2	517,7			667,6	548,8	438,0	533,1	457,3	358,2			
1973					718,7	524,8	689,9	537,3	463,0	350,3			
1974					1197,6	934,0	1085,6	877,0	893,9	660,4			
1975					757,3	735,7	750,6	755,2	686,6	532,6			
1976					678,4	750,0	543,7	797,6	440,2	538,2			
1977					847,1	533,7	763,7	512,6	535,9	361,0			
1978					560,1	548,5	499,4	548,8	527,6	363,4			
1979					476,7	632,3	642,8	586,1	354,1	410,7	295,6	388,7	
1980					689,1	499,5	432,8	529,0	342,5	351,5	163,1	330,9	
1981					495,2	743,1	351,5	646,5	364,2	452,8	129,8	459,1	
1982					473,2	692,2	364,5	613,4	363,5	453,8	279,9	424,6	
1983					374,0	266,6	445,5	317,7	189,1	176,5	91,9	177,2	
1984								829,3	705,4	330,0	473,7	330,0	449,3
1985	1145,7	1019,7	1146,7	1110,3					495,1	795,9	495,1	784,4	
1986	596,0	718,8	598,0	776,7				668,8	758,1	576,3	496,3	576,3	456,2
1987	603,1	462,3	605,1	503,8				414,4	517,3	263,4	291,1	177,5	277,7
1988	684,5	627,1	686,5	683,7				575,4	680,0				
1989	753,1	781,6	755,1	843,1				622,0	766,3				
1990	212,7	452,5	213,7	505,5									
1991	235,3	593,0	237,3	638,4				497,0	641,9				
1992	625,9	328,8	627,9	352,0				468,0	350,6				
1993	375,0	291,8	378,0	305,6				198,2	293,6				
1994	348,9	546,4	349,9	585,4				447,0	548,6				
1995	700,4	653,0	702,4	693,6				778,0	683,3				
1996	696,1	618,9	697,1	671,9				718,0	638,9				
1997	588,9	581,2	590,9	624,6				556,9	602,1				
1998	317,6	288,2	319,6	305,8									
1999	445,0	553,6	447,0	580,1				361,6	555,5				

### 6.3.2. PREVISÃO DA VAZÃO MÉDIA DIÁRIA SAZONAL E ANÁLISE DAS INCERTEZAS

A previsão de vazão diária sazonal foi avaliada mediante os modelos de RNA e Regressão Múltipla de Melo (2003), já calibrados na etapa de validação cruzada.

Nas Tabelas 6.12 e 6.13, tem-se a comparação do desempenho dos modelos hidrológicos de RNA e Regressão Múltipla (Melo, 2003) para dois casos: (i) na simulação da vazão média diária sazonal, feita com os dados observados de precipitação e (ii) na previsão desta vazão, realizada através dos dados de precipitação sazonal previstos. Percebe-se que a transformação chuva-vazão está bem caracterizada por ambos os modelos tratados.

O desempenho dos modelos hidrológicos foram superiores aos do modelo meteorológico, pois, como pode ser visto na Tabela 6.12, ambos obtiveram coeficientes de determinação acima de 52%, chegando até a 96% para os dados da sub-bacia de Aparecida. No caso do modelo meteorológico, para previsão da precipitação, esse coeficiente não ultrapassou 52% (Tabela 6.10).

Tabela 6.12 – Comparação entre RNA e Regressão Múltipla (Melo, 2003) na simulação da vazão média diária sazonal a partir de dados de chuva sazonal observados

Sub-bacias	$R^2$ (%)		EPE		ER (%)	
	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)
Antenor Navarro	86,0	89,0	7,5	5,4	-100,2	-2,4
Aparecida	96,0	97,0	19,4	13,0	20,6	18,4
Pau dos Ferros	84,0	85,0	8,5	34,0	-3,7	-144,1
Piancó	63,0	62,0	13,7	16,5	8,6	13,6
São Fernando	52,0	52,0	39,0	45,3	27,3	50,7
Sítio Volta	64,0	65,0	13,4	14,1	73,2	79,6

Porém, os resultados da previsão da vazão sazonal foram surpreendentes, como podem ser vistos na Tabela 6.13. Apesar da propagação das incertezas, a depreciação nos resultados da vazão prevista não acompanhou a mesma proporção vista na previsão da precipitação, ocorrendo, inclusive, melhorias nas respostas dos modelos hidrológicos quando submetidos aos dados de precipitação prevista, como o foram para as sub-bacias de São Fernando e Sítio Volta.

As incertezas acumuladas em todo o processo da previsão da vazão sazonal, decorrentes dos modelos hidrológico e meteorológico, em termos do coeficiente de determinação, estão contidas na faixa de 22 a 73% para o modelo de RNA, e de 9 a 73% para o modelo de Regressão Múltipla (Melo, 2003). Entretanto, na grande maioria das vezes, o  $R^2$  se manteve acima de 66% para ambos os modelos hidrológicos, restando, assim, menos de 34% das variações entre as variáveis a serem compreendidas pelos modelos.

Tabela 6.13 – Comparação entre RNA e Regressão Múltipla (Melo, 2003) na previsão da vazão média diária sazonal a partir de dados de chuva sazonal previstos

Sub-bacias	$R^2$ (%)		EPE		ER (%)	
	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)	RNA	Reg. Múlt. (Melo)
Antenor Navarro	66,0	69,0	9,6	8,0	-108,5	-2,5
Aparecida	88,0	91,0	20,9	16,2	8,8	7,1
Pau dos Ferros	27,0	27,0	16,7	23,8	12,0	-86,1
Piancó	48,0	48,0	17,0	16,4	9,9	13,5
São Fernando	77,0	76,0	36,0	45,7	34,4	57,8
Sítio Volta	79,0	79,0	10,5	9,7	45,1	48,3

A Tabela 6.14 mostra a variação das incertezas, com relação ao coeficiente de determinação, produzidas pelos modelos hidrológicos de RNA e Regressão Múltipla (Melo, 2003), entre os níveis de simulação da vazão sazonal (com a precipitação observada) e o nível de previsão da vazão sazonal (com a precipitação prevista). Os valores negativos referem-se à depreciação deste indicador de desempenho entre as duas fases, os valores positivos referem-se ao aumento relativo deste indicador.

Assim, por exemplo, para Antenor Navarro houve uma depreciação no coeficiente de determinação, da fase de simulação para a de previsão da vazão sazonal, de 23,3% para o modelo hidrológico de RNA e de 22,5% para o modelo de Regressão Múltipla. A previsão da vazão para a sub-bacia de Pau dos Ferros foi a que obteve maior depreciação, em torno de 68%, o que já era de se esperar, pois, como foi visto, o modelo meteorológico não obteve bons resultados, para tal bacia, pelos motivos já discutidos anteriormente.

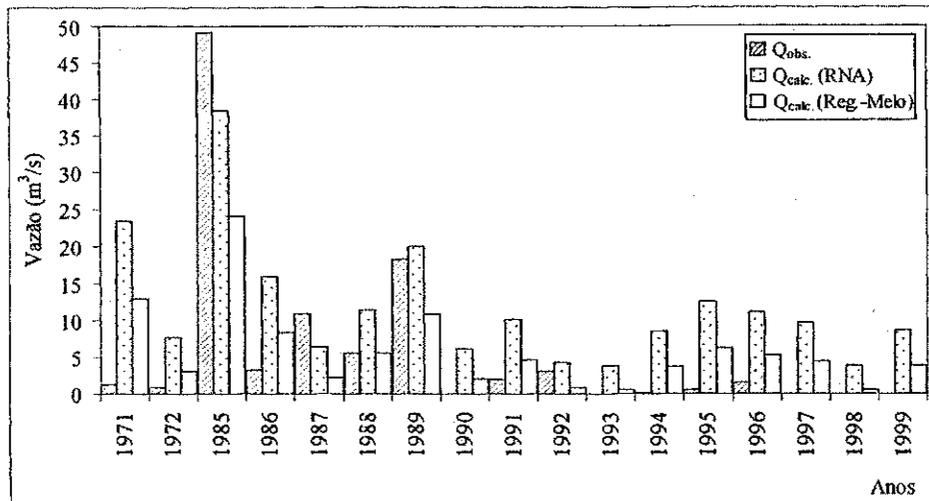
Verifica-se que, ao contrário das demais, as previsões de vazões sazonais, realizadas para as sub-bacias de São Fernando e Sítio Volta, obtiveram um aumento relativo do coeficiente de determinação, onde, para o modelo de RNA teve-se um aumento relativo de 48,1 e 23,4%, respectivamente, enquanto que, para o modelo de Regressão Múltipla, o aumento relativo foi de 46,2 e 21,5%, respectivamente. De maneira geral, observa-se que o processo da transformação chuva-vazão, na bacia hidrográfica, através dos modelos hidrológicos, atenuou as incertezas contidas na previsão da precipitação.

Tabela 6.14 – Variação relativa do coeficiente de determinação entre os níveis de simulação da vazão sazonal e o da previsão

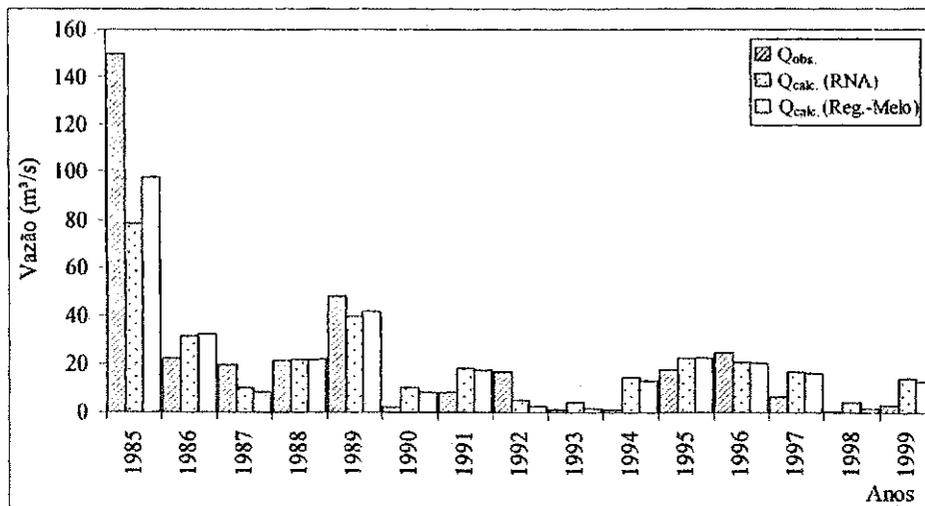
<i>Sub-bacias</i>	<i>Variação Relativa do R<sup>2</sup> (%)</i>	
	<i>RNA</i>	<i>Reg. Múlt. (Melo)</i>
Antenor Navarro	-23,3	-22,5
Aparecida	-8,3	-6,2
Pau dos Ferros	-67,9	-68,2
Piancó	-23,8	-22,6
São Fernando	48,1	46,2
Sítio Volta	23,4	21,5

Os resultados das previsões de vazões também estão expressos na Figura 6.23. Observa-se que, na maioria dos casos, houve uma tendência dos modelos em representar as variações dos picos dos eventos. No entanto, visivelmente, nota-se que o modelo de RNA não obteve um resultado satisfatório na previsão da vazão para Antenor Navarro (ver Figura 6.23.a), onde, apesar do mesmo

ter obtido um coeficiente de determinação razoável de 66%, o Erro Relativo (*ER*), para esse caso, foi de 108,5%. O mesmo pode ser observado, para ambos os modelos, no caso de Pau dos Ferros; porém, para esse caso, como foi dito, é compreensível, tendo em vista as limitações do modelo meteorológico já levantadas anteriormente.

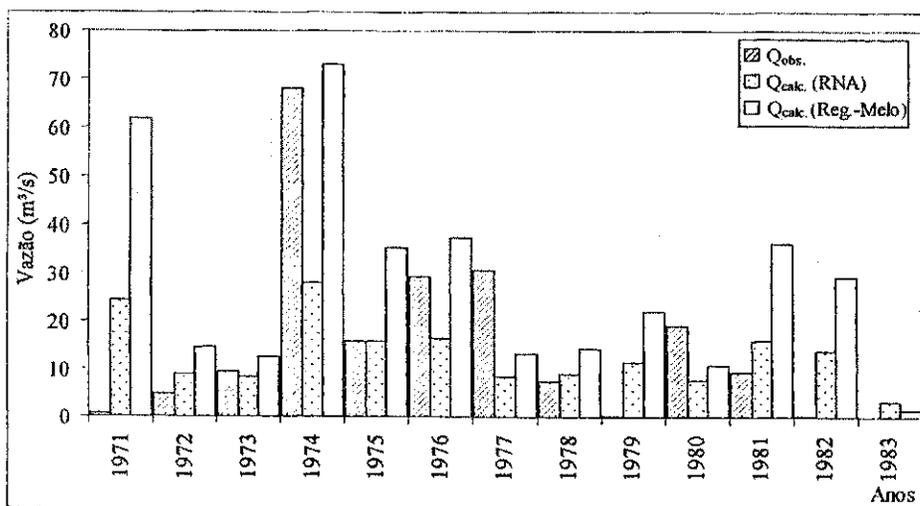


(a) Antenor Navarro

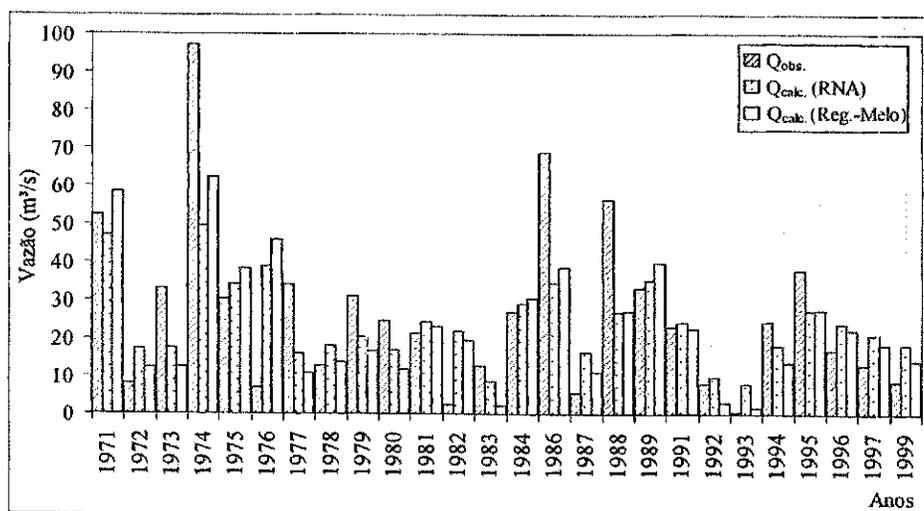


(b) Aparecida

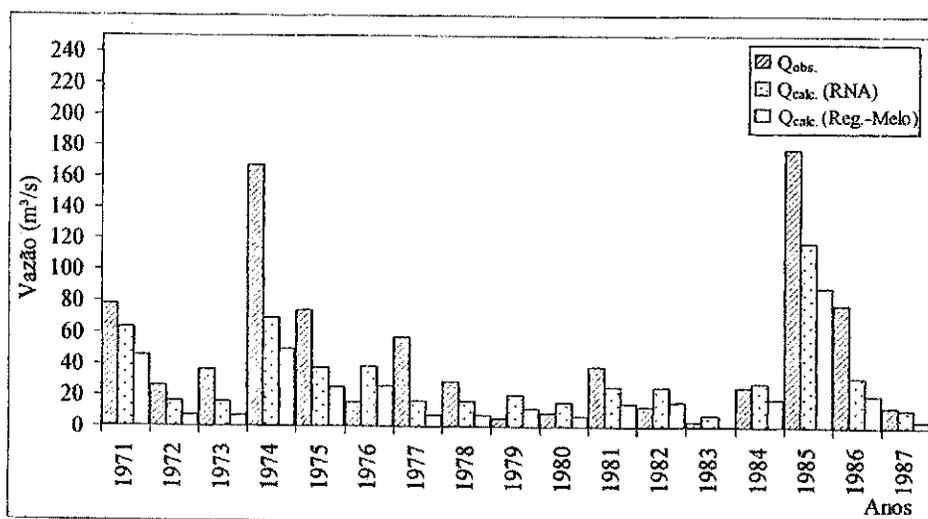
Figura 6.23 – Resultado da previsão da vazão média diária sazonal com os modelos de RNA e Regressão Múltipla de Melo para as sub-bacias de: (a) Antenor Navarro, (b) Aparecida, (c) Pau dos Ferros, (d) Piancó, (e) São Fernando e (f) Sítio Volta.



(c) Pau dos Ferros



(d) Piancó



(e) São Fernando

Figura 6.23 – Continuação: Resultado da previsão da vazão média diária sazonal com os modelos de RNA e Regressão Múltipla de Melo para as sub-bacias de: (a) Antenor Navarro, (b) Aparecida, (c) Pau dos Ferros, (d) Piancó, (e) São Fernando e (f) Sítio Volta.

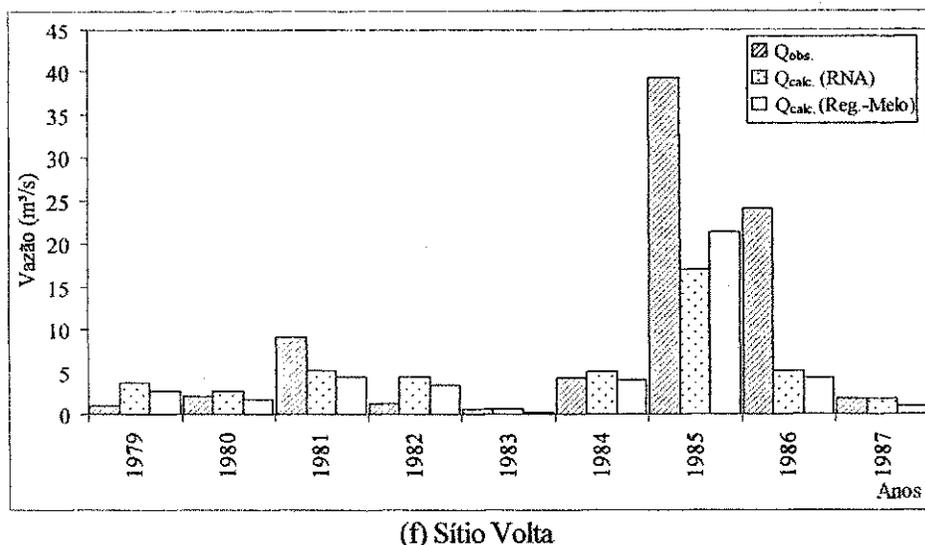


Figura 6.23 – Continuação: Resultado da previsão da vazão média diária sazonal com os modelos de RNA e Regressão Múltipla de Melo para as sub-bacias de: (a) Antenor Navarro, (b) Aparecida, (c) Pau dos Ferros, (d) Piancó, (e) São Fernando e (f) Sítio Volta.

#### 6.4. AVALIAÇÃO E COMPARAÇÃO FINAL ENTRE RNA E REGRESSÃO MÚLTIPLA

O método empírico de RNA obteve um bom desempenho na simulação da vazão média diária sazonal a partir de dados de precipitação sazonal observadas para todas as diferentes etapas de verificação, sendo compatível com métodos tradicionais como o de Regressão Múltipla. No entanto, há de se admitir a desvantagem dessa técnica frente à de Regressão no que diz respeito ao elevado número de parâmetros requeridos por esta, visto que, neste caso, foram usados 11 parâmetros no ajustamento da rede neural enquanto que na Regressão apenas 4 parâmetros foram usados. Todos os parâmetros da Equação 6.6, calibrados para todas as etapas, estão apresentados no Anexo A, sendo que, os parâmetros aptos a serem regionalizados juntamente com o modelo de RNA desenvolvido nesse estudo na simulação e previsão da vazão média diária sazonal, para a área estudada, podem ser encontrados na Equação 6.7. Este por sua vez, foi ajustado explorando-se todos os dados disponíveis, exceto os dados da sub-bacia de Serra Negra e os anos anômalos do ano de 1985 das séries dos postos de Piancó e São Fernando.

$$Q_c = 1318,3163 \left[ \frac{2}{(1 + e^{(-2N_1)})} - 1 \right] - 1318,179 \left[ \frac{2}{(1 + e^{(-2N_2)})} - 1 \right] + 0,1449 \quad (6.7)$$

onde:

$$N_1 = 3,988P + 0,5023A - 1,4841L - 2,6376 \quad (6.8)$$

$$N_2 = 3,988P + 0,5018A - 1,4847L - 2,6374 \quad (6.9)$$

A Figura 6.24 apresenta o comportamento no ajuste deste modelo para este caso. O modelo obteve um coeficiente de determinação de 82%. O erro padrão da estimativa (*EPE*) foi de  $12 \text{ m}^3/\text{s}$ . Tendo em vista que a vazão média é de  $20 \text{ m}^3/\text{s}$ , pode-se avaliar tal erro como elevado para os padrões da região estudada. Porém, o erro relativo foi baixo, de  $-1,80\%$ , refletindo a boa aproximação dos pontos gráficos à reta de igual valor, como pode ser visto nessa figura.

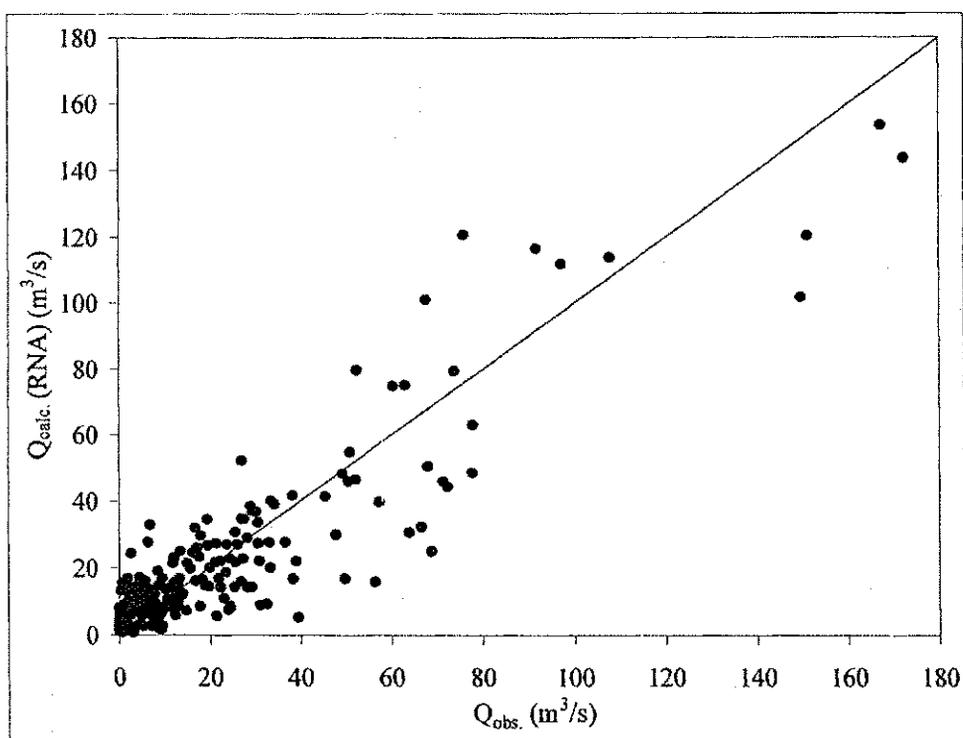


Figura 6.24 – Correlação existente no ajuste das vazões observadas às calculadas pelo modelo de RNA a ser regionalizado (todas as sub-bacias).

Para se avaliar qual destas metodologias é a mais viável no tocante à aplicabilidade, teria que se apresentar outras variáveis que auxiliassem essa decisão, como: implementação do modelo, custos, dinamismo, adaptabilidade dos modelos a novas realidades, etc. Deva-se salientar que o objetivo deste trabalho não se limita apenas a propor uma nova técnica que possa resultar na melhoria dos resultados obtidos, mas sim, ao estudo de um modelo que hoje é considerado cada vez mais nos campos científicos, inclusive na hidrologia, e que, por ser novo, é algo que precisa ser investigado e aprofundado.

Tanto o modelo de RNA quanto o modelo desenvolvido por Melo, na maioria das vezes, apresentaram resultados satisfatórios quando submetidos à previsibilidade da vazão média diária sazonal. Apesar dos dados fornecidos pelo modelo de previsão da precipitação sazonal ainda conterem uma razoável imprecisão, verifica-se que estas incertezas são atenuadas durante a transformação da chuva em vazão, na bacia, através dos modelos hidrológicos.

## 7. CONCLUSÕES E RECOMENDAÇÕES

### 7.1. CONCLUSÕES

Este estudo se propôs a investigar a técnica de Redes Neurais Artificiais como método de previsão da vazão média diária sazonal agregada à técnica de regionalização, bem como comparação do seu desempenho com o método tradicional de Regressão Múltipla utilizado em estudos anteriores. Diante disso, podem-se chegar as seguintes conclusões:

- O modelo baseado nas técnicas de Redes Neurais Artificiais (3-2-1) mostrou-se adequado na previsão da vazão média diária sazonal e na regionalização desta por meio de parâmetros e funções, tendo em vista os bons índices estatísticos obtidos no ajuste deste, tanto na fase de calibração quanto na de validação.
- A técnica de Redes Neurais Artificiais mostrou desempenho semelhante ao do estatístico clássico de Regressão Múltipla utilizado por Melo (2003), conseguindo alcançar, na fase de validação cruzada, coeficientes de determinação contidos na faixa entre 65 a 74% na fase de calibração e de 50 a 96% na fase de validação, enquanto que o método aplicado por Melo (2003) obteve coeficientes de determinação entre 60 a 71% na calibração e 51 a 97% na fase de validação. Os demais índices de desempenho, na sua maioria, acompanharam bem a tendência de variação do  $R^2$ .
- A Rede Neural superou o método de Regressão Múltipla de Melo quando da exclusão dos dados inconsistentes do posto de Serra Negra, obtendo no ajuste com as demais sub-bacias um coeficiente de determinação igual a 74%, contra 66% do método de Melo (2003).
- Existem relações entre a qualidade do ajuste do modelo e a conformidade das grandezas físicas das sub-bacias, de modo que se faz necessário uma pré-avaliação dos dados, sendo necessário reservarem-se amostras representativas do conjunto de bacias para a calibração da Rede Neural, visto que, nos casos onde isso ocorreu, tanto na validação mista quanto na clássica, o modelo de RNA obteve um bom ajuste.
- Ambos os modelos de RNA e Regressão Múltipla de Melo (2003), quando avaliados como possíveis modelos de previsão de vazão média diária sazonal, apesar dos elevados níveis de

imprecisões contidas na previsão da precipitação sazonal, obtiveram, de forma geral, bons resultados, sendo capazes de acompanhar as variações dos picos das vazões observadas. A Rede Neural obteve na previsão da vazão sazonal coeficientes de determinação contidos na faixa de 48 a 88%, enquanto que para a Regressão este índice esteve na faixa de 48 a 91%, excetuando-se os resultados para a sub-bacia de Pau dos Ferros por essa apresentar restrições ao modelo de previsão da precipitação RSM.

- As incertezas acumuladas, propagadas para a etapa da previsão da vazão, foram atenuadas no processo da transformação da chuva em vazão, nas bacias hidrográficas, por ambos os modelos hidrológicos de RNA e Regressão Múltipla aplicado por Melo (2003).
- Os resultados de uma regionalização, em termos de função e parâmetros, em virtude das incertezas a eles associadas, devem ser usados com cuidado;
- Conclui-se, contudo, que o modelo hidrológico de RNA com fins de regionalização, na forma como foi desenvolvido neste trabalho, pode servir como modelo de previsão da vazão média diária sazonal, como foi comprovado na simulação com os dados observados e mesmo nas aplicações de previsão da vazão às quais o modelo foi submetido. Pode-se esperar uma maior confiabilidade desta previsibilidade para casos em que se tenha um melhor nível de confiança da previsão da precipitação.

## 7.2. RECOMENDAÇÕES

Além das sugestões já citadas ao longo desta dissertação, baseado no conhecimento até aqui adquirido, faz-se ainda algumas recomendações a trabalhos posteriores:

- Incorporar tanto ao modelo de RNA quanto ao de Regressão Múltipla de Melo (2003) novas variáveis físicas como uso do solo, área coberta por vegetação, etc, que possam, juntamente com as atuais, melhor explicar a variável vazão média diária sazonal;
- Trabalhar com novas séries de chuva-vazão observadas, para a área estudada, que tenham lacunas preenchidas e observar as possíveis melhoras nos resultados;
- Prever a precipitação sazonal com um outro modelo meteorológico mais robusto para, então, prever a vazão média diária sazonal.
- Acoplar o modelo empírico de RNA a um modelo hidrológico precipitação-vazão, como por exemplo, na realização, por meio da RNA, da regionalização dos parâmetros desse modelo.

**REFERÊNCIAS BIBLIOGRÁFICAS**

ALMEIDA, R.; BARBOSA, P.S.F. (2004). *Previsão de secas hidrológicas com base em um modelo de redes neurais artificiais*. In: VII Simpósio de Recursos Hídricos do Nordeste. São Luís / MA.

BALLINI, R.; FRANÇA, E.; KADOWAKI, M.; SOARES, S. (1997). *Modelos de redes neurais e box & jenkins para previsão de vazão média mensais*. In: XII Simpósio Brasileiro de Recursos Hídricos, CD-ROOM, Vitória / ES.

BARP, A.R.B., BARBOSA, P.S.F. (1999). *Comparação entre modelo hidrológico conceitual chuva-vazão (SMAP) e modelo de redes neurais artificiais (RNA)*. In: IV Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa – IV SILUSBRA, 1999, Coimbra, Portugal. Anais ... CD-ROM.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDEMIR, T.B. (2000). *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro, RJ: Livros técnicos e científicos.

CAMPOS, R.L.D.; BÁEZ, Y.F. (2002). *Optimización del problema inverso en geofísica usando el algoritmo de entrenamiento de Levenberg-Marquardt*. Primer simposio colombiano de sismologia. "Avances de la Sismologia em los últimos veinte años". Disponível on-line em: <http://fing.javeriana.edu.co/geofisico/simposio2002/Metodos/PROBLEMA%20INVERSO%20EN%20GEOFISICA%20RN.PDF>. 10 Dez 2004.

CANNON, A.J.; WHITFIELD, P.H. (2002). Downscaling recent streamflow conditions in British Columbia, Canada using ensemble neural network models. *Journal of Hydrology*. vol. 259, pp. 136-151.

CARVALHO, A.P.L.F.; BRAGA, A.P.; LUDEMIR, T.B. (1998). *Fundamentos de redes neurais artificiais*. In: 11ª Escola de Computação, Rio de Janeiro, 246p.

CIRILO, J.A.; AZEVEDO, J.R.G.; MONTENEGRO, S.M.L. (1992). Modelos de simulação hidrológica aplicada à bacia hidrográfica do Estado de Pernambuco. In: I Simpósio de Recursos Hídricos do Nordeste, 1992, Recife.

DEMUTH, H.; BEALE, M. (1998). *Neural Network Toolbox for use with MATLAB – User's guide*, version 3. The Math Works, Inc.

DINIZ, L.S.; CLARKE, R.T. (2001). *Regionalização de parâmetros de modelo chuva-vazão usando redes neurais*. In: XIV Simpósio Brasileiro de Recursos Hídricos - Aracaju / SE, 2001.

EKLUND, P. (1994). Network size versus preprocessing. In: Yager, R. R., Zadeh, L. A. (Ed.). *Fuzzy sets, neural networks, and soft computing*, New York: Van Nostrand Reinhold. pp.250-264.

ELESBON, A.A.A.; FIOROT, P.; CESCNETO, E.; COSER, M.; MENDONÇA, A.S.F. (2002). Regionalização de vazões máximas, médias e mínimas para o estado do Espírito Santo visando futuras aplicações de SIG em sua automatização – ABRH. In: VI Simpósio de Recursos Hídricos do Nordeste. Maceió - AL, 2002.

FAVORETO, R.S.; ROHN, M.C.; MINE, M.R.M. (2001). A técnica de rede neural artificial aplicada na previsão de vazão. In: XIV Simpósio Brasileiro de Recursos Hídricos – V Simpósio de Hidráulica e Recursos Hídricos dos países de língua oficial portuguesa: gestão de Recursos Hídricos – O desafio da prática. Aracaju / SE, 2001.

FREITAS, V.A.F.; RAMEH, I.M.B.; VIEIRA, H.B.G.; ASFORA, M.C.; CIRILO, J.A. (2002). *Regionalização Hidrológica nas bacias 46, 47, 48, 49 do rio São Francisco* - ABRH. In: VI Simpósio de Recursos Hídricos do Nordeste. CD-ROM. Maceió - AL, 2002.

GALVÃO, C.O.; TRIGO, R.M. (1999). *Downscaling da precipitação e temperatura de modelos de circulação global para a escala de bacia hidrográfica*. In: IV Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa. Coimbra – Portugal

GALVÃO, C.O.; VALENÇA, M.J.S. (1999). *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*. 1ª ed. Porto Alegre, Editora da Universidade/UFRGS/ABRRH, 246p. (Coleção ABRH de Recursos Hídricos; vol. 7.)

GALVÃO, C.O.; CLARKE, R.T.; NOBRE, P. (2003) *Incertezas em previsão hidrometeorológica sazonal*. Campina Grande: UFCG. 30 p. [não publicado].

GALVÃO, C.O.; NOBRE, P.; BRAGA, A.C.F.M.; OLIVEIRA, K.F.; MARQUES, R.; SILVA, S.R.; GOMES FILHO, M.F.; SANTOS, C.A.G.; LACERDA, F.; MONCUNILL, D. (2005). *Climatic Predictability, Hydrology and water resources over Nordeste Brazil*. In: WAGENER, T.; FRANKS, S., GUPTA; H.V.; BØGH, E.; BASTIDAS, L.; NOBRE, C.; GALVÃO, C.O. (EDS). *Regional Hydrological Impacts of Climatic Change - Impact Assessment And Decision Making*. Iahs Publ. N. 295, P. 211-220.

GARDNER, M.W.; DORLING, S.R. (1998). Artificial neural networks (the multilayer perceptron) – a review of applications in the atmospheric sciences. *Atmospheric Environment*. vol. 32, pp. 2627-2636.

GÓES, V.C.; CAMPANA, N.A. (2001). *Regionalização de vazões no Distrito Federal*. XIV. In: Simpósio Brasileiro de Recursos Hídricos, Gestão de Recursos Hídricos: O Desafio da Prática, art. 144, 16p. CD-ROM, Aracaju, 2001.

GUYTON, A.C.; HALL, J.E. (1997). Tratamento de fisiologia médica. 9ª ed., Rio de Janeiro, Editora Guanabara Koogan S. A., 1997. Cap45, pp. 510-537.

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

HANSELMAN, D.; LITTLEFIELD, B. (1999). *MATLAB 5 Versão do Estudante – Guia do Usuário*. São Paulo: MAKRON Books.

HAYKIN, S. (2001). *Redes neurais: princípios e práticas*; trad. Paulo Martins Engel. – 2ª edição – Porto Alegre: Bookman, 900p.

HEBB, D. (1949). *The organization of behavior: a neuropsychological theory*. New York, Wiley.

HINES, J.W. (1997). *MATLAB Supplement to fuzzy and neural approaches in engineering*. Chichester: John Wiley & Sons.

HOPFIELD, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities, *Proceedings of the National academy of Sciences, USA*, vol. 79, pp. 2554-2558.

IBGE (1995). *Anuário estatística do Brasil*.

- KHALIL, M.; PANU, U.S.; LENNOX, W.C. (2001). Groups and neural networks based streamflow data infilling procedures. *Journal of Hydrology*. vol. 241, pp. 153-176.
- KOIVÁCS, Z.L. (2002). *Redes neurais artificiais: fundamentos e aplicações*. 3ª ed., São Paulo, Editora Livraria da Física, 174p.
- LANNA, A.E. SILVEIRA, G.; TUCCI, C.E. (1983). *Regionalização de vazões mínimas na bacia do rio Jacuí*. In: V Simpósio Brasileiro de Hidrologia e Recursos Hídricos, Blumenau, novembro, 1983.
- LOESCH, C.; SARI, S. (1996). *Redes neurais artificiais: fundamentos e modelos*. Blumenau, Editora da FURB, 125p.
- LOKE, E. (1995). Introduction to artificial neural networks in urban hydrology.
- MCCULLOCH, W.S.; PITTS, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5: pp. 115-133.
- MEDEIROS, J.D.F.; DINIZ, L.S.; TUCCI, C.E. (2002). *Regionalização de curvas de regularização para diferentes garantias: rio Apodi-Mossoró/RN - ABRH*. In: VI Simpósio de Recursos Hídricos do Nordeste. CD-ROM. Maceió - AL, 2002.
- MELO, R.N.T. (2003). *Estimativa de vazões médias sazonais em bacias sem dados hidrométricos para uso em sistemas de previsão hidrometeorológica*. Campina Grande. Dissertação (Mestrado) – UFCG/CCT, 122p.
- MICROSOFT COPORATION (2003). Excel (2003). Microsoft Co.
- MINSKY, M.L.; PAPERT, S.A. (1969). *Perceptrons: an introduction to computational geometry*. Massachusetts, MIT Press.
- MOLLER, M.F. (1993). A scaled conjugate gradient algorithm for fast supervised learnig. *Neural Network*. vol. 6. pp. 525-533.
- MARENGO, J.A.; CAVALCANTI, I.F.A.; SATYAMURTY, P.; NOBRE, C.A.; BONATTI, J.P.; MANZI, A.O.; TROSNIKOV, I.; SAMPAIO, G.; CAMARGO, H., SANCHES, M.B.; CUNNINGHAM, C.A.C.; D'ALMEIDA, C.; PEZZI, L.P. (2003). *Assessment of regional seasonal*

*rainfall predictability using the CPTEC/COLA atmospheric GCM. Climate Dynamics* 21, 459–475.

MÜLLER, M.; FILL, H.D. (2003). *Redes neurais aplicadas na propagação de vazões*. In: XV Simpósio Brasileiro de Recursos Hídricos. CD-ROM. Curitiba / PR, 2003.

MOREIRA, F.M.; MELO, C.R.; SANTOS, A.S.; ALMEIDA, T.A.; MAIA, F.M. V.L. (2002) – Estudo de regionalização da sub-bacia 39 - ABRH. In: VI Simpósio de Recursos Hídricos do Nordeste. CD-ROM. Maceió - AL, 2002.

NAYAK, P.C.; SUDHEER, K.P.; RANGAN, D.M.; RAMASASTRI, K.S. (2003). A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*. vol. 291, pp. 52–66.

OLIVO, A.A., SILVA, J.D.S., VIJAYKUMAR, N.L. (2002). *Previsão de cheias fluviais usando redes neurais artificiais*. In: VI Simpósio de Recursos Hídricos do Nordeste. Maceió / AL.

OSÓRIO, F.S.; VIEIRA, R. (1999). Tutorial de sistemas híbridos inteligentes. In: *Cong. da Soc. Brás. Computação – ENIA '99 – Encontro Nacional de Inteligência Artificial*, Rio de Janeiro.

RAMOS, A.M.; GALVÃO, C.O. (2001). Estabilidade de redes neurais em modelagem hidrometeorológica. In: XIV Simpósio Brasileiro de Recursos Hídricos - V Simpósio de Hidráulica e Recursos Hídricos dos países de língua oficial portuguesa: gestão de Recursos Hídricos – O desafio da prática. Aracaju / SE, 2001.

ROCHESTER, N.; HOLLAND, J.N.; HAIBT, L.H.; DUDA, W.L. (1956). Tests on cell assembly theory of action of the brain, using a large digital computer. *IRE Transactions on Information Theory IT-2*, pp. 80-93.

ROHN, M.C.; MINE, M.R.M. (2003). *Uma aplicação das redes neurais artificiais a previsão de chuvas de curtíssimo prazo*. In: XV Simpósio Brasileiro de Recursos Hídricos. CD-ROM. Curitiba / PR, 2003.

ROSENBLATT, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, nº65, pp. 386-408.

ROSENBLATT, F. (1962). *Principles of neurodynamics: perceptrons and the theory of brain mechanisms*. New York, Spartan Books.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. (1986). Learning representations by back-propagating errors. *Nature*, 323, pp. 533-536.

SANTOS, C.C. (2001). *Modelagem de bacias urbanas com redes neurais artificiais*. São Paulo. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Hidráulica e Sanitária, 105p.

SARMENTO, F.J. (1996). Modelagem de séries hidrológicas através de redes de neurônios. *Revista Brasileira de Recursos Hídricos – RBRH*, vol. 1, nº2, pp. 19-31.

SILVA, J.F.R.; ARAÚJO, L.M.N. (2002). *Regionalização de vazões no Estado do Maranhão – ABRH*. In: VI Simpósio de Recursos Hídricos do Nordeste. Maceió – AL, 2002.

TAFNER, M.A.; XEREZ, M.; RODRIGUES FILHO, I.W. (1996). *Redes neurais artificiais: introdução e princípios de neurocomputação*. Blumenau, EKO / Editora da FURB, 199p.

TAVARES, J.C.; BARROS, P.S.T.; ARAÚJO, L.M.N. (2002). *Otimização de rede fluviométrica através de estudos de regionalização - ABRH*. In: VI Simpósio de Recursos Hídricos do Nordeste. CD-ROM. Maceió - AL, 2002.

THOMÉ, A.C.G.; MARQUES, C.P.B. (2003) *Inteligência Computacional – Aula 11 – MLP (MultiLayer Perceptron)*. Disponível on-line em: <http://equipe.ncc.ufjf.br/thome/grad/nn/curso/mdidatico.htm>. 15 Jun 2004.

TUCCI, C.E. M. (1993). Ciclo Hidrológico. In: *Hidrologia, Ciência e Aplicação*. Ed. da Universidade Federal do Rio Grande do Sul. Porto Alegre. p 35-40.

TUCCI, C.E.M. (2002). *Regionalização de vazões*. 1ª ed., Rio Grande do Sul, Editora Universidade/UFRGS, 256p.

UFPB/ANEEL (2001). *Regionalização de vazões características de longo termo para os rios da Sub-bacia 37*. Convênio no. 0007/2000, AERH/CCT/Campus II, Campina Grande - PB, Junho de 2001.

VALENÇA, M.J.S. (1997). *Aplicação de redes neurais na área de recursos hídricos*. In: XII Simpósio Brasileiro de Recursos Hídricos, CD-ROOM, Vitória / ES.

VALENÇA, M.J.S.; LUDERMIR, T.B. (1999a). Introdução às redes neurais. *In: Galvão, C.O.; Valença, M.J.S. (Org.). Sistemas Inteligentes; aplicações a recursos hídricos e ciências ambientais.* Porto Alegre: Associação Brasileira de Recursos Hídricos. pp.19-59.

VALENÇA, M.J.S.; LUDERMIR, T.B. (1999b). Introdução às redes neurais. *In: Galvão, C.O.; Valença, M.J.S. (Org.). Sistemas Inteligentes; aplicações a recursos hídricos e ciências ambientais.* Porto Alegre: Associação Brasileira de Recursos Hídricos. pp.61-96.

VEMURI, V.R. (1994). *Artificial neural networks – forecasting times series.* Los Alamitos, IEEE Computer Society Press.

VON ZUBEN, F.J. (1996). Modelos paramétricos e não-paramétrico de redes neurais artificiais e aplicações. Tese de Doutorado. Faculdade de Engenharia Elétrica da Universidade Estadual de Campinas. FEE/DECAI, 243p.

WIDROW, B.; HOLL, M.E. (1960). Adaptive switching circuits. Institute of Radio Engineers, Western Electronic Show and Convention, pp. 96-104.

# ANEXO

## Anexo A: Parâmetros do modelo de RNA de múltiplas camadas (3-2-1).

Parâmetros da RNA de múltiplas camadas (3-2-1) na validação cruzada													
Parâmetros	Caso 1	Caso 2	Caso 3	Caso 4	Caso 5	Caso 6	Caso 7	Caso 8	Caso 9	Caso 10	Caso 11	Caso 12	Caso 13
$w_{1,1}$	3,7527	3,5815	1,8301	-1,7940	-3,6607	189,5700	-1,8484	2,8240	2,0967	4,1456	1,7546	-3,7297	-3,7312
$w_{2,1}$	-3,7526	3,5814	-1,8182	1,8660	3,6608	1,7383	1,8357	2,8242	1,6365	4,1456	-1,7736	-3,7296	3,7312
$w_{1,2}$	0,6515	0,2664	-6,0670	-1,0274	-0,5841	-147,8756	5,9781	0,3092	1,1020	0,5051	-7,9727	-0,6313	-0,6647
$w_{2,2}$	-0,6520	0,2673	-1,0519	-5,7278	0,5846	1,0116	1,0699	0,3099	-11,3660	0,5054	-1,0280	-0,6318	0,6652
$w_{1,3}$	-1,7043	-1,2878	-10,7208	-0,1192	1,6364	-608,8538	10,6919	-1,5745	0,2203	-1,4418	-13,8948	1,6342	1,7272
$w_{2,3}$	1,7036	-1,2876	-0,1600	-10,0538	-1,6358	0,6805	0,1921	-1,5740	-20,7253	-1,4415	-0,1706	1,6335	-1,7265
$b_1$	-2,4841	-2,3465	11,4077	5,7724	2,4020	389,4635	-11,3378	-1,8385	-6,3137	-2,7723	14,9345	2,4830	2,4114
$b_2$	2,4843	-2,3467	6,0372	10,6763	-2,4023	-5,0772	-6,0937	-1,8388	22,0703	-2,7724	5,8081	2,4833	-2,4117
$w_{3,1}$	-1241,0069	-1184,4338	0,1367	-529,5792	1255,7773	0,0604	-0,1407	-1171,3785	831,2862	-1920,5768	0,1397	1234,0635	1215,4098
$w_{3,2}$	-1241,1709	1184,6304	-793,9511	0,1311	1255,9138	77,6408	805,3192	1171,5030	0,1288	1920,7197	-553,1823	-1234,2963	1215,5460
$b_3$	0,1744	0,2013	793,8002	529,4307	0,1478	77,5672	805,1676	0,1264	831,1540	0,1606	553,0209	0,2432	0,1385

Parâmetros da RNA de múltiplas camadas (3-2-1) na validação mista com Serra Negra													
Parâmetros	Caso 1	Caso 2	Caso 3	Caso 4	Caso 5	Caso 6	Caso 7	Caso 8	Caso 9	Caso 10	Caso 11	Caso 12	Caso 13
$w_{1,1}$	-2,7874	3,1549	-3,1308	-2,5788	2,1796	2,0087	96,6935	1,0223	1,5053	4,3475	4,6762	-4,7781	-21,6027
$w_{2,1}$	-2,7937	-3,1551	-3,1305	1,7749	-2,0311	-2,0108	1,8433	1,0221	146,5142	-4,3077	2,7688	-3,0757	-3,2513
$w_{1,2}$	-2,7270	1,0752	-1,3225	-3,2941	1,1478	2,5410	-88,0281	1,1745	1,5709	1,3669	-1,5624	11,4122	12,1402
$w_{2,2}$	-2,6975	-1,0754	-1,3221	-37,1158	18,5071	-2,5380	1,2134	1,1735	-122,8268	-1,3566	3,5243	4,1203	-2,8503
$w_{1,3}$	-1,0647	-2,2645	2,4458	2,1049	-0,0079	-0,5356	-102,1479	1,3575	-0,5340	0,0345	-5,5187	-6,9312	10,6781
$w_{2,3}$	-1,3863	2,2675	2,4412	-10,4461	29,7767	0,5364	0,4974	1,3557	29,6765	-0,0527	-2,0184	-4,8985	-0,0756
$b_1$	5,6648	-2,6516	2,9241	6,1632	-5,5375	-7,2612	80,4148	-5,5638	-2,1306	-6,6261	-3,4172	8,2608	12,2350
$b_2$	5,9475	2,6511	2,9248	31,8943	-33,0532	6,7221	-5,1039	-6,0974	19,9962	6,9413	-4,3769	4,9239	4,1006
$w_{3,1}$	-80,8411	1890,8590	1951,5986	-427,0341	187,8683	-623495,8203	0,0604	-210648,7221	0,8902	-4815,4329	-4,5704	102,0702	0,0536
$w_{3,2}$	78,9177	1890,4105	-1951,9502	0,0965	-0,0976	-213490,3296	63,6269	614532,1603	0,1847	-9629,7147	26,5630	-3,5141	-1,3384
$b_3$	1,9170	0,4334	0,3361	426,9719	187,7755	-410005,4777	63,5773	403883,3876	0,6619	4814,2859	21,9840	-98,5601	1,2841

## Anexo A: Parâmetros do modelo de RNA de múltiplas camadas (3-2-1).

Parâmetros da RNA de múltiplas camadas (3-2-1) na validação mista sem Serra Negra												
Parâmetros	Caso 1	Caso 2	Caso 3	Caso 4	Caso 5	Caso 6	Caso 7	Caso 8	Caso 9	Caso 10	Caso 11	Caso 12
$w_{1,1}$	-2,7874	3,1549	-3,1308	-2,5788	2,1796	2,0087	96,6935	-1,8880	-1,9601	-0,0016	5,1959	6,5209
$w_{2,1}$	-2,7937	-3,1551	-3,1305	1,7749	-2,0311	-2,0108	1,8433	-9,4865	-84,6136	2,7419	5,1856	-1,6046
$w_{1,2}$	-2,7270	1,0752	-1,3225	-3,2941	1,1478	2,5410	-88,0281	-1,4127	-1,4743	-0,0001	-4,2506	0,8097
$w_{2,2}$	-2,6975	-1,0754	-1,3221	-37,1158	18,5071	-2,5380	1,2134	34,8917	70,5995	1,4568	-4,2327	-1,0375
$w_{1,3}$	-1,0647	-2,2645	2,4458	2,1049	-0,0079	-0,5356	-102,1479	-0,9068	-0,1442	0,0011	4,4269	20,3661
$w_{2,3}$	-1,3863	2,2675	2,4412	-10,4461	29,7767	0,5364	0,4974	-21,8477	-14,0122	4,2939	4,4388	-2,1462
$b_1$	5,6648	-2,6516	2,9241	6,1632	-5,5375	-7,2612	80,4148	6,7267	2,7195	-0,3166	-5,3759	-13,6721
$b_2$	5,9475	2,6511	2,9248	31,8943	-33,0532	6,7221	-5,1039	-1,5868	-13,5018	-8,4037	-5,3714	4,0172
$w_{3,1}$	-80,8411	1890,8590	1951,5986	-427,0341	187,8683	-623495,8203	0,0604	-730,0500	-0,8502	-136,0765	-76,3451	-0,1228
$w_{3,2}$	78,9177	1890,4105	-1951,9502	0,0965	-0,0976	-213490,3296	63,6269	-0,0702	-0,1166	186,2665	76,4800	-5,3262
$b_3$	1,9170	0,4334	0,3361	426,9719	187,7755	-410005,4777	63,5773	729,9991	0,7131	144,5777	0,1467	5,1694

Parâmetros da RNA de múltiplas camadas (3-2-1) na validação clássica			
Parâmetros	Caso 1	Caso 2	Caso 3
$w_{1,1}$	-3,1748	2,0270	-3,2013
$w_{2,1}$	3,1741	2,0264	3,2013
$w_{1,2}$	0,1741	2,0600	0,3377
$w_{2,2}$	-0,1730	2,0589	-0,3370
$w_{1,3}$	0,9341	-3,2831	0,9382
$w_{2,3}$	-0,9343	-3,2804	-0,9384
$b_1$	2,2023	-1,4372	1,8689
$b_2$	-2,2021	-1,4380	-1,8689
$w_{3,1}$	1757,8501	-1541,5585	2012,3061
$w_{3,2}$	1758,3055	1543,2507	2012,4601
$b_3$	0,4258	1,6375	0,1477